



**UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
CÂMPUS DE ILHA SOLTEIRA**

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

VALQUÍRIA RIBEIRO DE CARVALHO MARTINHO

**SISTEMA INTELIGENTE PARA A PREDIÇÃO DE GRUPO DE RISCO
DE EVASÃO DISCENTE**

Ilha Solteira (SP), 2014

VALQUÍRIA RIBEIRO DE CARVALHO MARTINHO

**SISTEMA INTELIGENTE PARA A PREDIÇÃO DE GRUPO DE RISCO
DE EVASÃO DISCENTE**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira - UNESP, como parte dos requisitos necessários à obtenção do título de *Doutora em Engenharia Elétrica*.

Área de Concentração: Automação.

Prof. Dr. CARLOS ROBERTO MINUSSI

Orientador

Ilha Solteira (SP), 2014

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

M385s Martinho, Valquíria Ribeiro de Carvalho.
Sistema inteligente para a predição de grupo de risco de evasão discente: - /
Valquíria Ribeiro de Carvalho Martinho. -- Ilha Solteira: [s.n.], 2014
145 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia
de Ilha Solteira. Área de conhecimento: Automação, 2014

Orientador: Carlos Roberto Minussi
Inclui bibliografia

1. Redes neurais artificiais. 2. Teoria da ressonância adaptativa. 3. Rede
neural ARTMAP-*Fuzzy*. 4. Sistema inteligente. 5. Predição da evasão escolar no
ensino superior. 6. Proatividade.


CERTIFICADO DE APROVAÇÃO

TÍTULO: Sistema inteligente para a predição de grupo de risco de evasão discente

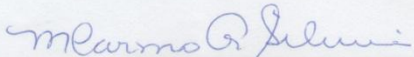
AUTORA: VALQUIRIA RIBEIRO DE CARVALHO MARTINHO

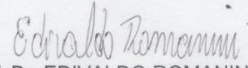
ORIENTADOR: Prof. Dr. CARLOS ROBERTO MINUSSI


Aprovada como parte das exigências para obtenção do Título de DOUTOR EM ENGENHARIA ELÉTRICA, Área: AUTOMAÇÃO, pela Comissão Examinadora:


Prof. Dr. CARLOS ROBERTO MINUSSI
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

Prof. Dra. ANNA DIVA PLASENCIA LOTUFO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Prof. Dra. MARIA DO CARMO G DA SILVEIRA
Departamento de Engenharia Elétrica / Universidade Estadual Paulista "Júlio de Mesquita Filho"


Prof. Dr. EDIVALDO ROMANINI
Departamento de Ciências Exatas / Universidade Federal de Mato Grosso do Sul


Prof. Dr. FERNANDO NOGUEIRA DE LIMA
Departamento de Engenharia Elétrica / Universidade Federal do Mato Grosso

Data da realização: 24 de fevereiro de 2014.

Valquíria Ribeiro de Carvalho Martinho

Professora efetiva do Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso. Formada em Engenharia Elétrica pela Universidade Federal de Mato Grosso e Licenciatura Plena para formação especial de professores para curso de ensino de 2º grau, pelo Centro Federal de Educação Tecnológica do Paraná. Especialização na área de concentração de Didática Geral, pela Faculdade de Educação de Assis. Mestre em Educação, na Área de Concentração de Teorias e Práticas Pedagógicas de Educação Escolar pela Universidade Federal de Mato Grosso. Doutoranda em Engenharia Elétrica no Programa de Pós-Graduação em Engenharia Elétrica pela Universidade Estadual Paulista “Júlio de Mesquita Filho” - Câmpus de Ilha Solteira. e-mail to: vribeiro@terra.com.br

Àqueles Seres aos quais estou ligada,
ontem, hoje e eternamente,
pelo mais sublime dos sentimentos, o *Amor*.

Ademar e Eunice, meus pais.

Fernando, Marina e Júlia, minha família.

AGRADECIMENTOS

Construir esta seção do trabalho é como tecer uma belíssima e grandiosa colcha, composta de maneira harmônica e respeitosa por todos aqueles diferentes e suas diferenças, que se fizeram presentes em minha Vida ao longo do período de construção e desenvolvimento do doutorado. Cada um, dentro de seu limite, com sua individualidade, particularidade, especificidade, vontade, importância, utilidade e intenção, contribuíram para a concretização e o êxito deste trabalho, possibilitando assim que eu fechasse mais um ciclo e atingisse mais um ponto de plenitude em minha caminhada. O fio usado para unir e compor as partes foi a Fé em uma Força Maior, Geradora de Luz, e o que existe de mais Puro, Verdadeiro e Nobre. Os vieses, encontros, desencontros e ajustes das partes para essa composição foram moldados com muito, muito Amor, Bondade, Alegria e Esperança e, o arremate final, uma Eterna Gratidão a Tudo, a Todos e ao Todo. Muito Obrigada!

Agradeço, de maneira especial...

A Deus, que é Pai, que é Filho e que é Espírito Santo, que habita em mim e em cada um de vós que se fizeram presentes nessa minha jornada. Ser Supremo, presença constante em minha vida, em quem eu posso Confiar e me Entregar, por estar sempre abrindo os caminhos, orientando, iluminando, consolando, e muitas vezes me carregando, me fortalecendo e reanimando para que eu pudesse, com Coragem, Perseverança e Alegria, trilhar esse caminho. Muito obrigada meu Pai!

Ao meu querido orientador, professor Carlos Roberto Minussi, ser humano admirável, especial e singular, por me aceitar como orientanda, após dois anos do início do doutorado, e, ainda, assumir e acreditar em uma proposta de pesquisa diferenciada. Pela convivência, que me possibilitou aprender com seu Exemplo e Simplicidade. É isso, sempre fez e faz tudo de maneira muito simples, seus exemplos, suas palavras, sua conduta, sua Vida... é tudo muito simples. Mas, com toda convicção, não escolheu o que é simples para fazer. Não se limita a orientar a pesquisa... Ele orienta Vidas! É uma mistura de Sábio, Filósofo, Mago.... Sabe Ouvir, coloca o máximo de Atenção naquele com quem dialoga, fala com propriedade e

Discernimento. Compreende, Reconhece e Respeita o limite de cada um. Com um sorriso maroto, tem sempre as palavras certas para abrandar corações e refrigerar almas. Nesse trecho do rio da minha Vida, durante o período do doutorado, passei por grandes cânions, enfrentei turbulências e remansos, mas confiei e sempre contei com o apoio de um Grande “Comandante”. Professor Minussi, Muito Obrigada! Sempre... sempre... sempre....

Aos professores Fernando Nogueira de Lima e Edivaldo Romanini, por aceitarem participar da banca examinadora e pelo respeito, zelo e rigor que demonstraram na compreensão e análise do trabalho, oferecendo valiosas contribuições para a melhoria da versão final desta tese.

À professora Anna Diva Plasencia Lotufo, uma mulher com jeito de menina, toda feminina, pela atenção, dedicação e exemplo de ternura com que recebe e acolhe a todos que a procuram. Por aceitar compor a banca examinadora, pelo incentivo, valorização do trabalho e sugestões para continuidade e publicações futuras.

À Maria do Carmo Gomes da Silveira, mulher elegante e delicada, por aceitar fazer parte da banca examinadora no Exame de Qualificação e, também, na defesa desta tese. Pelas contribuições enriquecedoras ao trabalho, advindas da leitura e análise minuciosa do mesmo.

Aos professores do PPGEE (Programa de Pós-Graduação em Engenharia Elétrica), pela possibilidade de construção dos conhecimentos ao longo do curso, pelo convívio e pelo exemplo de respeito e valorização com o ser humano em sua plenitude. E, especialmente...

Ao professor Rubén Augusto Romero Lázaro, pela iniciativa e ousadia em estabelecer parcerias interinstitucionais, como os Doutorados entre a Unesp-IFMT e Unesp-Unemat, possibilitando a capacitação de inúmeros profissionais, incentivando a pesquisa e ampliando os limites de abrangência do PPGEE da Faculdade de Engenharia Elétrica de Ilha solteira - Feis. E, também, pela seriedade, compromisso e qualidade com que desenvolve seu trabalho.

Ao professor José Carlos Rossi (*in memoriam*), por aceitar-me como orientanda, possibilitando meu ingresso no doutorado.

Ao professor Marcelo Carvalho Minhoto Teixeira, por acreditar em mim, me acolher e se oferecer para me orientar, quando do falecimento do professor Rossi.

Ao professor Edvaldo Assunção, pelas orações e intercessões pela saúde do Fernando, meu marido, e fortalecimento de toda minha família, quando, no início do doutorado, passamos por momentos extremamente difíceis e delicados.

Ao professor Dionízio Paschoareli Júnior e sua esposa, que me receberam em Ilha Solteira, me ouviram e se colocaram a disposição para o diálogo e reflexão, frente a uma decisão, tomada por mim, e que mudou todo o percurso do meu doutorado.

A todos os servidores e técnico-administrativos, de todos os Departamentos, Setores e Seções da Unesp, pelo carinho, atenção, orientação e colaboração dispensadas sempre que precisei. Pela estreita convivência, ressalto aqueles cujas marcas e lembranças deixadas em mim serão indeléveis: Mariana, Eder, Renato, Andressa, Luzinete, Fernanda, Adilson, Aderson, Márcia, Onilda e João.

Ao Deo (Deoclécio Mitsuiti Kosaka), com quem sempre pude contar para resolver os problemas relacionados à informática. Pela paciência, presteza, atenção, disposição e bondade para comigo, diante das minhas dúvidas, receios e dificuldades.

Ao João Josué Barbosa, pela atenção, presteza e cordialidade, pelas orientações e revisão do texto final da tese, quanto às normas da biblioteca da Unesp e da ABNT. E, também, a toda equipe da biblioteca, pela simpatia, carisma, atenção e cuidado com prestam o atendimento.

Aos Colegas do IFMT que compuseram a turma do Dinter e todos os colegas do SINTEL (Laboratório de Sistemas Inteligentes), pela oportunidade do convívio, pelos momentos de estudo, interação, discussões e contribuições mútuas, em momentos tão diversos ao longo dessa trajetória.

Ao amigo Clodoaldo, pela oportunidade de aprender e ensinar. Por compartilhar momentos de alegrias e tristezas, certezas e incertezas, angústias e ansiedades, construções e desconstruções, ilusões e desilusões, ao longo desta caminhada. Por proporcionar vivências e experiências inimagináveis, onde a superação de limites era a única maneira de continuar a caminhar. Pelo privilégio de concluir um processo e, ainda, parafrasear Fernando Pessoa: “Tudo vale a pena, se a alma não é pequena!”

A todos, todas e a cada um dos servidores, professores, colegas, amigos e amigas do IFMT, que incentivaram e colaboraram para o desenvolvimento deste trabalho e para esta conquista. Em especial ao colega Tony Inácio da Silva, pela iniciativa em propor, acreditar, fomentar, assumir e concretizar a parceria interinstitucional entre o IFMT e a Unesp, na realização do Dinter, possibilitando o aprimoramento técnico-científico para os profissionais do IFMT.

Ao IFMT e a Unesp por acreditarem na possibilidade de capacitação coletiva e se tornarem parceiros na realização do Doutorado Interinstitucional - Dinter.

À CAPES pelo apoio financeiro durante o afastamento das atividades do IFMT, para a construção e desenvolvimento da pesquisa e escrita desta tese.

À minha querida e amada, Dona Maria Monte Verde, por abrir as portas de sua casa e de seu coração, para que neles eu me instalasse e fizesse minha morada. Por cuidar de mim e de todas as minhas coisas, com carinho, dedicação, desprendimento e muito Amor. Pelas orações, pelo cuidado e preocupação comigo, com minhas filhas, meu marido e meus pais. Por permitir e me fazer sentir parte de sua Família e, até mesmo, “me adotar como filha”.

À Márcia, Mércia, Magda, Mara e Mariana, Evilar e Edmar, filhas, neta e filhos da D. Maria, por considerar e permitir minha estada junto com sua mãe e, ainda, aceitar espontânea e alegremente minha participação em seus encontros familiares. Às meninas, por estar presente na defesa da tese, por preparar e organizar a recepção para os amigos presentes.

À Maria Marli Brondani Minussi, por ressaltar as virtudes do professor Minussi, despertando em mim o interesse em tê-lo como orientador e, posteriormente, o encorajamento para procurá-lo. Por se preocupar com meu bem estar, por procurar um lugar para eu me instalar e por proporcionar meu encontro com a D. Maria, onde encontrei um Lar.

Às meninas, Izanete, Juraci, Vera, Ditinha, Beth, Maki, Leonora, Nair, D. Anita e D. Dina, amigas da D. Maria e minhas amigas, pelo apoio, carinho, cuidado e preocupações comigo e com todos da minha família. Pelos momentos de descontração e boas risadas. Pela oportunidade de vivenciar, aprender e ressignificar o sentido de viver muitos e muitos anos, colher flores em várias primaveras, ter no rosto as marcas do tempo e o cabelo como nuvens de algodão e, mesmo assim, cultivar a uma roda de amigos, ser alegre, ter entusiasmo e disposição. Por me ensinarem a Viver... Viver... e não ter a vergonha de ser feliz!

Ao Dr. Manoel Padilha, por cuidar e manter meu equilíbrio emocional, durante este período do doutorado, através das agulhinhas precisamente colocadas nos pontos de acupuntura.

À Ana Lúcia, pela simpatia, pelo cuidado e comprometimento na impressão, encadernação e gravação da versão final desta tese.

AGRADECIMENTOS

Agradeço àqueles que mesmo antes do doutorado já estavam ao meu lado e faziam parte do meu Viver.

Aos meus pais Ademar e Eunice, minha eterna gratidão pelo dom da vida. Por tudo que sou e consegui realizar. Pelo carinho, atenção, dedicação e preocupação. Por estarem sempre, incondicionalmente, prontos para ajudar; pelo estímulo e apoio desde o início, pela paciência em me ouvir e orientar.

Ao meu marido, Fernando, por assumir o cuidado de nossas filhas; por buscar atender minhas necessidades tanto materiais quanto emocionais. Pelas trocas de impressões, comentários e correções, fazendo às vezes o papel de revisor. Acima de tudo, pelo inestimável apoio, paciência, carinho, cuidado, compreensão e disponibilidade em todos os momentos deste processo, atitudes fundamentais na realização do trabalho e, principalmente, por seu amor demonstrado nessa e em toda nossa caminhada.

Às minhas lindas e maravilhosas filhas, Marina e Júlia, por assumir papéis e responsabilidades além de suas idades, para que eu pudesse me dedicar ao desenvolvimento da pesquisa e construção da tese. Pela paciência, compreensão e respeito que tiveram quando na maioria das vezes estive ausente e por reconhecerem e aceitarem que a condição para minha presença era por meio virtual, isto aliado ao carinho e ao desejo de ter-me com elas, porém sabendo deixar e esperar. Por suportar a distância, a ausência, a saudade, a tristeza, o vazio e os medos, readaptando a uma nova maneira, se desdobrando e encontrando forças para superar as situações que se apresentaram. Com Marina aprendi e aprendo a percepção do outro, que é captada pelo olhar, sem dizer uma só palavra; Júlia me ensina a perspicácia, com senso aguçado de observação, raciocínio rápido e sutileza de argumentação. Elas me enchem de orgulho e me fazem muito feliz! São minhas joias raras e verdadeiras heroínas.

À minha linda e querida avó, Aparecida, pelo apoio espiritual, orações e intercessões constantes.

Aos meus irmãos, Diógenes e Leandro, e minha irmã, Liliana, pela torcida, pelas palavras de incentivo e apoio incondicional ao longo desta caminhada; por estarem longe dos olhos e saberem fazer-se presentes e sempre pertos do coração. Em especial a Liliana e ao Gerardo que estiveram presentes na defesa da tese, me enchendo de alegria.

À médica e amiga, Otília Teófilo, que com doses homeopáticas de atenção, compreensão, segurança, otimismo, energia, me ajudou nos momentos de angústia e incerteza.

À *My Dear* professora e amiga, Odila Watzel, pelo incentivo, otimismo e alegria em cada *wordizinha* encaminhada a mim, por se desdobrar para me ajudar e atender minhas necessidade com tantos textos e artigos de úuuuuuuultima hora, por todas as mensagens enviadas e, acima de tudo, pela constante força que sempre me dizia... é isso aí... “Fé em Deus e pé na tábua!”

À amiga Silvia Maria dos Santos Sterling, pela oportunidade do diálogo, reflexão, construção e reconstrução de ideias pertinentes a esta tese e, também, ao cotidiano da vida. Pela Força e incentivo constante. Pela leitura do texto da tese, por participar da construção e ensaios da apresentação. Pelo desprendimento, pelo exemplo da força de uma amizade e pela presença na defesa da tese. Pelo primor e carinho com que, juntamente com a Mércia, preparou e organizou todos os detalhes em torno da defesa.

Aos Amigos e Familiares - tios, tias, primos, primas, cunhadas e cunhados - pela preocupação, apoio e incentivo constantes.

Durante essa caminhada e todo processo de construção do trabalho, percebia que tudo conspirava a favor de sua concretude, pois sempre encontrei pessoas dispostas a ajudar, muitas incentivando, apoiando e colaborando, tornando possível a realização desta conquista.

Assim, quero exprimir com muito carinho e alegria meu Muito Obrigada, meus sinceros agradecimentos a todos, todas e a cada um que encontrei e, direta ou indiretamente, contribuíram e incentivaram a construção desta tese.

Reverência ao destino

Falar é completamente fácil, quando se tem palavras em mente que expressem sua opinião.

Difícil é expressar por gestos e atitudes o que realmente queremos dizer...

Fácil é julgar pessoas que estão sendo expostas pelas circunstâncias.

Difícil é encontrar e refletir sobre os seus erros...

Fácil é ser colega, fazer companhia a alguém, dizer o que ele deseja ouvir.

Difícil é ser amigo para todas as horas e dizer sempre a verdade quando for preciso...

Fácil é analisar a situação alheia e poder aconselhar sobre esta situação.

Difícil é vivenciar esta situação e saber o que fazer ou ter coragem pra fazer...

Fácil é demonstrar raiva e impaciência quando algo o deixa irritado.

Difícil é expressar o seu amor a alguém que realmente te conhece...

Fácil é mentir aos quatro ventos o que tentamos camuflar.

Difícil é mentir para o nosso coração...

Fácil é ver o que queremos enxergar.

Difícil é saber que nos iludimos com o que achávamos ter visto...

Fácil é perguntar o que deseja saber.

Difícil é estar preparado para escutar esta resposta ou querer entender a resposta...

Fácil é chorar ou sorrir quando der vontade.

Difícil é sorrir com vontade de chorar ou chorar de rir, de alegria...

Fácil é ditar regras.

Difícil é segui-las...

Fácil é sonhar todas as noites.

Difícil é lutar por um sonho...

Carlos Drummond de Andrade

RESUMO

A evasão escolar é um dos problemas mais complexos e cruciais no âmbito da educação. Está presente e é motivo de preocupação nos vários níveis e modalidades de ensino, além de ferir o princípio da dignidade humana. No que tange ao ensino superior, internacionalmente, o fenômeno é objeto de atenção e de cuidado, no intuito de aumentar os índices de permanência e conclusão dos estudantes de graduação e minimizar os prejuízos sociais, econômicos, políticos, acadêmicos e financeiros causados a todos os envolvidos no processo educacional. Nesse contexto, é imprescindível o desenvolvimento de métodos e instrumentos eficientes e eficazes para predição, avaliação e acompanhamento de estudantes em risco de evasão, possibilitando o planejamento e a adoção de medidas proativas no intuito de minimizar a situação. Assim sendo, esta pesquisa tem por objetivo apresentar as potencialidades de um sistema inteligente capaz de identificar, de maneira proativa, continuada e acurada, o grupo de risco de evasão discente, da educação clássica-presencial, no ensino de nível superior. No desenvolvimento deste sistema foi utilizada uma das técnicas da inteligência artificial, as Redes Neurais Artificiais, mais especificamente, a Rede Neural ARTMAP-Fuzzy, uma rede neural da família ART (*Adaptive Resonance Theory*) que possibilita o aprendizado continuado do sistema. Para o treinamento e teste da Rede Neural e, posteriormente, a validação do sistema proposto foram utilizados os dados socioeconômicos e acadêmicos dos estudantes matriculados nos cursos superiores de tecnologia do Instituto Federal de Mato Grosso - IFMT. Os dados que compuseram os vetores de entrada do sistema foram coletados a partir de dois bancos de dados do sistema de informação do IFMT, respectivamente, o Q-seleção e o Q-Acadêmico. Este sistema faz a classificação dos padrões de entrada em propensos ou não propensos à evasão escolar. A consistência dos resultados, com índice de acerto do grupo evasivo atingindo entre 95% e 100% e acurácia global média em torno de 95%, demonstra a fidedignidade, a confiabilidade, a precisão, a robustez e a eficiência do sistema neural ARTMAP-Fuzzy proposto, ao fazer a predição do grupo de estudantes propensos à evasão. Constitui-se uma experiência instituinte permeada pela prática da alteridade, possibilitando a adoção de medidas e ações individualizadas a fim de atender às

necessidades de cada estudante e contribuir para superação de dificuldades e permanência na instituição. Sendo, dessa forma, útil para a sociedade, haja vista que, com uma ação proativa, conseguir com que um estudante, com potencial de evadir, tenha sucesso é, na prática, uma missão nobre, pois são sonhos que se realizam e, ao mesmo tempo, contribui-se para elevar o nível educacional do país. Além do que, esse sistema se insere na lacuna existente nas produções da comunidade científica mundial, no que tange ao tema em questão. Ressalta-se, ainda, que a inovação, a pujança e a audácia desta pesquisa encontram-se na possibilidade de identificar precocemente, ainda no primeiro semestre do curso, o grupo de estudantes em risco iminente de evasão utilizando, basicamente, os dados da inscrição do candidato.

Palavras-chave – Redes neurais artificiais. Teoria da ressonância adaptativa. Rede neural ARTMAP-*Fuzzy*. Sistema inteligente. Predição da evasão escolar. Educação superior. Proatividade.

ABSTRACT

School dropout is one of the most complex and crucial problems in the field of education. It permeates and afflicts the several levels and teaching modalities, besides hurting the principle of human dignity. In relation to higher education, internationally, the phenomenon is an object of attention and care, aiming to increase the indexes of permanence and completion rate of the undergraduate students and minimize social, economic, political and financial damage caused to all involved in the educational process. In this context, it is fundamental to develop efficient and effective methods and instruments for prediction, assessment and monitoring of the students at risk of dropping out, making the planning and the adoption of proactive actions possible for the improvement of the situation. Thus, this study aims to present the potentialities of an intelligent system able to identify, in a proactive, continued and accurate way, the student dropout risk group in higher education classroom courses. In the development of this system one of the artificial intelligence techniques was used, the Artificial Neural Networks, more specifically, the Fuzzy-ARTMAP Neural network, a neural network of the ART (*Adaptive Resonance Theory*) family which makes the continued learning of the system possible. For the training and test of the Neural Network and, later, the validation of the system proposed the socio-economic and academic records of the students enrolled in the technology courses of the Federal Institute of Mato Grosso – IFMT were used. The data that constituted the input vectors of the system were extracted from two database of the IFMT information system, respectively, the Q-selection and the Q-Academic. This system classifies the input patterns in school dropout propensity. The consistence of the results, showing a success rate of the dropout group around 95% and 100% and the overall mean accuracy around 95%, shows the reliability, validity, accuracy and efficiency of the Fuzzy-ARTMAP-*Fuzzy* neural system proposed, when making the prediction of the group of students more likely to dropout. It is an instituting experience permeated by the practice of alterity, allowing adoption of measures and individualized actions to meet the needs of each student and help them to overcome difficulties and remain in the institution, thus, being useful to society. Given that, with a proactive action, to make a student with potential to evade, be

successful is a noble mission, because they are dreams come true. In addition, this system fills the existing gap in the productions of the world scientific community, in relation to the issue under discussion. It is also noteworthy that innovation, the strength and the boldness of this research lie in the ability to identify ahead of time, in the first semester of the course, the group of students at eminent risk of dropping out basically, from the candidate's enrollment data.

Keywords – Artificial neural networks. Adaptive resonance theory. Fuzzy-ARTMAP neural network. Intelligent system. Dropout prediction. Higher education. Proactivity.

LISTA DE FIGURAS

Figura 1	- Gráfico do índice estimado da evasão nas IES públicas e privadas do Brasil (%) de 2000 a 2012.	34
Figura 2	- Fluxograma do sistema neural proposto capaz de realizar a predição do grupo de risco da evasão discente.	42
Figura 3	- Fases do processo de desenvolvimento da pesquisa.	46
Figura 4	- Quantidade de estudantes matriculados no IFMT – Câmpus Cuiabá por exame de seleção e por Departamento - no período de 2009/1 e 2010/2.	50
Figura 5	- Planilha do Microsoft Office Excel com os dados brutos dos candidatos aprovados no exame de seleção 2009/1 exportados do Q-Seleção.	52
Figura 6	- Planilha do Microsoft Office Excel com os dados dos estudantes no final do 1º semestre de 2009 - 2009/1 - exportados do Q-Acadêmico. ..	53
Figura 7	- Parte do banco de dados com os parâmetros dos vetores de entrada e saída da rede.	54
Figura 8	- Representação dos treinamentos e algoritmos de aprendizagem das redes neurais.	71
Figura 9	- Classificação das redes da família ART quanto à aprendizagem.	76
Figura 10	- Estrutura básica da rede neural ART.	77
Figura 11	- Estrutura da rede neural ART- <i>Fuzzy</i>	80
Figura 12	- Fluxograma da rede neural ART- <i>Fuzzy</i>	80
Figura 13	- Arquitetura da Rede Neural ARTMAP- <i>Fuzzy</i>	88
Figura 14	- Fluxograma da rede neural ARTMAP- <i>Fuzzy</i>	93
Figura 15	- Esquema geral da aplicação do sistema de predição da evasão escolar discente usando uma rede neural ARTMAP- <i>Fuzzy</i>	96

Figura 16	- Exemplo do processo de categorização.	97
Figura 17	- Amostra do resultado do processo de codificação decimal-binário dos atributos dos subvetores do vetor de entrada (<i>a</i>) do módulo ART _a	99
Figura 18	- Exemplo da composição dos vetores de entrada e saída desejada da rede neural ARTMAP- <i>Fuzzy</i> para aplicação ao problema da evasão discente.	100
Figura 19	- Número de estudantes matriculados e evadidos no CST de Automação e Controle do IFMT - 2004 a 2011.	104
Figura 20	- Resultados quantitativos e em percentuais do diagnóstico da evasão total no período de 2004 a 2010.	112
Figura 21	- Resultados quantitativos e em percentuais do diagnóstico da evasão total no período de 2004 a 2011.	115
Figura 22	- Resultados quantitativos e em percentuais do diagnóstico da evasão no ano letivo de 2011 - com o treinamento T-I.	118
Figura 23	- Resultados quantitativos e em percentuais do diagnóstico da evasão no ano letivo de 2011 - com o treinamento T-II.	120

LISTA DE TABELAS

Tabela 1	- Número total de Ingressos, Matrículas e Concluintes em cursos superiores presenciais, em instituições públicas e privadas no Brasil e estimativa dos índices de evasão de 2000 a 2012.	32
Tabela 2	- Cursos, níveis e modalidades de ensino no IFMT - Câmpus Cuiabá.	48
Tabela 3	- Cursos distribuídos nos Departamentos de Área (DA) e Pós-Graduação (DPPG).	49
Tabela 4	- Composição dos vetores de entrada e saída do sistema neural ARTMAP- <i>Fuzzy</i>	55
Tabela 5	- Síntese dos modelos da evasão escolar.	64
Tabela 6	- Comparação entre as redes ART 1 e ART- <i>Fuzzy</i>	80
Tabela 7	- Exemplo da conversão categoria decimal- padrão binário dos atributos do vetor de entrada da rede neural.	98
Tabela 8	- Números da evasão no CST em Automação e Controle do IFMT 2004 a 2011.	104
Tabela 9	- Composição dos conjuntos de treinamento da rede neural ARTMAP- <i>Fuzzy</i> e diagnóstico da evasão.	105
Tabela 10	- Valores dos parâmetros para o treinamento da rede neural ARTMAP- <i>Fuzzy</i>	107
Tabela 11	- Resultados quantitativos e em percentuais do diagnóstico da evasão total no período de 2004 a 2010.	111
Tabela 12	- Resultados quantitativos e em percentuais do diagnóstico da evasão no 1º ano do curso - acumulada no período de 2004 a 2010.	113
Tabela 13	- Resultados quantitativos e em percentuais do diagnóstico da evasão total no período de 2004 a 2011.	114

Tabela 14 - Resultados quantitativos e em percentuais do diagnóstico da evasão no 1º ano do curso - acumulada no período de 2004 a 2011.	115
Tabela 15 - Resultados quantitativos e em percentuais do diagnóstico da evasão no 1º semestre do curso - acumulada no período de 2004 a 2011.	116
Tabela 16 - Resultados quantitativos e em percentuais do diagnóstico da evasão no ano letivo de 2011 - com o treinamento T-I.	117
Tabela 17 - Resultados quantitativos e em percentuais do diagnóstico da evasão no ano letivo de 2011 - com o treinamento T-II.	119
Tabela 18 - Índices de desempenho do sistema neural ARTMAP- <i>Fuzzy</i>	121
Tabela 19 - Características e resultados - métodos preditivos da evasão escolar.	123

SIGLAS

AI	- Automação Industrial
ART	- <i>Adaptive Resonance Theory</i>
ARTMAP	- <i>Adaptive Resonance Theory Map</i>
Bit	- <i>Binary Digit</i>
CES	- Câmara de Educação Superior
CNE	- Conselho Nacional de Educação
CST	- Curso Superior de Tecnologia
DA	- Departamento de Área
DACC	- Departamento da Área de Construção Civil
DAEE	- Departamento da Área de Eletroeletrônica
DAI	- Departamento da Área de Informática
DAS	- Departamento da Área de Serviços
DE	- Departamento de Ensino
DEED	- Diretoria de Estatísticas Educacionais
DPPG	- Departamento de Pesquisa e Pós-Graduação
EUA	- Estados Unidos da América
FIES	- Fundo de Financiamento ao Estudante do Ensino Superior
GIS	- <i>Geographic Information Systems</i>
GPA	- <i>Grade Point Average</i>
IA	- Inteligência Artificial
IE's	- Instituições de Ensino
IES	- Instituição de Ensino Superior

IF	- Instituto Federal
IF's	- Institutos Federais
IFE	- Instituto Federal de Educação
IFES	- Instituições Federais de Ensino Superior
IFMT	- Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso.
INEP	- Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira
LTM	- <i>Long-Term Memory</i>
MEC	- Ministério da Educação
MLP	- <i>Multilayer Perceptron</i>
PCE/CREDU	- Programa de Crédito Educativo
PROUNI	- Programa Universidade para Todos
REUNI	- Programa de Apoio a Planos de Reestruturação e Expansão das Universidades Federais
RN	- Redes Neurais
RNA	- Rede Neural Artificial
RNA's	- Redes Neurais Artificiais
SESu	- Secretaria de Educação Superior
SETEC	- Secretaria de Educação Profissional e Tecnológica
SI	- Sistema Inteligente
SINTEL	- Grupo de Pesquisa e Laboratório de Sistemas Inteligentes
STM	- <i>Short-Term Memory</i>
SVM	- <i>Support Vector Machine</i>
SRV	- <i>Support Vector Regression</i>
TAMEC	- Termo de Acordo de Metas e Compromissos
UNESCO	- Organização das Nações Unidas para a Educação, Ciência e Cultura
UNESP	- Universidade Estadual Paulista

SUMÁRIO

INTRODUÇÃO	26	
CAPÍTULO 1 - SOBRE A PESQUISA		
1.1	CONTEXTUALIZAÇÃO	29
1.2	JUSTIFICATIVA	35
1.3	O PROBLEMA E A PROPOSTA DE SOLUÇÃO	38
1.4	OS OBJETIVOS	40
1.5	DO OBJETO DA PESQUISA - O SISTEMA INTELIGENTE	40
1.6	METODOLOGIA	45
1.6.1	Caracterização e Processo de Desenvolvimento	45
1.6.2	Âmbito e Universo da Pesquisa	48
1.6.3	A Coleta de Dados	51
1.6.4	A Análise dos Resultados	55
1.7	REFERENCIAL TEÓRICO	56
CAPÍTULO 2 - REVISÃO BIBLIOGRÁFICA		
2.1	EVASÃO ESCOLAR NO ENSINO SUPERIOR BRASILEIRO	58
2.2	MÉTODOS PROPOSTOS PARA PREDIÇÃO DA EVASÃO ESCOLAR	61
2.3	SÍNTESE DOS MODELOS DA EVASÃO ESCOLAR	64
CAPÍTULO 3 - REDES NEURAIAS ARTIFICIAIS		
3.1	REDES NEURAIAS ARTIFICIAIS	67
3.2	TEORIA DA RESSONÂNCIA ADAPTATIVA (ART)	73
3.2.1	Rede Neural ART Básica	76
3.2.2	Rede Neural ART-Fuzzy	79
3.2.2.1	Algoritmo da Rede Neural ART-Fuzzy	81
3.2.3	Rede Neural ARTMAP-Fuzzy	87

3.2.3.1	Algoritmo da Rede Neural ARTMAP-Fuzzy.	89
---------	---	----

CAPÍTULO 4 - IMPLEMENTAÇÃO DO SISTEMA ARTMAP-FUZZY PARA PREDIÇÃO DA EVASÃO ESCOLAR

4.1	CONSTRUÇÃO DA BASE DE DADOS	95
4.2	MODELAGEM DA REDE NEURAL ARTMAP-FUZZY APLICADA AO PROBLEMA DA EVASÃO	100
4.3	APLICAÇÃO DO SISTEMA NEURAL ARTMAP-FUZZY PARA O DIAGNÓSTICO DA EVASÃO	102

CAPÍTULO 5 - AVALIAÇÃO DE DESEMPENHO DA REDE NEURAL ARTMAP-FUZZY E ANÁLISE COMPREENSIVA DOS RESULTADOS

5.1	CRITÉRIOS PARA AVALIAÇÃO DE DESEMPENHO	108
5.1.1	Acurácia Global (A_g)	109
5.1.2	Sensibilidade (S)	109
5.1.3	Precisão (P)	110
5.2	RESULTADOS EXPERIMENTAIS	110
5.2.1	Resultados dos Diagnósticos (D) Realizados após o Treinamento T-I	111
5.2.2	Resultado do Diagnóstico D-VII Realizado após o Treinamento T-II	118
5.3	AVALIAÇÃO DO DESEMPENHO DO SISTEMA NEURAL ARTMAP-FUZZY PROPOSTO	120
5.4	ANÁLISE COMPARATIVA COM RESULTADOS DA LITERATURA	122

CAPÍTULO 6 - CONSIDERAÇÕES FINAIS

6.1	CONCLUSÃO	126
6.2	SUGESTÕES PARA TRABALHOS FUTUROS	128

REFERÊNCIAS	130
-------------	-------	-----

APÊNDICES

APÊNDICE A	- CODIFICAÇÃO DECIMAL-BINÁRIA DOS ATRIBUTOS UTILIZADOS NOS PADRÕES DE ENTRADA DA REDE NEURAL ARTMAP-FUZZY	137
APÊNDICE B	- ARTIGOS PUBLICADOS DURANTE O DESENVOLVIMENTO DA PESQUISA	141

ANEXOS

ANEXO A - AUTORIZAÇÃO DO IFMT PARA UTILIZAÇÃO DOS BANCOS DE DADOS Q-ACADÊMICO E Q-SELEÇÃO 144

O homem pretende ser imortal
e para isso defende princípios efêmeros
Um dia, inexoravelmente, descobrirá
que para ser imortal deverá defender Princípios Absolutos.
Nesse dia, morrerá para a carne, efêmera,
e viverá para o Espírito, Eterno
Será Imortal.

Dr. Celso Charuri

INTRODUÇÃO

*Faça as coisas o mais simples que puder,
porém não se restrinja às mais simples.*

Albert Einstein

Namastê¹!

Pode parecer estranho iniciar uma pesquisa que se insere no contexto da Engenharia com uma saudação em sânscrito, mas acredite, não o é. Ela vem ao encontro e sela o processo de construção, desenvolvimento, análise e resultado de uma pesquisa sobre a aplicação de Redes Neurais Artificiais (RNA) para a predição do grupo de risco de evasão discente. Isso porque, a implementação deste estudo, concretamente, no cotidiano escolar, constitui-se em uma experiência instituinte permeada pela prática da alteridade.

Nesta pesquisa, a engenharia na sua forma mais pura e primitiva, ou seja, do engenho², da capacidade de desenvolvimento, construção e transformação, se coloca a serviço da Educação, construindo oportunidades que propiciam a dignidade e possibilitam o desenvolvimento e a transformação da condição de vida dos cidadãos.

No âmbito da educação, a evasão escolar é um dos fenômenos mais complexos e cruciais, caracterizado pela interrupção no ciclo de estudo. Advém de uma série de determinantes e características multivariadas e inter-relacionadas. Gera prejuízos a todos os segmentos envolvidos e fere o princípio da dignidade humana. Sanar esse problema é contribuir para a construção do ser cidadão em sua plenitude.

Com essa missão, um sistema inteligente, utilizando redes neurais artificiais, foi concebido, treinado, testado e validado para identificar, de maneira proativa, grupos de risco

¹ Namastê - é uma saudação hindu, de origem sânscrita, que corresponde ao nosso olá. Inclinar-se juntando as mãos significa: "O Deus que habita em mim saúda o Deus que habita em você." "O Espírito em mim reconhece o mesmo Espírito em você."

² Capacidade de criar, realizar, produzir com arte, habilidade, sensibilidade; engenhosidade, criatividade, inventiva, talento. *Dicionário Houaiss da Língua Portuguesa*, Lisboa: Círculo de Leitores, 2002.

de evasão discente, em cursos superiores presenciais.

O percurso da pesquisa que respalda e consolida o desenvolvimento e aplicação do sistema inteligente proposto está estruturado da seguinte maneira:

No Capítulo 1, encontra-se o delineamento da pesquisa em sua totalidade, evidenciando suas particularidades, com uma breve contextualização do fenômeno da evasão, a justificativa da pesquisa, o problema e a proposta de solução, os objetivos, o objeto e a metodologia da pesquisa, além de uma síntese do referencial teórico.

Tem-se, no segundo Capítulo, o objetivo de descrever os resultados da pesquisa bibliográfica quanto aos métodos preditivos capazes de identificar estudantes em risco de evasão no ensino superior e, também, expor modelos e teorias sobre a evasão escolar discente.

No Capítulo 3 tratar-se-á, de maneira genérica, das redes neurais artificiais. Seu conceito, características, arquiteturas, tipos de treinamento, vantagens e aplicações serão sucintamente descritos. Em seguida, de maneira mais detalhada, a Teoria da Ressonância Adaptativa (*Adaptive Resonance Theory - ART*) e as arquiteturas de rede da família ART serão abordadas.

Tendo em vista que o objetivo desta pesquisa é o desenvolvimento de um sistema neural inteligente para o diagnóstico preditivo da evasão discente, encontra-se no Capítulo 4 uma descrição da implementação desse sistema, que foi desenvolvido utilizando uma rede neural ARTMAP-*Fuzzy*. Serão consideradas as etapas da extração das características dos estudantes, construção da base de dados, formulação do problema da evasão, treinamento da rede neural e o diagnóstico da evasão através da rede.

O Capítulo 5 traz, em um primeiro momento, os resultados obtidos com a aplicação do sistema neural ARTMAP-*Fuzzy* para o diagnóstico preditivo da evasão escolar, bem como, a análise compreensiva desses resultados e uma avaliação de desempenho da rede utilizada. Em um segundo momento, traz em seu bojo a análise comparativa dos resultados obtidos nesta pesquisa com resultados de outras pesquisas. Essa análise é alicerçada nos dados coletados na literatura que iluminaram o processo da análise.

Nas Considerações Finais, Capítulo 6, expõe-se as conclusões e as contribuições desta pesquisa e as sugestões para trabalhos futuros.

Trilhando esse caminho, espera-se que as contribuições advindas desta investigação sejam úteis às instituições de ensino para que possam, efetivamente, mitigar o fenômeno da

evasão escolar.

Ressaltam-se, antecipadamente e de forma concisa, que a originalidade e contribuição desta tese residem na possibilidade de identificar de maneira precoce (ainda no primeiro semestre do curso), proativa, continuada e acurada os estudantes propensos à evasão no ensino de nível superior no Brasil, utilizando, basicamente, os dados da inscrição do candidato, processados por um sistema inteligente que emprega a Rede Neural ARTMAP-*Fuzzy*. Além do que, a aplicabilidade desta pesquisa constitui-se em uma experiência instituinte permeada pela prática da alteridade.

SOBRE A PESQUISA

*Que o teu orgulho e objetivo consistam em
pôr no teu trabalho algo que se assemelhe a
um milagre.*

Leonardo da Vinci

Neste capítulo, a pesquisa será delineada, em sua totalidade, evidenciando suas particularidades, com uma breve contextualização do fenômeno da evasão, a justificativa da pesquisa, o problema e a proposta de solução, os objetivos, o objeto e a metodologia da pesquisa, além de uma síntese do referencial teórico.

1.1 CONTEXTUALIZAÇÃO

Historicamente, e de maneira pragmática, a Educação é concebida como instrumento de transformação e mudança da sociedade. Porém, dicotomicamente a essa ideia, percebe-se que ela sozinha não conseguiria tal intento e poderia até suscitar exclusão e estagnação. Nesse sentido, a educação será tão mais plena, quanto mais esteja sendo um ato de conhecimento, um ato político, um compromisso ético e uma experiência estética (1)³.

A educação, deste mundo moderno em que vivemos, demanda uma busca constante de novos conhecimentos, haja vista que o rumo e a velocidade das transformações exigem cada vez mais, de todos os homens, uma constante reciclagem de conhecimentos e uma contínua readaptação a um mundo que, afinal, ainda é sempre o mesmo e já é sempre um outro (2). E, portanto, em qualquer projeção que se faça do e para futuro, o conhecimento tem presença garantida. Por isso, há um consenso de que o desenvolvimento de um país está condicionado à qualidade da sua Educação (3).

³ Neste texto será adotado o sistema numérico para a chamada das referências, ou seja, para a indicação da fonte consultada. As fontes consultadas ou citações terão numeração única e consecutiva, em algarismos arábicos, localizada ao lado da citação e entre parênteses. Esta opção segue as orientações da biblioteca da Unesp na preparação dos trabalhos acadêmicos, de acordo com as normas vigentes da ABNT - 10520/2002 e 6023/2002, quanto às Citações e Referências, respectivamente.

Entretanto, 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, desde o estudante até os órgãos governamentais e de fomento. É um problema complexo e crucial (4), advindo da superposição de fatores endógenos e exógenos da instituição de ensino e, também, de variáveis demográficas e atributos individuais que influenciam na decisão do estudante de permanecer ou abandonar a escola.

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 da América - EUA, com taxa de evasão nas faculdades e universidades em torno de 40%, representando um declínio no índice de estudantes graduados no ensino superior (5). Enquanto que a China e a Índia estão formando, por ano, mais de um milhão de licenciados nas áreas de ciência básica, ciência de computadores e engenharia, e esses países estão oferecendo bons empregos para estes cidadãos bem treinados (6). Percebe-se, portanto, que a China e a Índia potencializam o ensino superior nestas áreas, aumentando o índice de conclusão. Entre estes extremos situa-se o Brasil, apresentando um índice médio de evasão em torno de 20% (7, 8).

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 (9).

Frente a essa situação, nos últimos anos, no Brasil, foram realizados monitoramentos, estudos empíricos, pesquisas científicas e levantamentos estatísticos sobre a evasão, com vistas à adoção de medidas capazes de solucionar ou reduzir os altos índices desse fenômeno e, assim, evitar as perdas tanto sociais e acadêmicas, quanto financeiras.

As contribuições e ações resultantes desses processos podem ser identificadas sob três paradigmas: 1- contribuições teóricas, que visam compreender e identificar os fatores que contribuem e influenciam no fenômeno e no processo da evasão; 2- ações específicas de cada instituição de ensino superior (IES), centrada em sua realidade e especificidade; e, 3- formulação de políticas públicas, implementadas por meio de ações governamentais, com foco nas instituições de ensino (IE's), como o Programa REUNI - Reestruturação e Expansão

das Universidades Federais (10) e o Termo de Acordo de Metas e Compromissos (11) estabelecidos, respectivamente, com as instituições federais de ensino superior (IFES) e os institutos federais (IF's). Outras ações são destinadas diretamente aos estudantes de baixa renda e possibilitam o financiamento da graduação no ensino superior, tais como o Programa de Crédito Educativo (PCE/CREDOC), o Fundo de Financiamento ao Estudante do Ensino Superior (FIES) e o Programa Universidade para Todos - PROUNI (12).

As ações governamentais destinadas às instituições federais de ensino se propõem a assegurar a viabilização de mais recursos para tais ações, mediante o cumprimento das metas preestabelecidas na implantação do REUNI e do Termo de Acordo de Metas e Compromissos.

Mas, os estudos sobre evasão existentes no Brasil são academicamente limitados às experiências individuais, de uma IES ou de um docente. Portanto, ainda são incipientes e tímidos, se comparados com os países desenvolvidos em que os estudos e pesquisas sistematizados são inúmeros. Nos EUA, mais de 14 mil *sites* tratam da questão (13). No entanto, os dados sobre evasão nos cursos superiores do Brasil não diferem muito das médias internacionais. Variam bastante por dependência administrativa (pública ou privada), região e curso (14).

Nos EUA, estudos acadêmicos e pesquisas científicas sobre a evasão e retenção de estudantes do ensino superior, iniciaram nos anos 30, de maneira despreziosa e limitada. Nos anos 60, em decorrência da conjuntura sócio-político-cultural-econômica em que vivia as IES, houve um crescimento significativo nos índices de evasão. A preocupação com a situação, a complexidade do fenômeno e a necessidade de encontrar soluções, intensificaram as pesquisas e o desenvolvimento de medidas para minimizar a evasão (15).

O termo retenção é largamente utilizado na literatura internacional para designar o conjunto de medidas destinadas a viabilizar a manutenção do estudante na instituição, tanto financeira como academicamente, para que não ocorra a evasão. Preferencialmente, fala-se em retenção em vez de evasão, por ser um termo mais objetivo e proativo (16). Países como a Austrália e os Estados Unidos têm abordado o tema de maneira científica e, por considerá-lo de alta relevância, criaram gerências ou diretorias para a gestão da retenção. Cabe à gerência de retenção de estudantes, juntamente com os professores, auxiliares educacionais e administradores, arquitetar, desenvolver e implementar novos programas e adaptar ações/cursos/serviços de apoio para incrementar o número de alunos que retornam à Universidade, a cada ano, para completarem os seus cursos e se formarem (16).

Nesta pesquisa, para a coleta dos dados e, posteriormente, para a análise compreensiva dos resultados, utilizou-se o termo evasão, considerada como a saída definitiva do estudante de seu curso de origem sem concluí-lo, conforme o relatório da Comissão Especial de Estudos sobre a Evasão nas Universidades Públicas Brasileiras (17).

No Brasil, a educação superior passa por uma avaliação, mediante o resultado do Censo da Educação Superior, realizado anualmente pelo Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (18). O Censo se constitui em um relevante instrumento para a obtenção de dados e geração de informações que subsidiam a formulação, o monitoramento e a avaliação das políticas públicas, bem como os estudos acadêmicos, pesquisas científicas e a gestão das instituições de ensino.

Considerando os dados dos Censos da Educação Superior de 2000 a 2012, compilados na Tabela 1, foi possível estimar os índices de evasão anual, naquele período, no Brasil. Os dados utilizados para a estimativa da evasão no ensino superior são: número total de estudantes que ingressaram em cursos superiores presenciais, em instituições de ensino públicas e privadas, número total de matrículas e número de estudantes que concluíram o curso (19).

Tabela 1 - Número total de Ingressos, Matrículas e Concluintes em cursos superiores presenciais, em instituições públicas e privadas no Brasil e estimativa dos índices de evasão de 2000 a 2012.

Ano	Categoria Administrativa	Matrículas	Ingressos	Concluintes	Índice de Evasão (%)	Ano
2000	Total	2.694.245	897.557	352.305	18,9	2000
	Pública	887.026	233.083	116.641	13,0	
	Privada	1.807.219	664.474	235.664	22,1	
2001	Total	3.030.754	1.036.690	395.988	14,85	2001
	Pública	939.225	244.621	132.616	9,84	
	Privada	2.091.529	792.069	263.372	17,31	
2002	Total	3.479.913	1.411.208	466.260	21,48	2002
	Pública	1.051.655	320.354	151.101	9,34	
	Privada	2.428.258	1.090.854	315.159	26,84	
2003	Total	3.887.022	1.540.431	528.223	22,13	2003
	Pública	1.136.370	321.689	169.159	9,54	
	Privada	2.750.652	1.218.742	359.064	27,50	
2004	Total	4.163.733	1.621.408	626.617	24,31	2004
	Pública	1.178.328	357.979	202.262	15,18	
	Privada	2.985.405	1.263.429	424.355	28,00	

Ano	Categoria Administrativa	Matrículas	Ingressos	Concluintes	Índice de Evasão (%)	Ano
2005	Total	4.453.156	1.678.088	717.858	21,54	2005
	Pública	1.192.189	331.365	195.554	11,81	
	Privada	3.260.967	1.346.723	522.304	25,26	
2006	Total	4.676.646	1.753.068	736.829	21,73	2006
	Pública	1.209.304	335.767	183.085	12,35	
	Privada	3.467.342	1.417.301	553.744	25,14	
2007	Total	4.880.381	1.808.970	756.799	22,04	2007
	Pública	1.240.968	336.223	193.531	11,84	
	Privada	3.639.413	1.472.747	563.268	25,64	
2008	Total	5.080.056	1.873.806	800.318	22,25	2008
	Pública	1.273.965	352.615	187.758	12,04	
	Privada	3.806.091	1.521.191	612.560	25,72	
2009	Total	5.115.896	1.732.613	826.928	20,95	2009
	Pública	1.351.168	379.134	187.804	10,51	
	Privada	3.764.728	1.353.479	639.124	24,50	
2010	Total	5.449.120	1.801.901	829.286	14,96	2010
	Pública	1.461.696	435.710	178.407	11,81	
	Privada	3.987.424	1.366.191	650.879	16,14	
2011	Total	5.746.762	1.915.098	865.161	17,06	2011
	Pública	1.595.391	456.635	194.666	11,26	
	Privada	4.151.371	1.458.463	670.495	19,29	
2012	Total	5.923.838	2.204.456	876.091	23,81	2012
	Pública	1.715.752	499.370	202.394	13,16	
	Privada	4.208.086	1.705.086	673.697	28,09	

Fonte: Tabela elaborada pela autora com dados dos Censos da Educação Superior 2002-2012 – Mec/Inep/Deed.

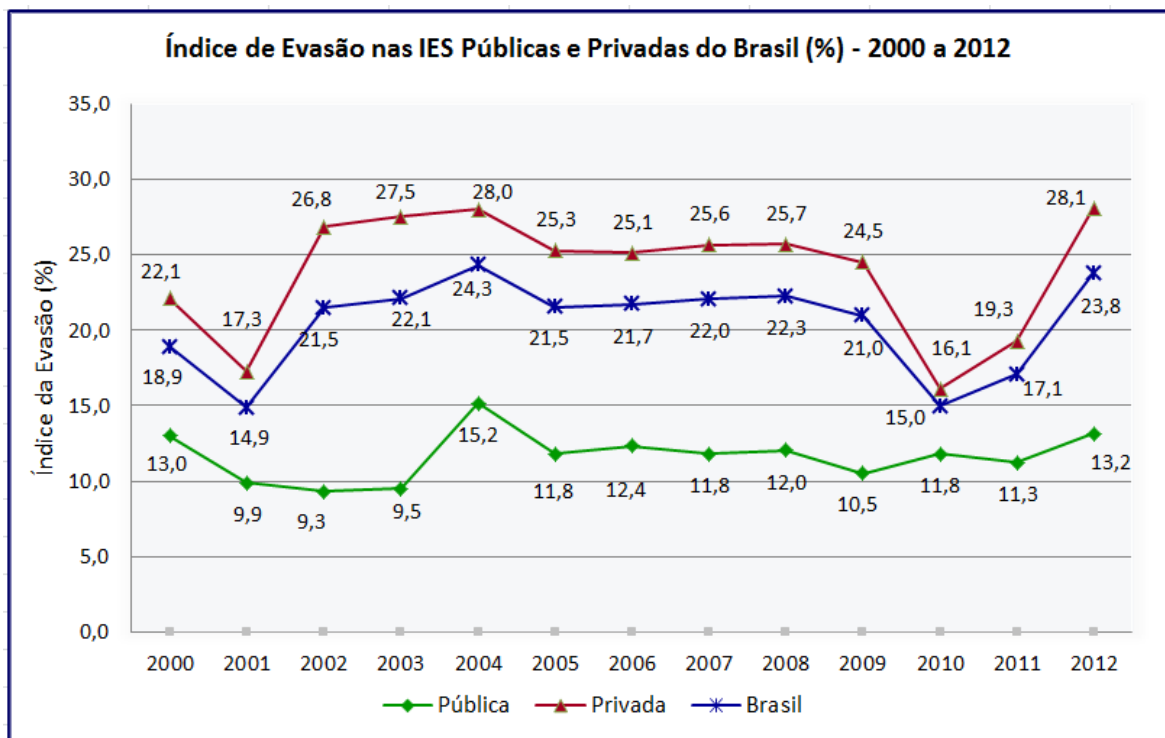
Os resultados das avaliações com relação à evasão, nas instituições de ensino superior (IES) no Brasil, são alarmantes, com índices muito superiores aos constatados pela Organização das Nações Unidas para a Educação, a Ciência e a Cultura (UNESCO) para a educação básica (20). Na Figura 1 são mostrados os índices estimados da evasão no ensino superior, no período de 2000-2012.

Observando-se os índices plotados na Figura 1, pode-se perceber que a evasão nas instituições privadas cresce ao longo do tempo em relação às instituições públicas, demonstrando ser esta perspectiva uma tendência para o futuro. Conseqüentemente, a taxa de evasão total média, no Brasil, encontra-se um pouco abaixo da média das instituições privadas

e bem acima da média das instituições públicas, tendo em vista a crescente taxa de evasão no ensino superior privado e a manutenção das taxas de evasão nas instituições públicas.

A partir de 1990, com a autorização para abertura de novos cursos e novas vagas para o ensino superior e com as oportunidades de bolsas e facilidades para o pagamento das mensalidades, as instituições de ensino privadas responderam a uma demanda reprimida, aumentando as matrículas das classes C e D, e tiveram um crescimento vertiginoso. Porém, esse crescimento foi paradoxal, gerando, como consequência mais séria, a evasão, uma vez que os estudantes, mesmo com as facilidades, não conseguiam pagar a mensalidade na instituição privada e não conseguiam entrar na instituição pública, consequentemente abandonavam os estudos, evadindo-se da instituição de ensino superior. Outra razão que se coloca como geradora da evasão no ensino superior é a pouca maturidade social, daqueles que estão se matriculando em um curso de nível superior, para vivenciar o ensino superior (21).

Figura 1 - Gráfico do índice estimado da evasão nas IES públicas e privadas do Brasil (%) de 2000 a 2012.



Fonte: Gráfico elaborado pela autora a partir dos dados da Tabela 1.

A composição dos índices estimados de evasão anual no Brasil apontados na Tabela 1 e mostrados na Figura 1 foi obtida aplicando-se (1), adaptada de (21):

$$Evas\tilde{a}o(n) (\%) = \frac{(M(n-1) - NA_{con}(n-1)) - (M(n) - NA_{nov}(n))}{(M(n-1) - NA_{con}(n-1))} \times 100 \quad (1)$$

sendo:

- Evas\tilde{a}o(n) (%)* : Índice de evasão em determinado ano (*n*);
n : Ano em que se deseja estimar a evasão;
n-1 : Ano anterior a *n*;
M(n) : Matrícula total em determinado ano (*n*);
M(n-1) : Matrícula total no ano anterior a *n*;
NA_{con}(n-1) : Número de alunos concluintes/graduados no ano anterior a *n*;
NA_{nov}(n) : Número de alunos novos/ingressantes em determinado ano *n*.

A análise atual dos índices da evasão escolar no Brasil, mostrados na Figura 1, ilustra o preocupante estado de fadiga e fragilidade em que se encontra a educação superior brasileira. Esses resultados corroboram a necessidade de uma força tarefa por parte de toda sociedade: pesquisadores, gestores públicos e educacionais, educadores, profissionais especialistas, a família e os próprios educandos, para adoção de medidas que propiciem resultados satisfatórios no sentido de mitigar o fenômeno da evasão escolar e possibilitar uma educação de qualidade. Isso poderia impulsionar a Nação para um desenvolvimento socioeconômico sustentável, e quiçá, garantir a todo cidadão o direito, que lhe é de direito: o trabalho, a saúde, o lazer, a dignidade, a cidadania e, a tão sonhada felicidade e paz (4).

1.2 JUSTIFICATIVA

Diante do contexto histórico da educação no Brasil, percebe-se que o panorama complexo, intrincado e obscuro em que se encontra atualmente, arrasta-se de longa data e, certamente, o fator preponderante para esta situação é a evasão escolar.

Além dos danos sociais e humanos causados diretamente ao cidadão envolvido no processo educativo, outro aspecto concernente à evasão escolar é a destinação de verba para as instituições de ensino públicas. A dotação orçamentária é de vital importância para as IE's e está diretamente relacionada com o número de matrículas e o número de concluintes na instituição.

Em se tratando das instituições federais de ensino e, especificamente, dos institutos

federais de educação (IFE's) profissional e tecnológica, a viabilização de mais recursos para estas instituições está vinculada e será mediante o cumprimento de metas preestabelecidas, na implantação do Termo de Acordo de Metas e Compromissos (11). Esse Termo foi firmado entre os reitores dos institutos federais e o Ministério da Educação, por intermédio da Secretaria de Educação Profissional e Tecnológica (MEC/SETEC).

Para efeito do Termo de Acordo de Metas e Compromissos consideram-se os cursos técnicos de nível médio (integrado, concomitante e subsequente), PROEJA, cursos de graduação (Curso Superior de Tecnologia - CST, licenciatura, bacharelado), de pós-graduação (*lato sensu e stricto sensu*) e de formação inicial e continuada.

Algumas das metas a serem cumpridas são estritamente relacionadas ao tema em questão, e têm como objetivo elevar gradualmente a taxa de conclusão dos cursos e, conseqüentemente, reduzir as taxas de evasão (4). Como exemplo tem-se:

- alcançar a meta mínima de 90% de eficiência da instituição até o ano de 2016, com meta intermediária de no mínimo 75% no ano de 2013, medida semestralmente. O índice de eficiência da instituição será calculado pela média aritmética da eficiência de cada turma. Esta será medida pela relação entre o número de alunos regularmente matriculados e o número de total de vagas de cada turma, sendo que este total de vagas é resultado da multiplicação das vagas ofertadas no processo seletivo pelo número de períodos letivos para cada uma dessas turmas;
- alcançar a meta mínima de 80% de eficácia da instituição até o ano de 2016, com meta intermediária de no mínimo 70% até o ano de 2013, medida semestralmente. O índice de eficácia da instituição será calculado pela média aritmética da eficácia de cada turma. Sendo esta medida pela relação entre o número de alunos concluintes e o número de vagas ofertadas no processo seletivo para cada uma dessas turmas;
- alcançar a relação de 20 alunos regularmente matriculados nos cursos presenciais por professor.

Um estudo estatístico, realizado para identificar e analisar os fatores preponderantes e determinantes da evasão escolar no CST em Automação Industrial (AI) no Instituto Federal de Educação de Mato Grosso (IFMT) - Campus Cuiabá, no período de 2004-2010, constatou que dos 389 (trezentos e oitenta e nove) estudantes matriculados, 243 (duzentos e quarenta e

três) estão evadidos, representando um índice de 62,47% (sessenta e dois vírgula quarenta e sete por cento) de evasão (22).

Este alto índice de evasão, demonstrado por esse estudo, é uma ameaça real para o cumprimento do Acordo de Metas e constitui uma tarefa desafiadora, tendo em vista que a meta é reduzir para 10% o índice de evasão na instituição até 2016.

O CST em Automação Industrial do IFMT se depara e convive com o fenômeno da evasão discente. O índice de evasão neste curso, 62,47%, está acima da média dos índices da evasão no ensino superior, em torno de 23,8%, entre as instituições públicas e privadas de ensino superior no Brasil.

Essa constatação ratifica a necessidade de se encontrar maneiras, desenvolver métodos e instrumentos de avaliação e predição, planejamento de ações e acompanhamento, que sejam eficientes e eficazes para o saneamento da situação.

Além do que, admite-se que diminuir a evasão custa seis vezes menos do que trazer um novo estudante até a instituição de ensino (13). Combater a evasão é o modo mais eficiente de aumentar o número de matrículas e, ainda, mostrar a efetividade do processo, tendo em vista que fazer o aluno concluir seu curso, com qualidade, significa que a escola atingiu seu objetivo (13).

Nesse contexto, diante da complexidade do fenômeno e da necessidade de encontrar soluções, é imprescindível realizar estudos sistemáticos, observar os sinais de evasão iminente, desenvolver e implementar estratégias para favorecer a identificação precoce dos estudantes propensos à evasão. Isso, com o intuito de possibilitar a articulação de um conjunto de medidas e ações proativas no sentido de reverter as intenções de abandono, melhorar o sistema educacional e mitigar o fenômeno da evasão, possibilitando a manutenção do 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 às suas necessidades específicas.

Esta convicção vai ao encontro do que enfatiza a UNESCO (23), de que a evasão pode se constituir em fenômeno coletivo, mas é sempre um processo individual.

Portanto, reflexões, análises, estudos e pesquisas, à luz da ciência e da tecnologia, poderiam evidenciar, nortear, iluminar e alavancar o desenvolvimento da educação, superando

o enigma da evasão.

É nessa perspectiva que esta pesquisa se apresenta e se justifica, ou seja, ao encontro da necessidade do meio, à luz da ciência e da tecnologia, busca solução para um problema real e concreto, a evasão escolar. E o faz, almejando contribuir de maneira profícua com a redução dos índices de evasão discente, possibilitando a articulação de um conjunto de ações proativas e preventivas com intervenções individualizadas, destinadas a manter o estudante na instituição.

Conforme já mencionado, acredita-se que fazer (ação proativa) com que um aluno, com potencial de evadir, tenha sucesso é uma missão nobre, pois são sonhos que se realizam. Nessa perspectiva, proporcionar-se-á ao cidadão a ascensão social e profissional, contribuindo fortemente para o progresso do país em todos os sentidos. Certamente, também é motivo de satisfação institucional ter cumprido a missão de formar e educar em sua plenitude.

1.3 O PROBLEMA E A PROPOSTA DE SOLUÇÃO

Partindo do pressuposto de que a evasão escolar é um fenômeno intrincado e arraigado na Educação, que causa perdas sociais e financeiras e assola o processo educacional em nível nacional e internacional, cabe fazer algumas indagações: “O que já foi realizado, em nível de Brasil, com relação a essa questão?”; “Quais as medidas adotadas e os resultados alcançados?”; “É possível contribuir para amenizar essa situação?”; “De que maneira se pode contribuir?”; “Como contribuir?”; “Em que medida e aspecto a contribuição poderá ser efetiva?”.

Algumas questões levantadas podem ser percebidas e compreendidas pela leitura do panorama atual da Educação no Brasil, pela vivência prática no ambiente escolar, pelos índices estatísticos e informações advindas de pesquisas bibliográfica, histórica e documental.

De maneira geral, os trabalhos de pesquisa visam a identificar os fatores que contribuem e influenciam no fenômeno e no processo da evasão, permitindo, posteriormente, a formulação de estratégias para o enfrentamento da situação.

Os programas de prevenção e intervenção desenvolvidos e estruturados levando-se em conta os resultados das pesquisas e com intuito de manter o estudante na instituição, são implantados de maneira coletiva e atendimento generalizado, por meio de políticas públicas ou projetos específicos de instituições de ensino isoladas. No entanto, os resultados das

medidas e ações adotadas ainda estão aquém das expectativas e anseios quanto a redução dos índices da evasão.

Acredita-se que as medidas e ações adotadas para amenizar essa situação poderiam ser mais profícuas se houvesse o conhecimento prévio dos estudantes propensos à evasão. Isso possibilitaria a implantação coletiva dos programas de prevenção, porém com intervenção individualizada, suprindo as necessidades específicas de cada estudante e contribuindo para sua manutenção na instituição e conclusão do curso.

Portanto, uma proposta de solução é a possibilidade de identificar, de maneira proativa, continuada e acurada, o grupo de estudantes propensos a evasão.

Nessa perspectiva, faz-se necessário o desenvolvimento de métodos, instrumentos ou sistemas capazes de identificar previamente o grupo de risco de evasão discente. Então, de alguma maneira, ainda é possível contribuir para amenizar a situação da evasão discente.

Logo, é preciso pesquisar para conhecer: “Como desenvolver esse produto e em que medida e aspecto ele poderá contribuir efetivamente para manter o estudante na instituição e minimizar o fenômeno da evasão escolar?”.

Sabe-se que o sistema educacional é composto por vários níveis e modalidades de ensino e todos eles são afetados pela questão da evasão escolar. Porém, por uma questão de temporalidade para o desenvolvimento previsto para pesquisa em nível de doutorado, faz-se necessário recortar, delinear e focar a situação para investigar seus aspectos específicos, mas sempre percebendo e considerando a totalidade da questão.

Assim, inserida no âmbito da Engenharia, usando e aplicando suas técnicas, esta pesquisa se propõe, de maneira arrojada e inovadora, “engenhar, desenvolver e apresentar um sistema inteligente capaz de identificar previamente o grupo de estudantes propensos à evasão, em cursos superiores de tecnologia, da educação clássica presencial”.

Dessa maneira, sucintamente, o foco central da pesquisa é investigar: “em que medida o desenvolvimento de um Sistema Inteligente (SI) capaz de realizar a predição de grupos de risco de evasão discente, em cursos superiores presenciais, contribui para manter o estudante na instituição e amenizar os índices de evasão?”.

1.4 OS OBJETIVOS

O objetivo principal desta pesquisa é desenvolver um sistema inteligente utilizando a rede neural ARTMAP-*Fuzzy* (24-26) capaz de fazer a predição de grupos de risco de evasão discente, em cursos superiores presenciais,

Para se alcançar esse objetivo principal, faz-se necessário atingir alguns objetivos mais específicos, que são:

- Realizar um levantamento bibliográfico para conhecer as possíveis causas da evasão no ensino superior presencial no Brasil e os modelos e teorias correlatas a essa questão;
- Analisar os bancos de dados com os registros dos estudantes, quanto às informações socioeconômicas, curso, data de matrícula e situação acadêmica;
- Selecionar, relacionar e correlacionar as características mais relevantes para compor o banco de dados das amostras de entrada e buscar as respectivas situações acadêmicas para montar o banco de dados da saída da rede neural ARTMAP-*Fuzzy*;
- Categorizar os dados de entrada e saída da rede e transferi-los para um código binário, por exemplo, de até 3 *bits*⁴ por informação usada;
- Conceber e desenvolver o código-fonte do sistema inteligente utilizando a rede neural ARTMAP-*Fuzzy* em linguagem de programação Fortran;
- Preparar os conjuntos de dados para treinamento e teste da rede neural ARTMAP-*Fuzzy*;
- Treinar, testar e validar a rede;
- Analisar os resultados obtidos com o desenvolvimento e construção do sistema proposto;

1.5 DO OBJETO DA PESQUISA - O SISTEMA INTELIGENTE

As variáveis envolvidas no processo da evasão guardam em si uma gama de

⁴ *bit* - cada dígito do código binário (*binary digit*) representado pelos algarismos “0” e “1”.

especificidades inerentes aos diferentes níveis de ensino, cursos e instituições em que ela ocorre. Elas 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) (27), um dos paradigmas da Inteligência Artificial (IA) (28).

As Redes Neurais (RN) são sistemas matemáticos computacionais ou circuitais que emulam o cérebro humano na interpretação e processamento das informações. Elas “aprendem” através de experiências, podendo tornarem-se capazes de fazer generalizações mais confiáveis. Essa capacidade de generalização 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.

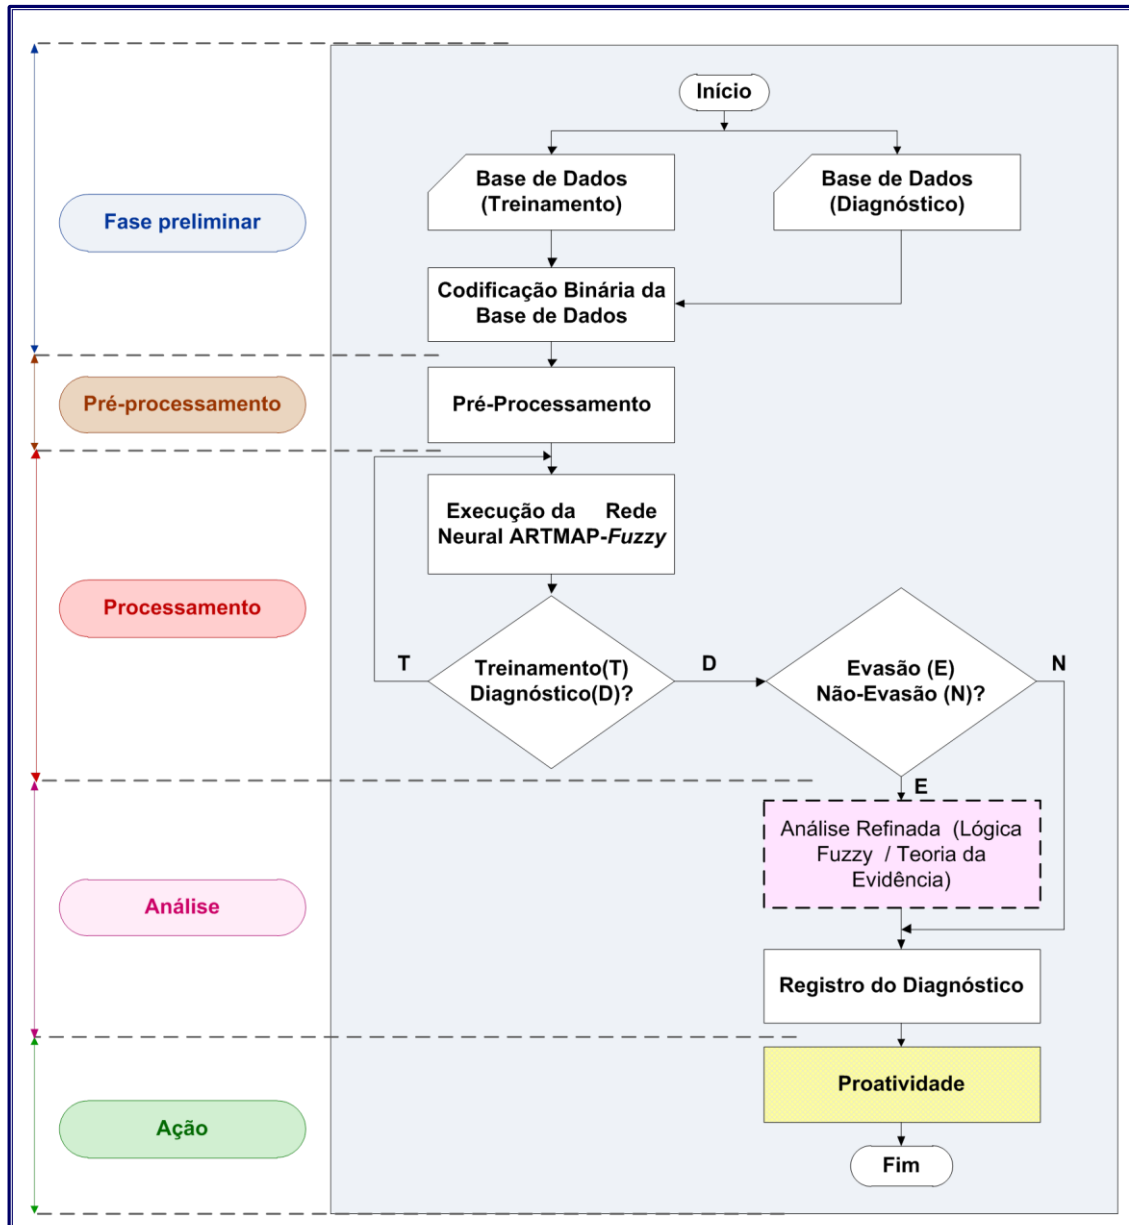
O Sistema Inteligente (SI) proposto, nesta pesquisa, consiste no emprego de uma rede neural artificial, mais especificamente de uma rede *ARTMAP-Fuzzy* (24-26) como possibilidade de identificar de maneira precoce, acurada e fidedigna o grupo de risco de evasão escolar discente, em cursos presenciais do ensino superior. Um módulo da Lógica *Fuzzy* (29) ou outro módulo que emprega a Teoria de Evidência de Dempster e Shafer (30) foi acoplado na saída do SI *ARTMAP-Fuzzy* como proposta para trabalhos futuros.

A Rede Neural *ARTMAP-Fuzzy* é uma rede da família ART (*Adaptive Resonance Theory*) (24), possui uma arquitetura em que o treinamento é realizado de modo supervisionado e auto-organizável, com possibilidade de aprendizado continuado (24, 31). Seu potencial de aplicação se destina a resolver vários problemas de classificação e de aproximação de funções não-lineares e multidimensionais.

Os sistemas de redes ART são capazes de aprender e de se adaptar em um ambiente em mudança, através do ajuste dos pesos (são estáveis) e, ao mesmo tempo, preservam seus conhecimentos aprendidos anteriormente, mantendo sua capacidade para aprender novos padrões (são plásticos). A estabilidade e a plasticidade são características essenciais para o processamento das redes ART, pois propiciam uma aprendizagem estável e convergência rápida.

A estrutura e sequência de desenvolvimento do sistema de predição da evasão escolar proposto nesta pesquisa estão representadas no fluxograma da Figura 2.

Figura 2 - Fluxograma do sistema neural proposto capaz de realizar a predição do grupo de risco da evasão discente.



Fonte: Fluxograma elaborado pela autora.

A implementação do sistema segue um procedimento padrão com quatro fases de execução, quais sejam:

- **Fase preliminar** : Nesta fase delimita-se o âmbito da investigação. Faz-se a seleção das bases de dados originais e das características que as compõem e a definição da amostra. Realiza-se a “limpeza” e a filtragem dos dados brutos selecionados, a categorização das características dos estudantes e o tratamento das informações. As bases de dados analógicos são

codificadas para o código binário e convertidas em bases de dados binários, tanto para o treinamento quanto para o diagnóstico do SI. Após a binarização as informações são dispostas em linhas. Em cada linha do conjunto de informações estão contidos os atributos 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, ou seja, não evadiu (0) ou evadiu (1), fornecido pela base de dados.

- Pré-processamento: Os vetores de entrada e saída desejada são apresentados às entradas dos módulos ART_a e ART_b , respectivamente, para o pré-processamento das informações. É realizada a leitura, normalização e codificação de complemento dos vetores entrada/saída, deixando-os no padrão adequado para o processamento da rede neural ARTMAP-*Fuzzy*. Nesta fase, os parâmetros da rede são definidos e os pesos inicializados.
- Processamento : Nesta fase ocorre o treinamento da rede neural e, conseqüentemente, a busca de “casamento” entre as classes de saída e de entrada.
- Fase de análise : A rede fará o registro da classificação do vetor de entrada quanto a evasão (classe “1”) ou não-evasão (classe “0”). Como proposta de trabalhos futuros, se a resposta de evasão for positiva (classe “1”), essa informação passa pelo módulo de análise fina, representado com linhas tracejadas no fluxograma da figura 2, para uma melhor discriminação sobre a qualidade da informação. Essa análise consiste em identificar, dentre as características predictoras, quais teriam maior influência e peso na decisão do estudante em evadir.

Ao final do processo, tem-se a fase da Ação. Diante dos resultados, propõe-se um planejamento de ações individualizadas (ação proativa) para atender às necessidades específicas de cada estudante identificado no grupo de risco, proporcionando condições para sua permanência na instituição. Salienta-se que a proatividade é uma atividade que depende fortemente da atuação da instituição.

A concepção de um sistema neural essencialmente binário é consideravelmente vantajoso em relação à formulação da rede neural ARTMAP-*Fuzzy* híbrida (dados binários e

analógicos). Desse modo, ela apresenta um comportamento mais eficiente (maior rapidez e melhor precisão na qualidade das respostas) e permite a extração do conhecimento de forma contínua (treinamento continuado (31-33)), buscando uma melhor adaptação às condições da instituição e o aperfeiçoamento com o passar do tempo.

Nesta pesquisa, os dados de entrada e de saída da rede neural são totalmente binários (digital) o que permite uma maior capacidade de inovação, se comparada a outras arquiteturas e tipos de redes neurais disponíveis na literatura especializada.

Destaca-se que o sistema inteligente concebido preserva o sigilo absoluto dos indivíduos/estudantes que são usados como sujeito e/ou objeto de análise.

O Código-fonte do sistema inteligente proposto foi desenvolvido em linguagem de programação Fortran e compilado com o programa Microsoft Developer Studio. No desenvolvimento da pesquisa, a aplicação do sistema, as simulações e o processamento do programa foram realizados em um microcomputador com sistema operacional Windows 7 Home Premium de 64 *bits*, processador Intel (R) Core (TM) i7 - 2630, CPU de 2GHz e 4GB de memória RAM.

Esta proposta capaz de identificar problemas e contribuir para a adoção de medidas que favoreçam ao estudante condições para completar o curso com pleno êxito, caracteriza-se, em sua essência, uma ação proativa e instituinte.

Ressalta-se que, frente aos trabalhos científicos sobre evasão, a originalidade, pertinência, audácia e a pujança científica desta pesquisa encontram-se:

1. na utilização da Rede Neural ARTMAP-*Fuzzy* como possibilidade de identificar, de maneira proativa, continuada e acurada os estudantes, da educação clássica-presencial, propensos à evasão no ensino de nível superior no Brasil, constatando-se que não existem, no contexto da revisão bibliográfica realizada, trabalhos científicos que se utilizam dessa ferramenta no âmbito em que se propõe esta pesquisa;
2. na possibilidade de usar, basicamente, os dados da inscrição dos estudantes, para identificar precocemente a iminente evasão, contribuindo para que se possa articular uma rede de apoio psicossocial, econômico e educacional que envolvam os estudantes pertencentes ao grupo de risco evasivo, intervindo nesse processo na tentativa de minimizar o índice de evasão, vislumbrando inclusive, o desenvolvimento de programas de apoio que possam atender as necessidades

específicas dos novos estudantes que se matricularem na instituição.

1.6 METODOLOGIA

Compreendendo metodologia como o conjunto de métodos ou caminhos que são percorridos na busca do conhecimento (34), o desenvolvimento desta pesquisa será delineado partindo de sua caracterização.

1.6.1 Caracterização e Processo de Desenvolvimento

Esta pesquisa constitui-se em um trabalho científico original, no sentido de ser realizada pela primeira vez e contribuir com novas conquistas (34) com relação ao tema em questão.

Considerando que o objeto desta pesquisa é um Sistema Inteligente concebido e desenvolvido com a finalidade de identificar previamente o grupo de estudantes em risco de evasão escolar, pode-se afirmar que esta pesquisa é de natureza aplicada. Pois, seu objetivo final é contribuir para aplicações práticas, pela busca de soluções para problemas concretos (34). Assim, caracteriza-se como uma investigação do tipo teórico-prática.

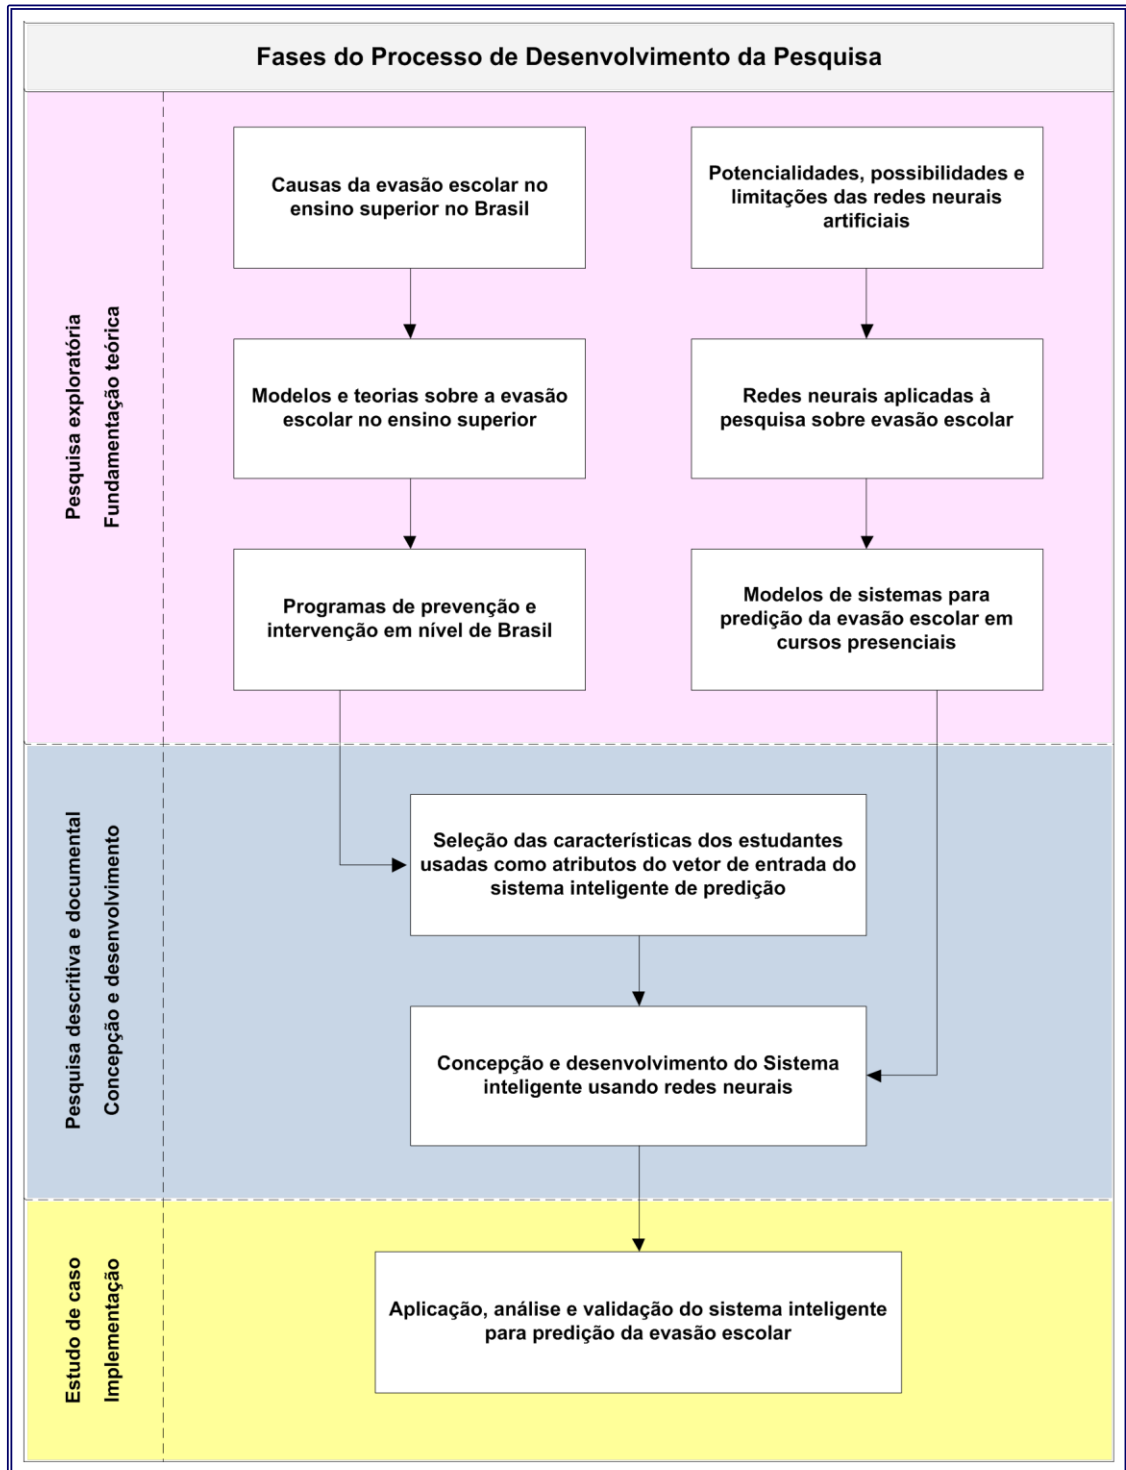
As análises, interpretações e inferências sobre os resultados apresentados pelo sistema proposto são baseadas na abordagem quantitativa, e complementadas pela abordagem qualitativa quando inter-relaciona os resultados e atribui significado frente ao fenômeno da evasão.

O processo de desenvolvimento da pesquisa encontra-se estruturado em três fases distintas, porém sequencialmente inter-relacionadas, tendo em vista a composição dos diferentes objetivos específicos para se concretizar o objetivo principal. Esse processo de desenvolvimento está apresentado na Figura 3.

A primeira fase se constitui numa pesquisa exploratória de cunho bibliográfico, sendo um trabalho preliminar e preparatório (34) para o desenvolvimento dessa pesquisa. Realizou-se um levantamento em várias publicações científicas com o intuito de perceber quais as contribuições relativas ao fenômeno da evasão, compreender suas possíveis causas e conhecer quais e como os programas de prevenção e intervenção estão sendo implementados no ensino superior presencial no Brasil. De maneira complementar, esses aspectos também foram

pesquisados em nível internacional. Ainda, com relação à evasão foram encontrados e registrados os modelos e teorias sobre a evasão escolar.

Figura 3 - Fases do processo de desenvolvimento da pesquisa.



Fonte: Elaborado pela autora.

Concomitantemente ao estudo da evasão, foi realizado um levantamento bibliográfico com relação aos sistemas de predição da evasão escolar. Inicialmente a busca era aberta, aceitando sistemas com diferentes técnicas. Em seguida, usou-se um filtro para selecionar apenas os sistemas que utilizassem técnicas no escopo da Inteligência Artificial (IA) e, mais especificamente as redes neurais.

Nesta fase percorreu-se a evolução histórica das redes neurais com o objetivo de apropriar e apreender o conhecimento sobre suas potencialidades, possibilidades e limitações.

Na segunda fase da pesquisa, ocorre a etapa preliminar da implantação do sistema neural. Baseada na pesquisa bibliográfica da primeira fase, são selecionadas as variáveis ou atributos do vetor de entrada da rede, o sistema é concebido e o tipo de rede é escolhido. Salienta-se que o código-fonte para execução do sistema é desenvolvido usando a linguagem de programação Fortran.

Nesta fase, realiza-se a coleta dos dados, sendo utilizada como instrumento a pesquisa documental, pois se baseia em documentos primários, documentos históricos e dados estatísticos que ainda não foram utilizados em nenhum estudo ou pesquisa (34).

Na fase final ocorre a validação do sistema desenvolvido e a análise dos resultados da pesquisa, fundamentada na realização de um estudo de caso. Inicialmente, como estudo de caso único, os resultados são utilizados para comprovar a fidedignidade, veracidade e robustez do sistema proposto que, *a posteriori*, servirão como piloto para o diagnóstico de múltiplos casos, demonstrando a possibilidade de generalização ou da diversidade (35).

O estudo de caso consiste na observação detalhada de um contexto ou indivíduo e suas relações e implicações, de uma única fonte de documentos ou de um acontecimento específico (35).

Essa linha de ação foi seguida no processo de desenvolvimento de um sistema inteligente para predição do grupo de risco de evasão escolar discente, em cursos presenciais do ensino superior no Brasil, utilizando Rede Neural Artificial ARTMAP-*Fuzzy*, proposto nesta pesquisa. Suas especificidades para o estudo em questão são delineadas a seguir.

1.6.2 Âmbito e Universo da Pesquisa

Esta pesquisa foi desenvolvida no âmbito do Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso - IFMT, Câmpus Cuiabá.

O IFMT integra a rede federal de educação profissional, científica e tecnológica e, atualmente, oferece cursos em níveis e modalidades conforme Tabela 2.

Tabela 2 - Cursos, níveis e modalidades de ensino no IFMT - Câmpus Cuiabá.

Níveis	Ensino Médio			Ensino Superior			Pós-Graduação		
Modalidades	Ensino Médio Integrado	Proeja	Técnico Subsequente / Pós-Médio	Tecnólogo	EaD	Bacharelado	Especialização	Minter	Dinter
Cursos	Agrimensura	Edificações	Agrimensura	Automação e Controle	Sistema para Internet	Engenharia da Computação	Esp. em Proeja	Ciências Políticas	Engenharia Elétrica
	Edificações	Eletrotécnica	Edificações	Controle de Obras		Engenharia de Controle e Automação	Esp. em TECNEP	Engenharia Elétrica	Geotecnia
	Eletrônica		Eletrônica	Sistemas para Internet		Secretariado Executivo	Redes e Computação Distribuída		Psicologia Social
	Eletrotécnica		Eletrotécnica	Redes de Computador					
	Eventos		Eventos						
	Informática		Guia de Turismo						
	Secretariado		Manutenção e Suporte em Informática						
	Telecomunicações		Secretariado						
			Telecomunicações						
			Topografia e Geoprocessamento						

Fonte: Elaborada pela autora a partir dos dados do site institucional do IFMT - Câmpus Cuiabá. <http://www.cba.ifmt.edu.br/webui/>

Os cursos estão distribuídos em departamentos de quatro diferentes áreas do conhecimento (DA), sendo: Construções Prediais - DACC, Eletroeletrônica - DAEE, Informática - DAI e Serviços - DAS e no Departamento de Pesquisa Pós-Graduação - DPPG, conforme Tabela 3.

Tabela 3 - Cursos distribuídos nos Departamentos de Área (DA) e Pós-Graduação (DPPG).

Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso - IFMT – Câmpus Cuiabá.						
Níveis	D.A Modalid	DACC	DAEE	DAI	DAS	DPPG
Ensino Médio	Ensino Médio Integrado	Agrimensura	Eletrônica	Informática	Eventos	-
		Edificações	Eletrotécnica		Secretariado	
			Telecomunicações			
	Proeja	Edificações	Eletrotécnica	-		-
	Técnico	Agrimensura	Eletrônica	Manutenção e Suporte em Informática	Guia de Turismo	-
		Edificações	Eletrotécnica		Secretariado	
Topografia e Geoprocessamento		Telecomunicações				
Ensino Superior	Tecnólogo	Controle de Obras	Automação e Controle	Sistema para Internet	-	-
				Redes para Computadores Distribuídas		
	EaD	-	-	Sistema para Internet	-	-
Bacharelado			Engenharia de Controle e Automação	Engenharia da Computação	Secretariado Executivo	-
Pós-Graduação	Especialização	-	-	Redes e Computação Distribuída	-	Especialização em Proeja
						Especialização em TECNEP
	Minter	-	-	-	-	Ciências Políticas
						Engenharia Elétrica
	Dinter	-	-	-	-	Engenharia Elétrica
						Geotecnia
Psicologia Social						

Fonte: Elaborada pela autora a partir dos dados do site institucional do IFMT - Câmpus Cuiabá. <http://www.cba.ifmt.edu.br/webui/>

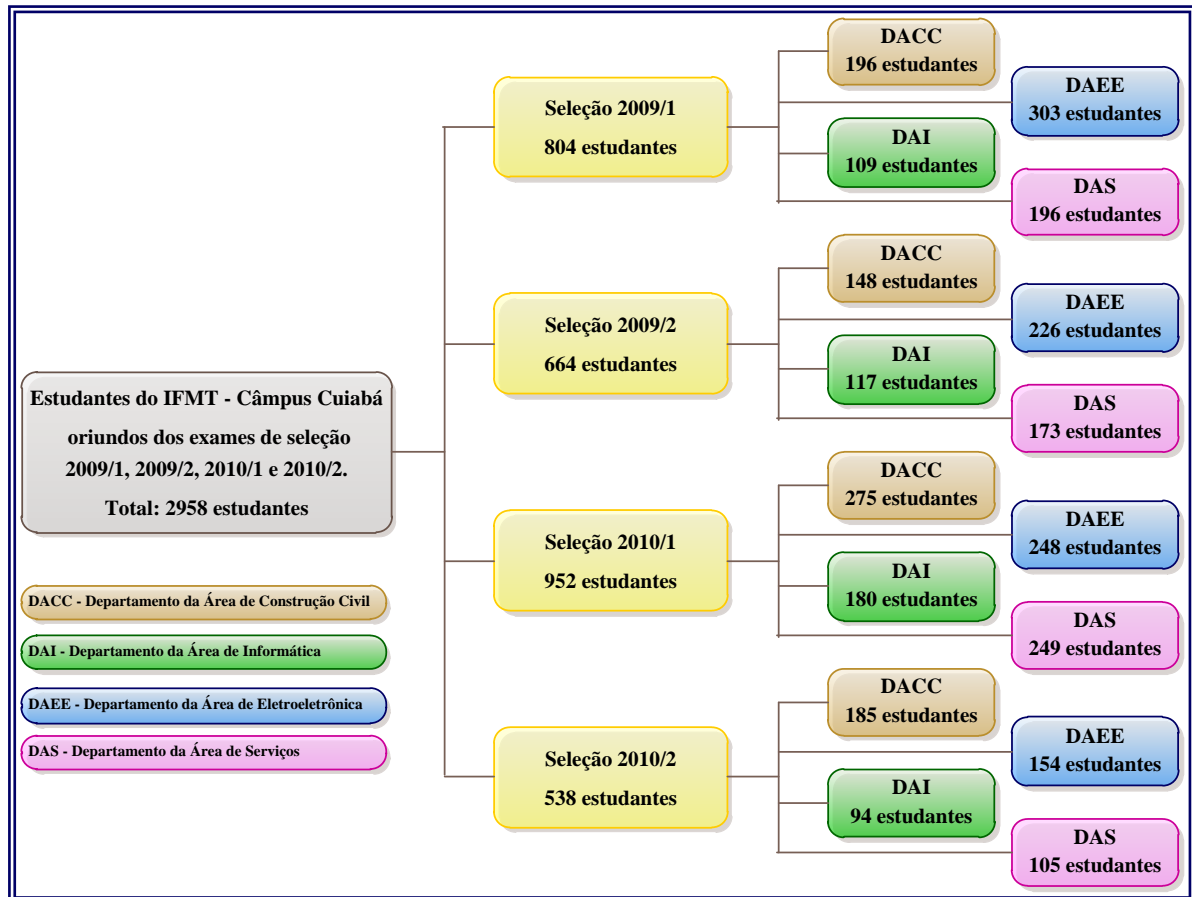
O universo de interesse desta pesquisa são os estudantes matriculados nos Cursos Superiores de Tecnologia (CST), de caráter presencial, realçados nas Tabelas 2 e 3.

A quantidade de estudantes que se matricularam no Câmpus Cuiabá, do IFMT, oriundos dos processos de seleção entre os anos de 2009/1⁵ e 2010/2, nos níveis e modalidades de ensino em cada departamento de área (DA) do conhecimento, pode ser conferida no fluxograma mostrado na Figura 4. Parte desses estudantes matriculados estará

⁵ 2009/1 - Ano / Semestre de ingresso na Instituição.

propensa à evasão, os quais se pretende identificar de maneira proativa, continuada e precisa com aplicação do sistema preditivo proposto nesta pesquisa.

Figura 4 - Quantidade de estudantes matriculados no IFMT - Câmpus Cuiabá por exame de seleção e por Departamento - no período de 2009/1 e 2010/2.



Fonte: Elaborada pela autora a partir do banco de dados do processo Q-Seleção.

A escolha do grupo de estudantes dos CST se justifica pelos altos índices de evasão nos mesmos, constatado através de levantamentos estatísticos prévios realizados pela Diretoria de Ensino (DE) do IFMT - Câmpus Cuiabá, bem como, um estudo, pormenorizado, realizado no CST em Automação e Controle (22).

O estudo de caso para predição da evasão escolar foi realizado com os dados dos estudantes do CST de Automação e Controle. Os dados coletados para análise compreende um período de sete anos, de 2004/2 a 2011/2. Este conjunto de dados foi distribuído em dois grupos, sendo um para o treinamento da rede neural (2004/2 a 2010/2) e outro para o diagnóstico ou predição da evasão (2011/1 e 2011/2).

Após essa fase, considerada piloto, o sistema poderá ser implementado para os demais CST, separadamente, tendo em vista as especificidades dos fatores que favorecem a evasão dos estudantes em cada um deles.

1.6.3 A Coleta de Dados

A coleta de dados para o desenvolvimento dessa pesquisa foi realizada utilizando a pesquisa documental.

Os dados foram coletados a partir dos dois sistemas de gestão e controle utilizados pelo IFMT, o Q-Acadêmico⁶, onde se concentra toda história acadêmica dos estudantes, e o Q-Seleção⁷, sistema que controla os processos seletivos da instituição. Nesse último, estão armazenados os dados referentes às respostas do questionário socioeconômico, preenchido pelos candidatos no ato da inscrição para o exame de seleção para ingresso no IFMT.

O questionário socioeconômico é composto por 23 (vinte e três) questões. Para essa investigação as respostas de 13 (treze) delas foram selecionadas como características preditoras na análise da evasão. A escolha das questões foi norteada pela análise dos modelos e teorias sobre a evasão escolar encontrados na pesquisa bibliográfica realizada na fase exploratória dessa pesquisa.

Além dos dados do questionário, foram consideradas outras características como distância aproximada entre residência e escola, obtida analisando o bairro onde o estudante reside, turno de estudo e número de estudantes por turma, coletadas no Q-Acadêmico.

Neste estudo, as características consideradas como preditoras para a análise da evasão foram: sexo, idade, etnia, estado civil, quantidade de pessoas que residem na mesma casa com o estudante, renda familiar, possui ou não computador em casa, escolaridade dos pais, escola de origem, autoavaliação como estudante, procedência, distância escola-residência, meio de transporte, situação de trabalho, turno de estudo e número de estudantes por sala de aula.

⁶ Q-Acadêmico - Sistema de gestão e controle acadêmico integrado, onde se concentra toda história acadêmica dos estudantes do IFMT. <http://www2.qualidata.com.br/q_academico.htm>

⁷ Q-Seleção - Sistema gerenciador de banco de dados que controla os processos seletivos do IFMT. <http://www2.qualidata.com.br/q_selecao.htm>

Inicialmente, foram coletados os dados brutos dos candidatos aprovados no exame de seleção. Os dados extraídos do Q-Seleção foram exportados para uma planilha do Microsoft Office Excel 2010, mostrada parcialmente na Figura 5. Em seguida essas informações foram filtradas para selecionar somente as respostas das questões de interesse para a pesquisa.

Figura 5 - Planilha do Microsoft Office Excel com os dados brutos dos candidatos aprovados no exame de seleção 2009/1 exportados do Q-Seleção.

Nome Candidato	Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Q10	Q11	Q12	Q13	Q14	Q15
20 ANOS	MASCUL	SOLTE	NEGR	EVANGÉ	SIM, EM TEM	3	DE 1,5 A 2	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA MU	NÍVEL MÉDIO	4
20 ANOS	MASCUL	SOLTE	NEGR	EVANGÉ	SIM, EM TEM	3	DE 1,5 A 2	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA MU	NÍVEL MÉDIO	4
MAIS DE 30	MASCUL	CASA	OUTR	CATÓLIC	SIM, EM TEM	2	ACIMA DE	MOTOC	CLÍNICA	NÃO	NENHUMA	NÃO	SUPLETIVO	NÍVEL MÉDIO	4
MAIS DE 30	MASCUL	CASA	OUTR	CATÓLIC	SIM, EM TEM	2	ACIMA DE	MOTOC	CLÍNICA	NÃO	NENHUMA	NÃO	SUPLETIVO	NÍVEL MÉDIO	4
30 ANOS	MASCUL	SOLTE	BRAN	CATÓLIC	ESTOU DESE	3	ACIMA DE	MOTOC	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA MU	NÍVEL SUPERIO	4
30 ANOS	MASCUL	SOLTE	BRAN	CATÓLIC	ESTOU DESE	3	ACIMA DE	MOTOC	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA MU	NÍVEL SUPERIO	4
17 ANOS	MASCUL	SOLTE	INDÍG	CATÓLIC	NÃO TRABA	3	ACIMA DE	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA PAR	NÍVEL MÉDIO	4
17 ANOS	MASCUL	SOLTE	INDÍG	CATÓLIC	NÃO TRABA	3	ACIMA DE	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA PAR	NÍVEL MÉDIO	4
MAIS DE 30	MASCUL	CASA	BRAN	CATÓLIC	SIM, EM TEM	4	ACIMA DE	CARRO	CLÍNICA	NÃO	NENHUMA	NÃO	SUPLETIVO	NÍVEL MÉDIO	4
MAIS DE 30	MASCUL	CASA	BRAN	CATÓLIC	SIM, EM TEM	4	ACIMA DE	CARRO	CLÍNICA	NÃO	NENHUMA	NÃO	SUPLETIVO	NÍVEL MÉDIO	4
18 ANOS	MASCUL	SOLTE	BRAN	CATÓLIC	SIM, EM TEM	6	DE 0,5 A 1	A PÉ	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
18 ANOS	MASCUL	SOLTE	BRAN	CATÓLIC	SIM, EM TEM	6	DE 0,5 A 1	A PÉ	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
18 ANOS	MASCUL	SOLTE	BRAN	CATÓLIC	SIM, EM TEM	6	DE 0,5 A 1	A PÉ	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
MAIS DE 30	FEMININ	MORA	NEGR	ESPÍRITA	SIM, EM TEM	3	ACIMA DE	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	SUPLETIVO	NÍVEL MÉDIO	4
MAIS DE 30	FEMININ	MORA	NEGR	ESPÍRITA	SIM, EM TEM	3	ACIMA DE	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	SUPLETIVO	NÍVEL MÉDIO	4
MAIS DE 30	MASCUL	SOLTE	BRAN	NENHUM	SIM, EM TEM	3	ACIMA DE	CARRO	CLÍNICA	SIM	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
MAIS DE 30	MASCUL	SOLTE	BRAN	NENHUM	SIM, EM TEM	3	ACIMA DE	CARRO	CLÍNICA	SIM	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
20 ANOS	MASCUL	SOLTE	BRAN	CATÓLIC	SIM, EM TEM	2	DE 1,5 A 2	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
20 ANOS	MASCUL	SOLTE	BRAN	CATÓLIC	SIM, EM TEM	2	DE 1,5 A 2	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
20 ANOS	MASCUL	SOLTE	OUTR	CATÓLIC	SIM, EM TEM	3	DE 2,5 A 3	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
20 ANOS	MASCUL	SOLTE	OUTR	CATÓLIC	SIM, EM TEM	3	DE 2,5 A 3	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
MAIS DE 30	MASCUL	MORA	NEGR	CATÓLIC	SIM, EM TEM	3	DE 1,5 A 2	MOTOC	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA MU	NÍVEL MÉDIO	4
MAIS DE 30	MASCUL	MORA	NEGR	CATÓLIC	SIM, EM TEM	3	DE 1,5 A 2	MOTOC	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA MU	NÍVEL MÉDIO	4
19 ANOS	FEMININ	SOLTE	NEGR	CATÓLIC	SIM, EM TEM	4	DE 2,5 A 3	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
19 ANOS	FEMININ	SOLTE	NEGR	CATÓLIC	SIM, EM TEM	4	DE 2,5 A 3	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
17 ANOS	MASCUL	SOLTE	BRAN	EVANGÉ	NÃO TRABA	3	ACIMA DE	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
17 ANOS	MASCUL	SOLTE	BRAN	EVANGÉ	NÃO TRABA	3	ACIMA DE	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
25 ANOS	FEMININ	SOLTE	OUTR	CATÓLIC	SIM, EM TEM	5	DE 2,5 A 3	MOTOC	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL SUPERIO	4
25 ANOS	FEMININ	SOLTE	OUTR	CATÓLIC	SIM, EM TEM	5	DE 2,5 A 3	MOTOC	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL SUPERIO	4
18 ANOS	MASCUL	SOLTE	MESTI	CATÓLIC	NÃO TRABA	4	DE 1,5 A 2	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
18 ANOS	MASCUL	SOLTE	MESTI	CATÓLIC	NÃO TRABA	4	DE 1,5 A 2	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
MAIS DE 30	MASCUL	MORA	BRAN	CATÓLIC	SIM, EM TEM	3	ACIMA DE	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
MAIS DE 30	MASCUL	MORA	BRAN	CATÓLIC	SIM, EM TEM	3	ACIMA DE	ÔNIBUS	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA EST	NÍVEL MÉDIO	4
25 ANOS	MASCUL	SOLTE	NEGR	CATÓLIC	SIM, EM TEM	4	DE 0,5 A 1	BICICLE	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA MU	NÍVEL SUPERIO	4
25 ANOS	MASCUL	SOLTE	NEGR	CATÓLIC	SIM, EM TEM	4	DE 0,5 A 1	BICICLE	CLÍNICA	NÃO	NENHUMA	NÃO	ESCOLA MU	NÍVEL SUPERIO	4

Fonte: Elaborada pela autora a partir da planilha do Microsoft Office Excel.

Nesse ambiente, manualmente, foi feita a “limpeza” dos dados. Foram eliminadas as colunas com códigos e protocolos específicos do sistema, as questões do questionário que não faziam parte das características selecionadas, os candidatos que não haviam preenchidos os campos de interesse para o foco da pesquisa e/ou com dados duplicados.

Após o processo de “limpeza” e filtragem dos dados extraídos do Q-Seleção, de maneira semelhante, foi realizada uma consulta no Q-Acadêmico. Nesse sistema de gestão acadêmica foram extraídas informações dos estudantes quanto ao bairro que reside, turno de estudo e o número de estudantes por sala de aula, para compor o conjunto de características preditoras para a análise e identificação precoce da evasão. Os dados foram exportados para

uma planilha do Microsoft Office Excel 2010 para se proceder com a filtragem dos mesmos. A Figura 6 mostra uma parcela desta planilha.

Figura 6 - Planilha do Microsoft Office Excel com os dados dos estudantes no final do 1º semestre de 2009 - 2009/1 - exportados do Q-Acadêmico.

Nome	Sit. Matrícula	Nascimento	Sexo	Per. Let Inic	Curso	Período	Turno	Instituição	Endereço	Númer	Bairro	Cidade	Percent. Freq.
Concluído	28/04/1986	M	2009/1	Técnico em Agrimensu	1	Noturno	ampus - Cuiab	Avenida do Cont	1	São Roque	Cuiabá -	92,4137931034483	
Matriculado	03/12/1969	M	2009/1	Técnico em Refrigeraç	1	Noturno	ampus - Cuiab	Rua Portugal	94	Bordas da Chapada	Cuiabá -	0	
Concluído	23/01/1987	F	2009/1	Técnico em Guia de Tu	1	Noturno	ampus - Cuiab	Rua 52, Qd L	16	São João Del Rey	Cuiabá -	94,0298507462687	
Concluído	02/04/1988	M	2009/1	Técnico em Guia de Tu	1	Noturno	ampus - Cuiab	Rua Presidente	6	Jd Glória I	Várzea G	95,7356076759062	
Matriculado	07/02/1983	F	2009/1	Técnico em Guia de Tu	1	Noturno	ampus - Cuiab	Rua General Car	45	Dom Aquino	Cuiabá -	25,7777777777778	
Concluído	12/01/1988	F	2009/1	Especialização em Red	1	Vespertino	ampus - Cuiab	Av. Marginal	50	Araés	Cuiabá -	99,3548387096774	
Cancelado	24/03/1987	M	2009/1	Técnico em Guia de Tu	1	Noturno	ampus - Cuiab	Rua Couto Mag	567	Jardim Leblon	Cuiabá -	0	
Matriculado	17/05/1986	M	2009/1	Técnico em Eletrônica	1	Noturno	ampus - Cuiab	Rua 84	25	Cpa III	Cuiabá -	100	
Concluído	04/02/1982	M	2009/1	Técnico em Eletrotéc	1	Noturno	ampus - Cuiab	Rua Conego Pre	31	Dom Aquino	Cuiabá -	85,929648241206	
Matriculado	14/08/1971	M	2009/1	Técnico em Refrigeraç	1	Noturno	ampus - Cuiab	Rua Grabieli Fel	206	Cristo Rei	Cristo Re	92,204899772828	
Matriculado	20/10/1976	M	2009/1	Técnico em Refrigeraç	1	Noturno	ampus - Cuiab	Rua 07	20	Nova Fronteira	Várzea G	0	
Matriculado	01/10/1981	F	2009/1	Técnico em Secretária	1	Noturno	ampus - Cuiab	Rua Indutão	6	Vila Arthur	Várzea G	99,2647058823529	
Concludente	07/04/1988	M	2009/1	Técnico em Eletrotéc	1	Noturno	ampus - Cuiab	Rua 4	1	Cohab Marzagão	Nobres -	88,5416666666667	
Concluído	25/02/1983	M	2009/1	Especialização em Red	1	Vespertino	ampus - Cuiab	Rua Galdino Pim	162	Centro	Cuiabá -	97,4193548387097	
Matriculado	02/06/1989	M	2009/1	Técnico em Telecomur	1	Matutino	ampus - Cuiab	Rua Banmdeiran	295	Pico do Amor	Cuiabá -	12,9901960784314	
Concludente	18/03/1983	M	2009/1	Técnico em Eletrotéc	1	Noturno	ampus - Cuiab	Rua Pará	4	Cpa II	Cuiabá -	98,9949748743719	
Matriculado	17/02/1985	F	2009/1	Técnico em Edificaçõe	1	Noturno	ampus - Cuiab	Rua Professora	164	Centro	Santo An	94,8598130841121	
Matriculado	22/12/1975	M	2009/1	Curso Superior de Tecr	1	Noturno	ampus - Cuiab	Rua J Quadra 10	20	Parque Atalaia	Cuiabá -	95,5445544554455	
Matriculado	12/06/1974	M	2009/1	Técnico em Eletrotéc	1	Noturno	ampus - Cuiab	Travessa Y25	14	Nossa Sra. Apareci	Coxipó d	53,0337078651685	
Matriculado	17/05/1988	M	2009/1	Técnico em Agrimensu	1	Matutino	ampus - Cuiab	Rua 15 Quadra	12	Jardim Santa Amali	Cuiabá -	8,9655172413793	
Matriculado	25/03/1979	M	2009/1	Curso Superior de Tecr	1	Vespertino	ampus - Cuiab	Rua 77, Qd 21	30	Cpa III	Cuiabá -	90,8713692946058	
Evasão	25/08/1989	M	2009/1	Técnico em Telecomur	1	Matutino	ampus - Cuiab	Rua 315 Quadra	15	Tijucal	Cuiabá -	0	
Concluído	02/11/1987	F	2009/1	Técnico em Secretária	1	Vespertino	ampus - Cuiab	Rua Pacaraima	235	Planalto	Cuiabá -	88,7254901960784	
Matriculado	10/02/1989	F	2009/1	Técnico em Edificaçõe	1	Noturno	ampus - Cuiab	Rua Nove	432	Jardim Vitória	Cuiabá -	81,0747663551402	
Matriculado	24/10/1994	F	2009/1	Técnico em Secretária	1	Matutino	ampus - Cuiab	Av. José Estevã	62	Jardim Vitória	Cuiabá -	97,8119935170178	
Concluído	12/04/1990	F	2009/1	Técnico em Edificaçõe	1	Noturno	ampus - Cuiab	Rua 09 de Nove	219	Altos da Boa Vista	Cuiabá -	93,5406698564593	
Evasão	07/08/1987	F	2009/1	Técnico em Agrimensu	1	Noturno	ampus - Cuiab	Rua 3	320	Boa Esperança	Cuiabá -	0	
Matriculado	23/01/1991	M	2009/1	Curso Superior de Tecr	1	Noturno	ampus - Cuiab	Rua 25 Quadra	430	Morada da Serra	Cuiabá -	35,036496350365	
Evasão	23/01/1991	M	2009/1	Técnico em Edificaçõe	1	Matutino	ampus - Cuiab	Rua 25 Quadra	430	Morada da Serra	Cuiabá -	0	
Concluído	10/04/1989	F	2009/1	Técnico em Guia de Tu	1	Noturno	ampus - Cuiab	5	10	Jardim Petrópolis	Cuiabá -	88,6993603411514	
Evasão	01/10/1991	M	2009/1	Curso Superior de Tecr	1	Vespertino	ampus - Cuiab	Rua Prof Lidio M	159	Jd. Alvorada	Cuiabá -	98,3402489626556	
Concluído	11/12/1981	M	2009/1	Técnico em Guia de Tu	1	Noturno	ampus - Cuiab	Av Barao do Me	3899	Centro	Cuiabá -	88	
Matriculado	23/08/1989	M	2009/1	Técnico em Eletrotéc	1	Noturno	ampus - Cuiab	Rua Auro Borges	184	Serragem	Nobres -	92,7083333333333	
Concludente	22/05/1992	M	2009/1	Técnico em Eletrotéc	1	Noturno	ampus - Cuiab	Rua Toledo	184	Nova Tarceira	Araçuaçu	97,964824120603	

Fonte: Elaborada pela autora a partir da planilha do Microsoft Office Excel

Observa-se que os nomes dos candidatos/estudantes foram suprimidos para preservar a identidade dos mesmos, sendo na planilha final, identificados com números.

Para compor uma base de dados com os atributos de cada estudante as planilhas extraídas dos sistemas de gestão, Q-Seleção e Q-Acadêmico, foram confrontadas e compiladas. Durante esse processo, os estudantes com choque de informações e dados incoerentes ou ausentes detectados entre as planilhas foram eliminados.

Para construir a base de dados da saída desejada da rede neural, utilizada para o treinamento do sistema neural ARTMAP-Fuzzy, realizou-se uma análise na situação acadêmica do estudante ao final do 1º semestre.

Esses processos resultaram em um conjunto de pares de amostras entrada-saída que, depois de categorizados e binarizados, foram apresentados ao sistema neural ARTMAP-Fuzzy. Esses procedimentos foram realizados tanto para a base de dados de treinamento quanto para o diagnóstico do sistema neural.

Na figura 7 é mostrada, parcialmente, a base de dados com os parâmetros utilizados como entrada e saída da rede neural.

Figura 7 - Parte do banco de dados com os parâmetros dos vetores de entrada e saída da rede.

Características para a entrada da Rede																	Saída Desejada	
Nº Amostra	Sx	FxEt	Etn	EstCiv	Pes Cs	Rfam	Comp	EscPaís	Aaval	EscOri	Procd	DistER (Km)	Transp	Trab	Turno	Freq	Situação no Período 2009/1	
1	F	25	NEGRA	SOLTEIRO	2	5 A 2,5 S	NÃO	ATÉ A 4ª SÉRIE	BOM	PÚBLICA REGULAR	URBANA	2,9	MOTO	INTEGRAL	Noturno	25,78	Evadido 1	
2	M	22	BRANCA	SOLTEIRO	5	5 A 3 S	SIM	ATÉ A 4ª SÉRIE	ÓTIMO	PÚBLICA REGULAR	URBANA	9,5	ÔNIBUS	NÃO TRAB	Noturno	100,00	Aprovado	
3	F	27	NEGRA	SOLTEIRO	5	5 A 1,5 S	NÃO	ENTRE 5ª E 8ª SÉRIE	BOM	PÚBLICA REGULAR	URBANA	9,5	ÔNIBUS	INTEGRAL	Noturno	99,26	Aprovado	
4	M	20	MESTIÇA	SOLTEIRO	5	IMA 3 S	SIM	PÓS-GRADUADO	REGULAR	PÚBLICA REGULAR	URBANA	5,0	TRANSP. ES	NÃO TRAB	Matutino	8,97	Evadido 1	
5	M	19	BRANCA	SOLTEIRO	4	5 A 1,5 S	SIM	NÍVEL MÉDIO COMP	REGULAR	PARTICULAR REGU	URBANA	12,5	ÔNIBUS	NÃO TRAB	Matutino	0,00	Evadido	
6	F	21	MESTIÇA	SOLTEIRO	4	5 A 2,5 S	SIM	ENTRE 5ª E 8ª SÉRIE	BOM	PÚBLICA REGULAR	URBANA	7,9	ÔNIBUS	NÃO TRAB	Vespertino	88,73	Aprovado	
7	M	17	BRANCA	SOLTEIRO	7	5 A 1,5 S	NÃO	ENTRE 5ª E 8ª SÉRIE	BOM	PÚBLICA REGULAR	URBANA	8,3	ÔNIBUS	PARCIAL	Noturno	35,04	Evadido 1	
8	M	27	MESTIÇA	SOLTEIRO	5	5 A 2,5 S	NÃO	NÍVEL MÉDIO COMP	ÓTIMO	PÚBLICA REGULAR	URBANA	1	ÔNIBUS	NÃO TRAB	Noturno	88,00	Aprovado	
9	M	16	NEGRA	SOLTEIRO	4	5 A 1,5 S	NÃO	ATÉ A 4ª SÉRIE	BOM	PÚBLICA REGULAR	URBANA	6,3	A PÉ	NÃO TRAB	Noturno	92,96	Aprovado	
10	M	18	NEGRA	SOLTEIRO	4	5 A 2,5 S	SIM	PÓS-GRADUADO	BOM	PARTICULAR REGU	URBANA	7,5	ÔNIBUS	NÃO TRAB	Noturno	5,94	Evadido 1	
11	F	17	BRANCA	SOLTEIRO	4	5 A 1,5 S	NÃO	NÍVEL SUPERIOR IN	REGULAR	PÚBLICA REGULAR	URBANA	10,8	A PÉ	NÃO TRAB	Noturno	96,57	Aprovado	
12	M	16	BRANCA	SOLTEIRO	3	5 A 2,5 S	NÃO	NÍVEL MÉDIO COMP	BOM	PÚBLICA REGULAR	URBANA	5,2	ÔNIBUS	NÃO TRAB	Noturno	93,93	Aprovado	
13	M	26	BRANCA	SOLTEIRO	3	5 A 1,5 S	NÃO	NÍVEL MÉDIO COMP	BOM	PARTICULAR REGU	URBANA	6,6	ÔNIBUS	NÃO TRAB	Noturno	88,58	Aprovado	
14	M	17	NEGRA	SOLTEIRO	4	5 A 3 S	SIM	ATÉ A 4ª SÉRIE	BOM	PÚBLICA REGULAR	URBANA	21,9	ÔNIBUS	NÃO TRAB	Noturno	95,48	Aprovado	
15	M	17	NEGRA	SOLTEIRO	4	5 A 3 S	NÃO	ENTRE 5ª E 8ª SÉRIE	ÓTIMO	PÚBLICA REGULAR	URBANA	1	TRANSP. ES	NÃO TRAB	Vespertino	0,00	Evadido 1	
16	M	32	BRANCA	SOLTEIRO	4	IMA 3 S	NÃO	NÍVEL SUPERIOR CO	BOM	PARTICULAR REGU	URBANA	12,5	ÔNIBUS	NÃO TRAB	Noturno	85,00	Aprovado	
17	M	23	MESTIÇA	SOLTEIRO	6	5 A 2,5 S	NÃO	NÍVEL MÉDIO COMP	BOM	PÚBLICA REGULAR	URBANA	5,2	ÔNIBUS	NÃO TRAB	Noturno	52,38	Evadido 1	
18	M	12	MESTIÇA	SOLTEIRO	3	5 A 2,5 S	SIM	NÍVEL SUPERIOR CO	BOM	PÚBLICA REGULAR	URBANA	10	ÔNIBUS	NÃO TRAB	Vespertino	96,92	Aprovado	
19	M	22	NEGRA	SOLTEIRO	4	IMA 3 S	SIM	NÍVEL SUPERIOR CO	BOM	PÚBLICA REGULAR	URBANA	7	ÔNIBUS	NÃO TRAB	Noturno	89,96	Aprovado	
20	M	31	BRANCA	SOLTEIRO	4	IMA 3 S	SIM	NÍVEL MÉDIO COMP	REGULAR	PÚBLICA REGULAR	URBANA	7	ÔNIBUS	NÃO TRAB	Noturno	94,68	Reprovado	
21	M	24	BRANCA	SOLTEIRO	3	5 A 2,5 S	NÃO	NÍVEL MÉDIO COMP	BOM	PÚBLICA REGULAR	URBANA	5,7	ÔNIBUS	INTEGRAL	Noturno	0,00	Reprovado	
22	F	18	NEGRA	SOLTEIRO	4	5 A 3 S	NÃO	NÍVEL SUPERIOR CO	BOM	PÚBLICA REGULAR	URBANA	6,2	ÔNIBUS	NÃO TRAB	Matutino	17,65	Evadido 1	
23	F	19	NEGRA	SOLTEIRO	7	IMA 3 S	NÃO	NÍVEL MÉDIO COMP	BOM	PÚBLICA REGULAR	URBANA	3,8	ÔNIBUS	NÃO TRAB	Noturno	81,37	Aprovado	
24	M	44	BRANCA	SOLTEIRO	3	5 A 2,5 S	SIM	NÍVEL MÉDIO COMP	BOM	PÚBLICA REGULAR	URBANA	6	ÔNIBUS	DESEMPRE	Noturno	96,17	Aprovado	
25	M	23	BRANCA	SOLTEIRO	3	5 A 3 S	SIM	NÍVEL MÉDIO COMP	ÓTIMO	PÚBLICA REGULAR	URBANA	2,8	A PÉ	NÃO TRAB	Noturno	94,68	Aprovado	
26	F	14	BRANCA	SOLTEIRO	4	5 A 3 S	SIM	NÍVEL SUPERIOR CO	REGULAR	PÚBLICA REGULAR	URBANA	4,5	BICICLETA	NÃO TRAB	Vespertino	0,00	Reprovado	
27	M	24	BRANCA	SOLTEIRO	3	5 A 2,5 S	SIM	NÍVEL MÉDIO COMP	BOM	PÚBLICA SUPLETIV	URBANA	13,3	MOTO	INTEGRAL	Noturno	90,35	Aprovado	
28	M	35	MESTIÇA	SOLTEIRO	5	IMA 3 S	SIM	ENTRE 5ª E 8ª SÉRIE	REGULAR	PÚBLICA REGULAR	URBANA	2	ÔNIBUS	NÃO TRAB	Noturno	98,57	Aprovado	
29	M	18	MESTIÇA	SOLTEIRO	3	IMA 3 S	SIM	NÍVEL SUPERIOR CO	BOM	PARTICULAR REGU	URBANA	2,8	CARONA	NÃO TRAB	Matutino	3,91	Reprovado	
30	F	20	MESTIÇA	SOLTEIRO	2	5 A 1,5 S	NÃO	NÍVEL MÉDIO COMP	BOM	PÚBLICA REGULAR	URBANA	9	ÔNIBUS	NÃO TRAB	Noturno	17,48	Reprovado	

Fonte: Elaborada pela autora a partir da planilha do Microsoft Office Excel

O vetor de entrada da rede neural é composto por 16 parâmetros considerados como significativos para a predição da evasão escolar e a saída da rede constituída por duas classes, dentre as quais se espera os resultados para cada vetor de entrada informado. Uma síntese das variáveis de entrada e saída da rede neural pode ser visualizada na Tabela 4.

Tabela 4 - Composição dos vetores de entrada e saída do sistema neural ARTMAP-*Fuzzy*.

Atributos dos Subvetores de a e y				
	Posição	Nome	Abreviatura	Tamanho
Variáveis do Vetor de Entrada (a) do Sistema Neural ARTMAP- <i>Fuzzy</i>	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	Número de pessoas/Residência	PesCs	3 bits
	a_6	Renda Familiar	Rfam	3 bits
	a_7	Possui Computador	Comp	1 bit
	a_8	Escolaridade pais	EscPais	3 bits
	a_9	Escola de Origem	EscOrig	3 bits
	a_{10}	Autoavaliação	AAval	3 bits
	a_{11}	Procedência	Procd	1 bit
	a_{12}	Distância Escola - Residência	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
Saída (y)	y	Não-Evasão	NEv	1 bit
		Evasão	Ev	

Fonte: Elaborada pela autora.

1.6.4 A Análise dos Resultados

Após a implantação e treinamento do sistema neural ARTMAP-*Fuzzy*, esse sistema foi colocado em operação. Várias simulações, com alteração dos parâmetros da rede, foram executadas até se obter o melhor desempenho e, então, definir os parâmetros para operação do sistema proposto.

Posteriormente, realizou-se o diagnóstico, quanto à evasão, com uma base de dados composta pelos estudantes do CST em Automação e Controle. A base de dados utilizada para o diagnóstico possui entre 30% e 45% da quantidade de amostras da base de dados do treinamento.

O resultado do diagnóstico para o conjunto de amostras (estudantes) foi a classificação “1” para “evasão” e “0” para “não-evasão”. Comparando os resultados do diagnóstico com a real situação dos estudantes analisados quanto à evasão calculou-se os índices de acertos e erros do sistema.

A resposta do sistema inteligente para predição do grupo de risco de evasão discente em cursos superiores presenciais, considerando os índices de acertos e erros encontrados, foi parametrizada com alguns resultados de pesquisas apresentados nas referências encontradas na literatura pesquisada.

Ressalta-se que não se identificou, na literatura pesquisada, nenhuma proposta de sistema de predição com as características e peculiaridades do sistema desenvolvido nessa pesquisa. A parametrização dos resultados foi possível levando-se em conta que algumas particularidades das pesquisas encontradas são contempladas pelo sistema concebido, desenvolvido, testado, validado e apresentado neste trabalho.

Finalmente, após o processo de análise pôde-se compreender e inferir em que medida o sistema inteligente para predição de grupos de risco de evasão discente, desenvolvido nesta pesquisa, contribui para manter o estudante na instituição e amenizar os índices de evasão escolar. Bem como, propor algumas medidas de prevenção e intervenção com relação ao fenômeno da evasão. Além de perceber a continuidade desta pesquisa e identificar possibilidade de trabalhos futuros.

1.7 REFERENCIAL TEÓRICO

Sendo o objetivo desta pesquisa a concepção e o desenvolvimento de um sistema inteligente, baseado na Teoria da Ressonância Adaptativa (*Adaptive Resonance Theory - ART*), capaz de identificar previamente o grupo de estudantes em risco de evasão, fez-se necessária a compreensão do significado dessa teoria, suas potencialidades e possibilidades de aplicação. Assim, o aporte teórico de sustentação desta pesquisa e do desenvolvimento do sistema proposto está nos trabalhos dos precursores da Teoria ART encontrados em Carpenter e Grossberg (1992, 1987) (26, 36), Carpenter, Grossberg e Rosen (1991) (25), Carpenter, Grossberg *et al.* (1992) (24), Carpenter, Grossberg e Reynolds (1991) (37), Carpenter, Grossberg e Iizuka (1992) (38) e Grossberg (2013) (39).

O sistema inteligente proposto foi concebido e desenvolvido utilizando a rede neural

ARTMAP-*Fuzzy*, uma das redes da família ART. Considerando essa especificidade, esta pesquisa também está ancorada nos resultados das pesquisas desenvolvidas e apresentadas pelo Grupo de Pesquisa e Laboratório de Sistemas Inteligentes (Sintel) do Departamento de Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira - UNESP que estudaram e aplicaram essa técnica, como: Lopes (2005) (40), Lopes, Minussi e Lotufo (2005) (41), Marchiori (2006) (31), Moreno (2010) (32), Marchiori, Silveira, Minussi *et al.* (2011) (33),

Quanto à questão da evasão no ensino superior brasileiro, foram consultadas e consideradas as contribuições de vários pesquisadores - Lobo (2011) (13), Silva Filho *et al.* (2007) (14), Portela (2013) (16), Capelato (2011) (21), Barbosa (2010) (22), Baggi (2010) (42), Silva Filho e Lobo (2012) (7), Souza, Petró e Gessinger (2012) (43), Gaioso (2005) (44) - e também diversos documentos oficiais relativos à educação brasileira - relatórios e programas de políticas públicas sob responsabilidade do MEC, SESu, INEP e UNESCO (8-12, 17-20, 23) - para conhecer o panorama atual da educação no Brasil, as possíveis causas da evasão no ensino superior, as propostas de solução implantadas e os resultados obtidos.

Os modelos e teorias sobre a evasão escolar encontrados em Seidman (1996) (45), Spady (1970, 1971) (46, 47) Bean (1980, 1985) (48, 49), Bean e Metzner (1985) (50), Nora (1987, 2005) (51, 52), Cabrera *et al.* (1992) (53), e Tinto (1975, 1982, 1993, 1997, 2005, 2006) (54-59) contribuíram para a seleção das características dos estudantes que constituem os atributos dos vetores de entrada do sistema neural inteligente proposto.

Após a implementação do sistema e a análise das respostas obtidas, os resultados da pesquisa foram parametrizados com resultados encontrados na literatura, referenciados em Lykourantzou *et al.* (2009) (60), Mustafa, *et al.* (2012) (61).

Para situar esta pesquisa e perceber seu espaço dentre as produções científicas, realizou-se uma pesquisa bibliográfica quanto aos métodos preditivos de identificação de estudantes em risco de evasão no ensino superior presencial. Sendo esse um dos assuntos abordados no próximo capítulo.

REVISÃO BIBLIOGRÁFICA

*A primeira condição para modificar a realidade
consiste em conhecê-la.*

Eduardo Galeano

Neste capítulo, encontram-se descritos os resultados da pesquisa bibliográfica realizada na fase preliminar e exploratória desta investigação.

A pesquisa bibliográfica teve como objetivo perceber a lacuna em que se insere o objeto de estudo desta investigação. Ou seja, um sistema inteligente para predição da evasão escolar discente em cursos superiores presenciais utilizando a rede neural ARTMAP-*Fuzzy*, e situá-lo diante das produções da comunidade científica mundial, bem como, conhecer o estágio em que se encontram os estudos quanto aos métodos preditivos capazes de identificar estudantes em risco de evasão no ensino superior.

Outro assunto pesquisado e descrito neste capítulo diz respeito aos modelos e teorias sobre a evasão escolar no ensino superior e, complementarmente, algumas pesquisas que abordam o panorama da evasão no ensino superior brasileiro.

2.1 EVASÃO ESCOLAR NO ENSINO SUPERIOR BRASILEIRO

A maioria das referências encontradas na bibliografia pesquisada, no Brasil, apresenta os fatores que mais influenciam na evasão escolar em instituições e/ou cursos de ensino superior específicas. As referências mais relevantes que discutem de maneira mais abrangente o panorama do ensino superior brasileiro estão descritas a seguir:

- Na pesquisa desenvolvida por Gaioso (2005) (44) são investigadas as causas da repetência e da evasão nas instituições de ensino superior brasileiras sob a ótica dos dirigentes e dos estudantes. Parte de um levantamento bibliográfico sobre este tema e utiliza a entrevista

como técnica para coleta de informações dos sujeitos da pesquisa. Entende a evasão como sendo a interrupção no ciclo de estudos independentemente de sua causa. Em suas conclusões atribuiu como causas da evasão no ensino superior fatores relacionados aos estudantes, aos cursos e de caráter socioculturais, tais como: deficiência na educação básica, na didática dos professores e nos critérios de avaliação, repetências sucessivas, ingresso na faculdade por imposição, falta de orientação vocacional e dificuldade de adaptação no meio universitário, dificuldade financeira, casamento e nascimento de filho.

- No trabalho realizado por Silva Filho *et al.* (2007) (14) a evasão escolar no ensino superior brasileiro foi estudada do ponto de vista estatístico, baseada em dados oficiais do Censo da Educação Superior - Inep entre 2001 e 2005. Os autores apresentam dados internacionais e fazem a comparação com a realidade brasileira, demonstrando que os índices nacionais de evasão não estão muito diferentes das médias internacionais. Segundo o estudo, para o período supracitado, a média nacional da evasão no ensino superior foi de 22% ao ano, enquanto que nas instituições privadas foi de 26% e nas públicas de 12%. Sugere a existência de uma discreta correlação entre as causas da evasão e fatores socioeconômicos. Indica a necessidade de estudos sistemáticos com intuito de minimizar os índices da evasão evitando-se os desperdícios tanto sociais quanto financeiros (grifos da autora). Percebe-se que, depois de quase 10 anos, a situação da evasão no ensino superior brasileiro demonstrou uma evolução crescente, sugerindo que as medidas adotadas frente a situação não foram profícuas (comentário da autora).

- Baggi (2010) (42) realizou uma pesquisa bibliográfica nas produções acadêmicas na área da Educação registradas na Biblioteca Digital de Teses e Dissertações – BDTD, no período de 2000 a 2009. O objetivo central era perceber a relação existente entre o estudo da evasão escolar e a avaliação institucional. Constatou que a evasão no ensino superior é reflexo de todo processo de ensino que se inicia no ensino fundamental. O estudo revelou que as políticas públicas de ação afirmativa e compensatória que viabilizam o acesso do cidadão ao ensino superior mascaram a realidade, tendo em vista que não fazem o acompanhamento do estudante e, portanto, desconhecem as dificuldades enfrentadas para se manterem na instituição, contribuindo para o aumento no índice de evasão. Aponta a necessidade de fortalecer a avaliação institucional, pois acredita que ela poderá contribuir na identificação dos sinais da evasão possibilitando minimizá-la. O resultado da pesquisa indicou uma lacuna existente na reflexão teórica e metodológica sobre a evasão no ensino superior e a necessidade de programas específicos que proponham mudanças para o enfrentamento da situação (grifos

da autora).

- Souza, Petró e Gessinger (2012) (43) apresentam em seu trabalho o estado da arte sobre a evasão escolar no Brasil no período de 2000 a 2011, baseando-se nas produções acadêmicas em nível de mestrado e de doutorado constantes no *site* da Capes. Inicialmente, analisaram o foco central das pesquisas sobre evasão e constataram que os objetivos estão agrupados em: compreender as causas que levam o estudante à evasão numa determinada IES (64%); analisar historicamente o fenômeno da evasão (6%); investigar a relação entre os indicadores de satisfação dos estudantes com relação à determinada IES e a evasão (6%); conhecer o perfil do estudante que evade (12%); examinar quais cursos apresenta o maior índice de evasão (3%); desenvolver e analisar propostas de trabalho relacionadas à tecnologia com a intenção de diminuir os índices de reprovação e de evasão (9%). Posteriormente, identificaram quais os fatores mais frequentes indicados como causa da evasão no ensino superior, sendo eles: falta de condições financeiras, influência familiar, falta de vocação para a profissão, repetência em disciplinas que envolvem o conhecimento matemático, qualidade do curso e a localização da IES, condições relacionadas ao trabalho, idade do aluno (quanto maior a idade, mais fácil do aluno evadir). Outros fatores mencionados foram: insatisfação com o projeto pedagógico da instituição, professores, infraestrutura, recursos disponíveis, excesso de oferta de vagas, desemprego e as dificuldades na aprendizagem. Os resultados desta investigação evidenciam a necessidade de pesquisas com objetivo de propor e analisar alternativas para reduzir os índices de evasão, tendo em vista que a maioria dos estudos se restringe a conhecer as causas da evasão, sem indicar possíveis caminhos para enfrentar a situação (grifos da autora).

Nesses trabalhos foram apresentados o estado da arte sobre a evasão escolar no ensino superior brasileiro e uma síntese das análises e contribuições de vários pesquisadores sobre as causas da evasão. Bem como, a situação da Educação no Brasil a partir de dados estatísticos de escolas públicas, privadas e de pesquisa de órgãos governamentais, além de uma análise comparativa dos índices de evasão em nível nacional e internacional.

Percebe-se que as pesquisas apontam para a necessidade de novos programas, propostas e métodos para acompanhar e atender os estudantes, além de apresentarem mudanças eficazes frente ao fenômeno da evasão escolar no ensino superior brasileiro.

2.2 MÉTODOS PROPOSTOS PARA PREDIÇÃO DA EVASÃO ESCOLAR

Quanto à questão dos métodos de predição e análise da evasão escolar foram encontradas poucas referências na literatura consultada, sendo as mais pertinentes e relevantes ao foco de desenvolvimento desta pesquisa apresentadas na sequência.

- Karamouzis e Vrettos (2008) (62) realizaram uma pesquisa com objetivo de prever a taxa de aprovação dos estudantes nos dois primeiros anos dos cursos de graduação e a sua continuidade na faculdade. Os pesquisadores utilizaram uma rede neural *Multilayer Perceptron* (MLP) com três camadas, com treinamento via algoritmo de retropropagação. Com informações demográficas e acadêmicas, coletadas no momento da inscrição, criaram o perfil dos estudantes composto por 12 parâmetros. Os parâmetros utilizados foram: etnia, sexo, intenção de se matricular na faculdade, idade, escola de origem no ensino médio, o estudante necessita de atendimentos especiais/deficiência?, o estudante necessita de apoio/reforço acadêmico?, CEP, endereço, idade com que terminou o ensino médio, tempo de dedicação para a faculdade e você é um estudante bem sucedido? O vetor de entrada da rede foi constituído por estes 12 parâmetros representativos do perfil dos estudantes. Após o treinamento da rede testaram-na com o próprio conjunto de treinamento e, em seguida, com o conjunto de teste, obtiveram um taxa média de acerto de 72% e 68%, respectivamente.

- Na pesquisa realizada por Jadrić, Garača e Ćukušić (2010) (63), os autores testaram e compararam três técnicas de mineração de dados para identificar a desistência dos estudantes nos dois primeiros anos da graduação em um curso de Economia. Os modelos de classificação usando árvore de decisão, regressão logística e redes neurais foram desenvolvidos baseados na metodologia SEMMA (*Sampling, Exploring, Modifying, Modelling and Assessment*). A base de dados para o estudo é composta por dados coletados na inscrição do candidato e atributos referentes ao processo de estudo, num total de vinte e quatro variáveis. Após a aplicação da metodologia, a rede neural apresentou um melhor desempenho em relação aos outros modelos, apontando que 36% dos estudantes poderão evadir. A pesquisa também apontou e separou as causas da evasão e delineou o perfil típico do estudante propenso a desistir da faculdade.

- Desenvolver um método de previsão de desempenho como critério para seleção e admissão de candidatos aos cursos de engenharia foi o objetivo do estudo conduzido por Oladokun, Adebajo e Charles-Owaba (2008) (64). Utilizaram uma rede neural MLP com

duas camadas escondidas e cinco neurônios por camada. A base de dados foi construída com informações de cinco gerações de graduandos. As variáveis que compuseram o vetor de entrada da rede foram selecionadas a partir dos registros de inscrição do candidato. Essas variáveis são: média final do ensino médio, resultados nas disciplinas de matemática, linguagem, física e química, notas em outras ciências, idade do aluno no momento da inscrição, tempo decorrido entre formação no ensino médio e admissão da universidade, escolaridade dos pais, escola de origem do ensino médio, tipo de ensino médio, local da universidade, local da residência e sexo. Os resultados indicam que a rede neural utilizada atingiu uma precisão global média de 74% de acertos na classificação dos candidatos em bons, médios e ruins. Observa-se que o objetivo da utilização do sistema de predição proposto nesse trabalho é a seleção de melhores candidatos para admissão na faculdade de engenharia, melhorando os índices de desempenho na avaliação do curso (comentário da autora).

- O índice de desistência em torno de 40% entre os calouros do Curso de Engenharia motivou Dekker, Pechenizkiy e Vleeshouwers (2009) (65) a desenvolverem um estudo experimental na busca de um método de predição da evasão. Na realização da pesquisa aplicaram e testaram modelos baseados nos classificadores WEKA, árvores de decisão, e um classificador Bayesiano. Consideraram três conjuntos de dados: somente dados pré-universitários contendo informações, principalmente, sobre o desempenho no ensino médio (13 atributos), somente dados universitários (74 atributos) e um conjunto completo dos dados. Os resultados mostraram que um dos modelos de árvore de decisão aplicados atingiu uma precisão de 68% quando analisou somente os dados pré-universitários. Analisando o conjunto completo dos dados o método obteve precisão entre 75% e 80% na identificação da evasão.

- Em um estudo realizado por Hanewicz (2009) (66) a análise espacial por meio da tecnologia GIS (*Geographic Information Systems*) foi utilizada para identificar padrões de retenção de estudantes universitários. A base de dados constituía-se do endereço dos estudantes, que depois de mapeados e analisados identificavam os estudantes que abandonaram a instituição de ensino, mantiveram-se matriculados ou se graduaram após seis anos de matrícula. Este estudo contribuiu para que os gestores do ensino superior pudessem conhecer e compreender os estudantes a fim de satisfazer suas necessidades e, assim, mantê-los na instituição.

- Fu *et al.* (2012) (67) empregaram a regressão de vetores de suporte (SVR), uma técnica da aprendizagem de máquina, para construir um modelo de previsão de desempenho acadêmico baseado nas características de personalidade dos estudantes. A base de dados de

entrada da máquina de vetor de suporte (SVM) foi composta por dados biográficos (3 itens), perfil da personalidade (5 itens) e desempenho acadêmico do ensino médio - GPA (*Grade Point Average*). Os dados foram coletados por meio de questionários. O modelo proposto obteve uma precisão próxima de 80% na previsão de desempenho dos estudantes.

- A pesquisa realizada por Lykourantzou *et al.* (2009) (60) teve como foco investigar e identificar o grupo de estudantes com propensão à evasão em estágios iniciais de cursos *e-learning*. Os pesquisadores utilizaram, individualmente, três técnicas de aprendizagem de máquina: rede neural *feedforward*, máquina de vetor de suporte (SVM) e rede neural ARTMAP-*Fuzzy* simplificada. Em seguida, fizeram esquemas de combinações entre as técnicas. Os dados utilizados são características demográficas e atributos dos estudantes com informações detalhadas de suas atividades e de seu progresso. Essas características foram coletadas de maneira totalmente eletrônicas, permitindo fazer previsões de forma dinâmica e adaptá-las de acordo com os níveis de desempenho de cada estudante e de sua participação ao longo do curso. Na análise dos resultados a técnica que obteve melhor desempenho quanto à rapidez, sensibilidade e precisão na previsão de estudantes propensos à evasão foi o esquema de decisão. Entre a aplicação dos métodos aplicados individualmente e os esquemas de combinações a taxa global de precisão alcançada foi de 40% a 50% quando utilizaram somente as características demográficas e entre 75% e 85% quando utilizaram todos os atributos dos estudantes. Os pesquisadores sugerem que futuras investigações possam aplicar o método proposto para a previsão de evasão de estudantes em outros tipos de cursos, dentre eles a educação clássica (grifo da autora).

- O objetivo da pesquisa desenvolvida por Mustafa, Chowdhury e Kamal (2012) (61) foi desenvolver um modelo dinâmico de previsão de evasão discente para as universidades. A base de dados foi composta por quatro fatores: sexo, situação financeira, período do curso que evadiu, se possui alguma deficiência. Utilizaram técnicas de mineração de dados, árvores de classificação e regressão (CART) e árvores CHAID, para classificar a situação dos estudantes em sucesso e insucesso. Após a análise dos resultados concluíram que a utilização das árvores apenas com os dados da inscrição dos candidatos não são boas para identificar a evasão. As taxas de precisão das árvores de classificação não foram significativas, sendo 38,1% com a árvore CHAID e 28,57% com a árvore CART. Os autores sugerem acrescentar outros fatores como idade, etnia, situação de trabalho, ambiente de estudo e tipo de educação para melhorar o desempenho.

Com relação aos métodos de predição da evasão escolar o cenário foi construído e

descrito diante das referências encontradas na bibliografia pesquisada. Constatou-se que não foi encontrada na literatura consultada nenhuma proposta para predição da evasão escolar com as características do sistema proposto e desenvolvido nesta pesquisa.

Ressalta-se, mais uma vez, que a pertinência e a pujança científica desta pesquisa estão na utilização de uma Rede Neural ARTMAP-*Fuzzy*, com uma base de dados composta essencialmente por dados da inscrição do candidato, como possibilidade de identificar os estudantes do ensino superior presencial propensos à evasão.

2.3 SÍNTESE DOS MODELOS DA EVASÃO ESCOLAR

A seleção dos atributos que compõem a base de dados do sistema desenvolvido para predição da evasão em cursos superiores foi realizada com base na análise compreensiva dos modelos da evasão escolar, encontrados na literatura pesquisada. Uma síntese destes modelos está apresentada na Tabela 5.

Tabela 5 - Síntese dos modelos da evasão escolar.

	Autores (Ano)	Identificação do Modelo	Características	Detalhamento das Variáveis/Atributos relevantes a esta pesquisa	Atributos desta Pesquisa correlacionados aos Modelos
Abordagens Sociológicas	Spady (1970, 1971)	Modelo do Processo da Evasão	<ul style="list-style-type: none"> • Demográficas • Histórico familiar • Potencial acadêmico • Congruência normativa 	<ul style="list-style-type: none"> - Sexo - Idade - Educação religiosa dos pais - Escolaridade dos pais - Origem (urbana/rural) - Desempenho nas notas - Apoio de amigos - Integração social - Atitudes - Aspirações - Autoconceito 	<ul style="list-style-type: none"> - Sexo - Idade - Escolaridade dos pais - Procedência (urbana/rural) - Autoavaliação
	Tinto (1975, 1993, 1997)	Modelo de Integração e Desgaste do Estudante	<ul style="list-style-type: none"> • Atributos individuais • Histórico familiar • Escolaridade no ensino médio • Personalidade 	<ul style="list-style-type: none"> - Etnia - Sexo - Habilidades acadêmicas - Relacionamentos sociais - Status socioeconômico - Ambiente familiar - Comprometimento emocional 	<ul style="list-style-type: none"> - Etnia - Sexo - Renda familiar - Tem computador - Autoavaliação

	Autores (Ano)	Identificação do Modelo	Características	Detalhamento das Variáveis/Atributos relevantes a esta pesquisa	Atributos desta Pesquisa correlacionados aos Modelos
	Braxton <i>et al.</i> (2004)	Modelo da Desistência do Estudante em Tempo Integral	<ul style="list-style-type: none"> • Características do estudante • Ambiente externo • Ambiente no Campus • Integração acadêmica 	<ul style="list-style-type: none"> - Educação dos pais - Finanças - Trabalho - Família - Dependentes 	<ul style="list-style-type: none"> - Escolaridade dos pais - Renda familiar - Situação de Trabalho - Número de pessoas /residência
	Nora <i>et al.</i> (2005)	Modelo do Comprometimento Estudante-Instituição	<ul style="list-style-type: none"> • Fatores psicológicos • Necessidade financeira • Apoio familiar • Demandas ambientais • Experiências acadêmicas e sociais • Desenvolvimento intelectual e não cognitivo 	<ul style="list-style-type: none"> - Responsabilidades familiares - Responsabilidades profissionais - Deslocamento - Autoestima 	<ul style="list-style-type: none"> - Renda familiar - Estado civil - Situação de Trabalho - Número de pessoas /residência - Autoavaliação - Meio de transporte - Distância escola-residência
Abordagens Psicológicas	Bean (1980) Bean e Metzner (1985)	Modelo de Desgaste de Estudantes não Tradicionais	<ul style="list-style-type: none"> • Individuais • Acadêmicas • Ambientais • Integração social • Resultados acadêmicos e psicológicos 	<ul style="list-style-type: none"> - Idade - Sexo - Etnia - Horas de trabalho - Responsabilidades com a família - Tempo de dedicação ao estudo - Habilidades de estudo 	<ul style="list-style-type: none"> - Idade - Sexo - Etnia - Situação de trabalho - Estado civil - Turno de estudo - Renda familiar
	Pascarella (1980)	Modelo de Desgaste	<ul style="list-style-type: none"> • Características das experiências do estudante • Fatores institucionais • Experiências universitárias 	<ul style="list-style-type: none"> - Atitudes - Valores e interesses - Salas de aula - Atividades de lazer - Interação com colegas - Padrões de admissão - Tamanho da instituição 	<ul style="list-style-type: none"> - Número de estudantes /sala - Turno de estudo
	Astin (1984)	Modelo do Envolvimento do Estudante	<ul style="list-style-type: none"> • Características dos estudantes • Características do programa 	<ul style="list-style-type: none"> - Idade - Sexo - Etnia - Desempenho no ensino médio - Experiências educacionais - Integração professores e colegas 	<ul style="list-style-type: none"> - Idade - Sexo - Etnia - Escola de origem

Fonte: Elaborada pela autora a partir dos Modelos encontrados na literatura consultada.

Na coluna detalhamento das variáveis, da Tabela 5, foram inseridos basicamente os atributos relevantes para esta pesquisa. As variáveis destacadas em azul, na Tabela 5, contribuíram para a escolha das variáveis consideradas preditoras da evasão e compõem o vetor de entrada do sistema de previsão da evasão.

O sistema desenvolvido baseia-se na utilização de uma rede neural da família ART, a rede neural ARTMAP-*Fuzzy*, portanto, faz-se necessário aprender, compreender e assimilar sobre essa família de redes neurais, suas potencialidades e limitações, sendo este o assunto abordado no capítulo seguinte.

REDES NEURAIIS ARTIFICIAIS

*É fazendo que se aprende a fazer
aquilo que se deve
aprender a fazer.*

Aristóteles

Neste capítulo, inicialmente, tratar-se-á, de maneira genérica, das redes neurais artificiais. Seu conceito, características, arquiteturas, tipos de treinamento, vantagens e aplicações serão sucintamente descritos. Em seguida, de maneira mais detalhada, a Teoria da Ressonância Adaptativa (*Adaptive Resonance Theory* - ART) será abordada. As redes que compõem a família ART serão apresentadas e os algoritmos das redes ART serão descritos.

Nesta pesquisa, para inferir sobre os estudantes propensos à evasão, foi utilizada a Rede Neural ARTMAP-*Fuzzy*, uma arquitetura de rede da família ART, auto-organizável e com aprendizagem supervisionada. Sendo assim, esta rede será evidenciada e minuciosamente detalhada no decorrer deste capítulo.

3.1 REDES NEURAIIS ARTIFICIAIS

As redes neurais artificiais (RNA) ou, simplesmente, redes neurais (RN), uma das técnicas da Inteligência Artificial (IA) (68), são modelos matemáticos computacionais que emulam o cérebro humano e adquirem conhecimento através de um processo de aprendizagem, ou seja, elas “aprendem” através da experiência (27, 69-75).

De maneira geral as redes neurais constituem-se em um paradigma de sistema de processamento e transmissão de informação inspirado no sistema neural biológico. São compostas por um grande número de elementos de processamento (neurônios artificiais), altamente interconectados (sinapses neurais artificiais), paralelamente distribuídos e funcionando em uníssono para realizar uma tarefa particular ou resolver problemas específicos, complexos ou intratáveis (27).

Dentre as características das redes neurais artificiais que as tornam aptas a desempenhar um comportamento inteligente, imitando o cérebro humano, destacam-se:

- Capacidade de generalização: permite que a RNA, após o treinamento, seja capaz de generalizar o conhecimento apreendido, possibilitando estimar resultados precisos para padrões de entrada que não estavam contidos no conjunto de dados de treinamento;
- Capacidade de aprendizagem continuada: algumas redes, em especial, são capazes de aprender novos padrões sem perder o conhecimento adquirido anteriormente;
- Robustez e tolerância a falhas: mesmo que alguns neurônios sejam eliminados da estrutura da rede ou mesmo algumas informações fornecidas de maneira incompleta, ausente, contraditória ou com ruídos é possível obter uma resposta correta, tendo em vista o alto nível de interconexão entre os neurônios;
- Armazenamento distribuído do conhecimento: o conhecimento do processo é armazenado de maneira distribuída entre as sinapses dos neurônios da rede, tornando-a mais tolerante a falhas em neurônios individualmente danificados;
- Aprendizagem por experiência: os pesos sinápticos são ajustados baseados na apresentação sucessiva de padrões, possibilitando a aprendizagem e a aquisição de conhecimento através da experimentação e exemplos;
- Paralelismo: neurônios fortemente interconectados e operantes ao mesmo tempo produzem resultado com elevado desempenho computacional.

Uma rede neural típica consiste de vários neurônios, arranjados 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 RN.

As redes neurais possuem sempre uma camada de entrada, responsável pelo recebimento de informações advindas do meio externo, e uma camada de saída que produz e apresenta os resultados finais da rede. Entre as camadas de entrada e saída da rede pode haver um número variável de camadas, denominadas camadas ocultas, escondidas ou intermediárias. Nelas é realizado grande parte do processamento da rede.

Os dados de entrada de uma rede neural são multiplicados pelos pesos sinápticos e em seguida é realizada a soma ponderada. A saída dos neurônios é obtida por meio de uma

função de ativação, podendo ser esta parcialmente diferenciável (função degrau, bipolar ou rampa simétrica), ou totalmente diferenciável (função linear, sigmoidal ou gaussiana).

A maneira como os neurônios de uma rede neural estão dispostos ou estruturados entre si, através da direção das conexões sinápticas, define a arquitetura da rede. Basicamente, existem três tipos de classes de arquiteturas diferentes (24):

- Redes *feedforward* de uma única camada: todas as sinapses se ligam somente aos neurônios da camada seguinte, sendo rigorosamente alimentada adiante ou acíclica;
- Redes *feedforward* de múltiplas camadas: além de ter a camada de entrada e de saída, também possui uma ou mais camadas intermediárias, sendo alimentadas sempre para frente;
- Redes Recorrentes: tem pelo menos um ciclo de realimentação, podendo ter sinapses com os neurônios da mesma camada (*feed-lateral*) e com os da camada anterior (*feedback*).

As composições estruturais de uma rede, quanto ao número de neurônios em cada camada e a função de ativação de cada neurônio, após definida sua arquitetura, diz respeito à topologia da rede neural.

A maneira como os neurônios de uma rede estão estruturados está estreitamente relacionada com o algoritmo de aprendizagem usado para treiná-la (27).

Analogamente ao sistema biológico, a aprendizagem das redes neurais requer ajustes nas conexões sinápticas que existem entre os neurônios. A aplicação de procedimento e regras ordenadas para se fazer os ajustes dos pesos sinápticos, consiste no processo de treinamento da rede. O conjunto desses procedimentos e regras ordenadas, utilizadas para realizar o processo de aprendizagem, é denominado “algoritmo de aprendizagem”, cuja função é modificar os pesos sinápticos da rede de maneira ordenada para alcançar o objetivo desejado (27).

Os principais modelos de processos de treinamento e aprendizagem em redes neurais são (27, 40, 72):

- Treinamento Supervisionado: a base de dados para o treinamento consiste em pares de vetores entrada/saída, contendo as informações de entrada e sua respectiva saída desejada. Ocorre o aprendizado quando, após o processamento, a

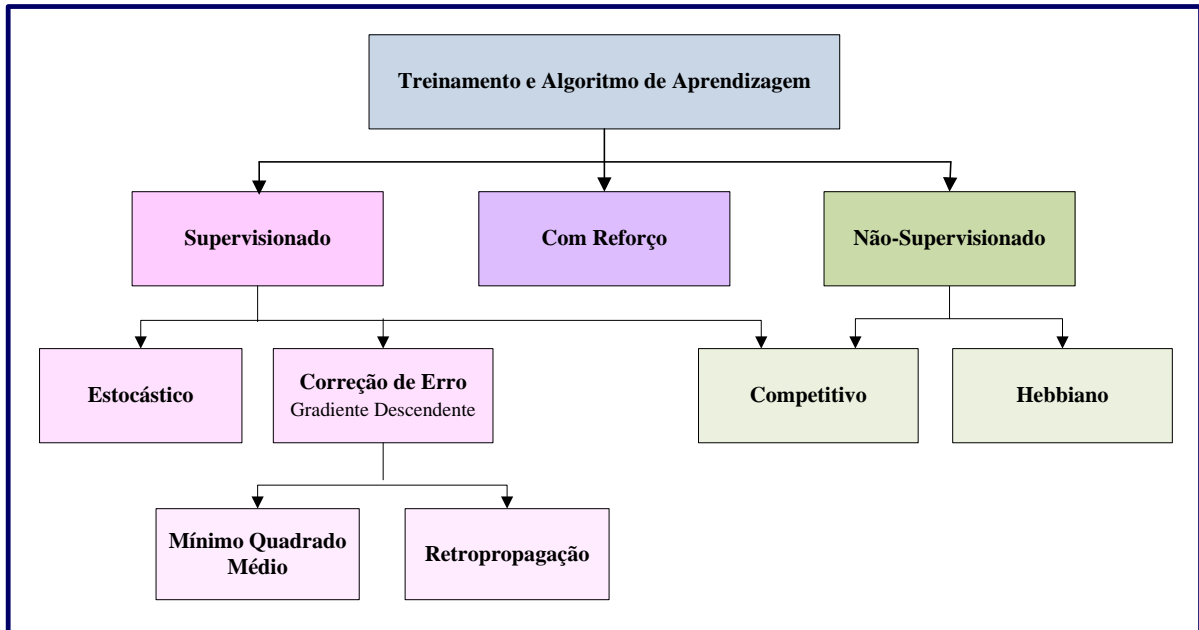
saída da rede for igual à saída desejada. Caso isso não ocorra, a rede deverá ajustar os pesos sinápticos e repetir todo o processamento até obter a saída desejada.

- **Treinamento Não-supervisionado:** não existe a saída desejada, a base de dados para o treinamento é composta exclusivamente pelos vetores de entrada da rede. Neste paradigma, a rede é autônoma e se auto-organiza para efetuar a classificação dos padrões de entrada. Os pesos sinápticos são ajustados internamente, pelo algoritmo de aprendizado, de modo a corroborar a classificação.
- **Treinamento Competitivo:** é um tipo de treinamento supervisionado, ou seja, existe uma saída desejada. Porém, a rede possui vários neurônios na camada de saída e quando um padrão de entrada é apresentado à rede os neurônios da saída competem entre si, prevalecendo apenas um neurônio que definirá a saída desejada.
- **Treinamento com Reforço:** o processo de treinamento ocorre por tentativa e erro. É avaliada a defasagem da resposta produzida pela rede com a saída desejada. Se for satisfatória, os pesos sinápticos são gradualmente incrementados com o objetivo de reforçar a condição do sistema.
- **Treinamento Híbrido:** o ajuste dos pesos é realizado através de uma combinação dos paradigmas de treinamento supervisionado e não-supervisionado.

Esses paradigmas de treinamento são classificados em função da presença ou ausência de tutor e das informações fornecidas para o sistema aprender. Alguns algoritmos de aprendizagem utilizados nos treinamentos das redes neurais são: aprendizagem por correção de erro (gradiente descendente), hebbiana, estocástica e aprendizagem competitiva. Considera-se que ocorreu o aprendizado em uma rede neural quando se atinge uma solução generalizada para uma dada situação problema.

Uma representação hierárquica do tipo de treinamento e o algoritmo de aprendizagem utilizado para aprendizagem da rede neural é mostrada na Figura 8.

Figura 8 - Representação dos treinamentos e algoritmos de aprendizagem das redes neurais.



Fonte: Elaborada pela autora.

Esta habilidade de aprender e, conseqüentemente, de generalizar o aprendizado e a estrutura maciçamente paralelamente distribuída de uma rede neural, possibilita-a resolver problemas complexos, atualmente intratáveis (27).

As RNA's mais conhecidas, resumidamente, são: Adaline (*Adaptive Linear Neural Element*), ART, Máquinas Boltzmann (*Boltzmann Machine*), Máquinas Cauchy (*Cauchy Machine*), Rede Hopfield, LVQ (*Learning Vector Quantization*), Perceptron, RBF (*Radial Basis Function*), RNN (*Recurrent Neural Network*), SOM (*Self-Organizing Map*), GRNN (*General Regression Neural Networks*).

As RNA's apresentam certas propriedades e capacidades que são únicas e inerentes às suas estruturas, tornando-as úteis e vantajosas aos sistemas que as utilizam (27, 32,40), quais sejam:

- Não-linearidade: é um atributo do neurônio artificial, sendo que na aplicação prática as redes neurais oferecem uma alternativa analítica muito importante para as situações onde o sinal de entrada a ser analisado advém de dispositivos não-lineares, como por exemplo sinais de voz;
- Mapeamento de entrada-saída: gerado a partir da aprendizagem por meio de exemplos, sendo possível classificar um novo padrão apresentado à rede. Ocorre

na aplicação do paradigma de aprendizado supervisionado, que promove o ajuste dos pesos das conexões sinápticas da rede, considerando a comparação entre os pares de vetores, de entrada e de saída desejada, apresentados à rede neural;

- Aprendizado e generalização: são capazes de apresentar resultados precisos e sensíveis por meio da aprendizagem e do armazenamento de conhecimento;
- Processamento paralelo: possibilita a execução de tarefas complexas com maior rapidez e, portanto, alto desempenho computacional;
- Robustez: a rede neural processa dados ruidosos (errôneos ou com variações aleatórias), incompletos ou faltantes de maneira segura e com resultados corretos;
- Flexibilidade: as RN são técnicas flexíveis por possibilitar uma vasta aplicabilidade em qualquer área do conhecimento;
- Adaptabilidade: as RNA's são dotadas de uma capacidade natural que propicia a adaptação de seus parâmetros, em resposta a mudanças no ambiente a sua volta, por meio de um novo treinamento. Porém, isso pode gerar um problema conhecido como o dilema da estabilidade-plasticidade. Uma possibilidade de solução deste problema é a utilização das redes da família ART.

A capacidade de aprender e de generalizar o conhecimento apreendido que as redes neurais artificiais possuem favorecem sua aplicação na solução de diversas situações problemas altamente complexas e em diversas áreas do conhecimento. Destaca-se como suas principais aplicações:

- “Clusterização” ou agrupamento de dados;
- Reconhecimento e classificação de padrões;
- Processamento de imagens;
- Aproximação de funções;
- Regressão;
- Controle;
- Otimização;
- Diagnóstico;
- Sistemas de predição.

Os sistemas de predição desempenham a função de prever valores futuros de dados em uma sequência de tempo. Podem ser dinâmicos e produzir resultados diferentes para os mesmos dados de entrada com base no estado do sistema, ou seja, o tempo. A predição exerce um impacto significativo nos sistemas de apoio às decisões. É nessa perspectiva que esta pesquisa foi delineada, encaminhada e desenvolvida, visando à predição dos grupos de risco à evasão escolar para que se possa, de maneira proativa, agir para atenuar tal situação.

Para a concretude dessa proposta e desenvolvimento do sistema de predição e diagnóstico dos estudantes propensos a evasão escolar, em que os dados são complexos, subjetivos, não-lineares e inter-relacionados, a técnica usada foi a rede neural ARTMAP-*Fuzzy*. Constitui-se em uma das redes da família ART, baseadas na teoria da ressonância adaptativa. Essas redes são auto-organizáveis, com treinamento supervisionado, baseada no algoritmo de aprendizagem competitivo, e possibilidade de manter um treinamento continuado. Essa ferramenta é capaz de lidar com dados complexos, não-lineares, imprecisos, incoerentes, ausentes ou ruidosos e, ainda, apresentar precisão no resultado desejado e maior rapidez.

Considerando essa perspectiva, na sequência serão abordadas a teoria da ressonância adaptativa (ART) e algumas das redes da família ART, mais especificamente as redes ART, ARTMAP, ART-*Fuzzy* e ARTMAP-*Fuzzy*.

3.2 TEORIA DA RESSONÂNCIA ADAPTATIVA (ART)

A Teoria da Ressonância Adaptativa foi proposta por Stephen Grossberg em 1976, como uma teoria do processamento de informação cognitiva humana, baseada na fisiologia do sistema nervoso.

Em seus trabalhos (76, 77) tinham como objetivo a busca de solução para o dilema da plasticidade-estabilidade, um dos problemas apresentados pelas redes neurais artificiais. Para tanto, pesquisavam para compreender: 1) como um sistema de aprendizagem é capaz de manter sua plasticidade (capacidade de aprender padrões ainda não conhecidos, mantendo a memória dos padrões aprendidos anteriormente) e, ao mesmo tempo, preservar a estabilidade dos padrões anteriores; 2) como o sistema pode ser flexível a ponto de conservar o conhecimento adquirido e armazenar novas informações e 3) como o sistema pode deliberar e decidir sobre a prioridade entre a condição de plasticidade e estabilidade (dilema da

plasticidade-estabilidade) sem comprometer seu desempenho e robustez.

A solução apresentada para o dilema foi o desenvolvimento da arquitetura da rede neural ART. Constituindo-se em um sistema de treinamento não-supervisionado, com algoritmo de aprendizagem competitivo, baseado na teoria da ressonância adaptativa (ART) (36, 78-80).

Em redes neurais, o termo "ressonância" diz respeito ao estado de uma rede neural em que um conjunto de dados, previamente armazenados em uma categoria (vetor padrão), possui uma correspondência muito próxima ou um "casamento" com o conjunto de dados de entrada atual (vetor de entrada) da rede neural. Essa correspondência ou "casamento" levam as redes da família ART ao estado de ressonância, o que permite a aprendizagem, ou seja, as redes ART's só aprendem em seu estado de ressonância.

O grau de semelhança entre os dados do vetor padrão e do vetor de entrada determina uma regra de similaridade que define o agrupamento dos dados nas categorias de saída.

As redes neurais cuja dinâmica de interação entre os processos de aprendizagem e de reconhecimento de informações se baseiam na teoria da ressonância adaptativa compõem um conjunto de redes neurais, conhecido como família ART.

Todos os sistemas de redes neurais da família ART são capazes de solucionar o dilema estabilidade-plasticidade (81), ou seja, são capazes de aprender novos padrões mantendo o conhecimento anteriormente apreendido, sem comprometer a estabilidade do sistema. Este processo é realizado através do teste de vigilância e do ajuste dos pesos.

Portanto, as principais características das redes ART são a plasticidade e a estabilidade. A plasticidade está relacionada com a adaptabilidade/flexibilidade, ou seja, o sistema deve ser adaptativo/flexível para absorver as mudanças que ocorrem no ambiente. Esta característica consiste na capacidade de aprender novos padrões, preservando a memória dos padrões apreendidos anteriormente. A estabilidade é a capacidade de preservar os conhecimentos adquiridos anteriormente e assegurar o agrupamento de padrões similares na mesma categoria de reconhecimento criadas pelo sistema, por meio do ajuste dos pesos.

Outra característica do sistema ART é a auto-organização, isto é, de maneira autônoma o sistema auto-organiza os padrões de entrada da rede em categorias de reconhecimento. Neste processo um novo padrão de entrada, a ser categorizado, é comparado com a representação de uma categoria já existente.

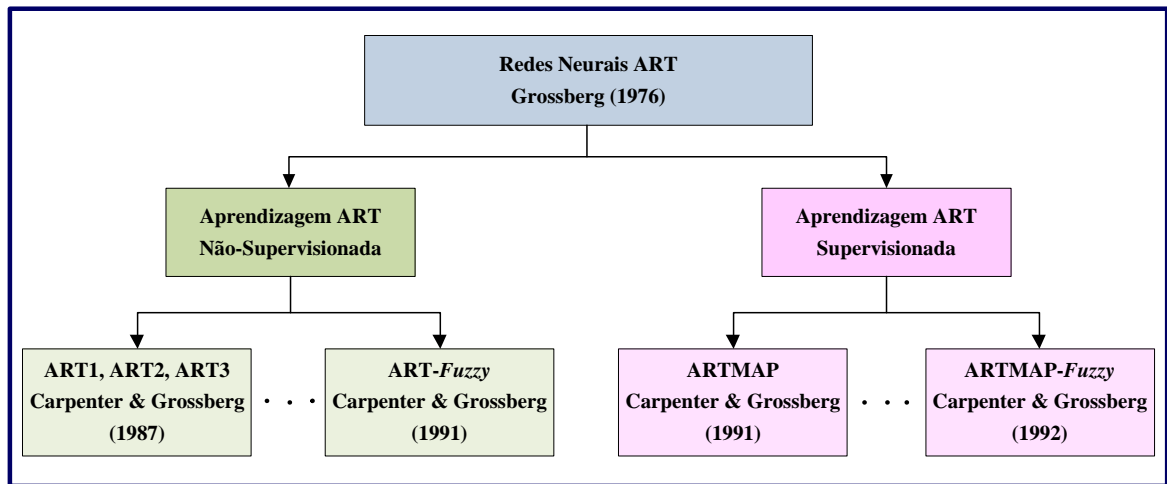
As redes ART podem se auto-organizar, em tempo real, aprendendo continuamente e produzindo categorias de reconhecimento estáveis, em resposta a sequências aleatórias de padrões de entrada (26), proporcionando convergência rápida e múltipla generalização.

A família ART possui vários modelos de redes neurais, dentre eles estão:

- ART1 (1987): a mais simples das redes ART, aceita apenas padrões de entradas binárias (36, 80);
- ART2 (1987): amplia as capacidades da rede para suportar também padrões de entradas contínuos/analógicos (82, 83);
- ART3 (1990): é o refinamento da ART 1 e ART 2, considera a ação dos neurotransmissores nos mecanismos de sinapse (84);
- ART-*Fuzzy* (1991): implementa a lógica *Fuzzy* no reconhecimento de padrão das redes ART, assim aumenta a habilidade de generalização. Uma característica muito útil da ART-*Fuzzy* é a codificação do complemento, um meio de incorporar a ausência de características nas classificações de padrão, isso no sentido de impedir a proliferação de categorias ineficientes e desnecessárias (25, 85);
- ARTMAP (1991): conhecida como ART preditiva, combina duas redes ART's um pouco modificadas, pode ser dois módulos de ART₁ ou dois módulos de ART₂ em uma estrutura de aprendizado supervisionado. O primeiro módulo recebe os dados de entrada e o segundo recebe os dados das saídas desejadas, então, é usada para fazer o ajuste mínimo possível do parâmetro de vigilância na primeira unidade, a fim de fazer a classificação correta. Emprega padrões de entrada binários ou contínuos / analógicos (37);
- ARTMAP-*Fuzzy* (1992): rede preditiva, baseada na lógica *Fuzzy* ou conceitos nebulosos, com treinamento supervisionado (24, 38).

Essas redes utilizam tanto a aprendizagem supervisionada quanto a não-supervisionada, conforme Figura 9.

Figura 9 - Classificação das redes da família ART quanto à aprendizagem.



Fonte: Elaborada pela autora.

3.2.1 Rede Neural ART Básica

A Rede Neural ART1 é a mais simples das Redes ART. Ela é competitiva, auto-organizável, aprende de maneira não-supervisionada e aceita apenas entradas binárias.

A estrutura básica de uma rede neural ART, mostrada na Figura 10, consiste de dois subsistemas, o subsistema de atenção e o de orientação (36, 81). Nestes subsistemas estão dispostos e interligados duas camadas de neurônios (F_1 e F_2) e seus pesos sinápticos (W_{ij} e V_{ji}), o módulo do teste de vigilância (ρ) e o módulo de *reset* (nó de rejeição).

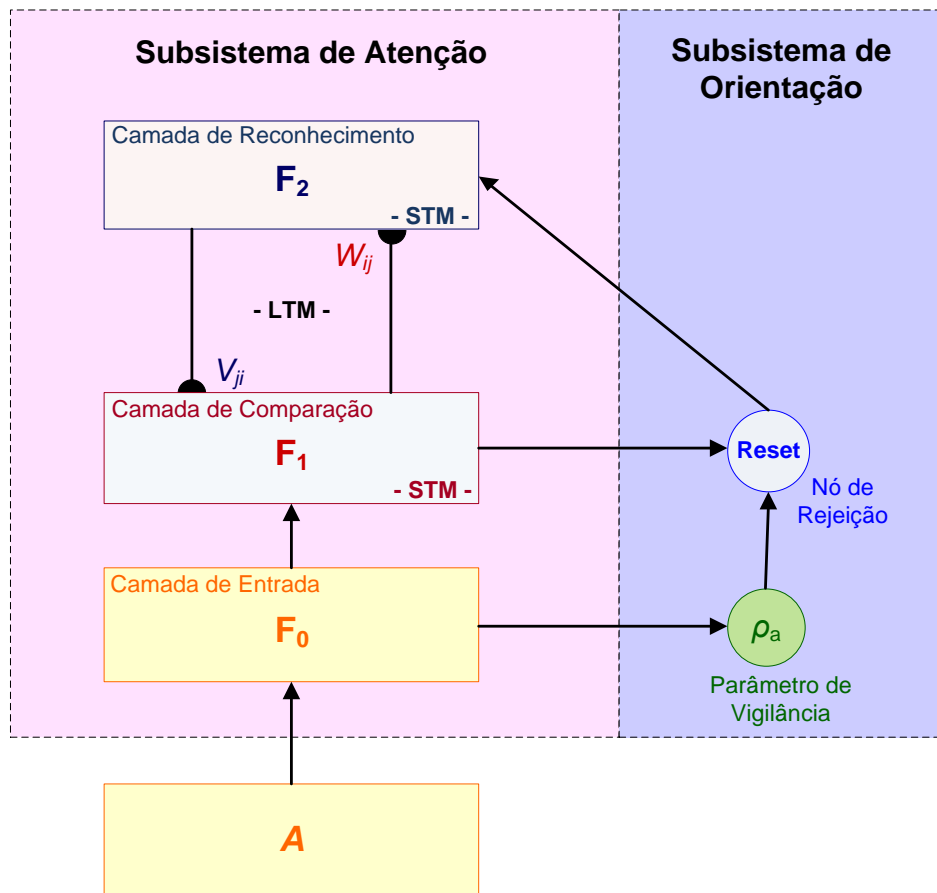
Os subsistemas de atenção e de orientação são complementares e se interagem para realizar o processamento dos padrões de entrada.

O subsistema de atenção é constituído por duas camadas de neurônios, a camada de comparação (F_1) e a camada de reconhecimento de padrões (F_2) e pela camada de entrada (F_0) que exibe o vetor de entrada atual A . Os neurônios das camadas F_1 e F_2 são totalmente interconectados através dos pesos *bottom-up* (W_{ij}) e *top-down* (V_{ji}), denominados de memória de longo prazo (*long-term memory*). As conexões de baixo para cima (*bottom-up*), de F_1 para F_2 , são conexões diretas (*feedforward*) e as conexões de cima para baixo (*feedback*), de F_2 para F_1 , são recorrentes (26).

O processamento dos padrões de entrada entre os nós das camadas F_1 e F_2 é realizado por meio de uma memória de curto prazo (*short-term memory* - STM), gerando respostas e representações internas mais acuradas desses padrões, em seu estado de ressonância. A

aprendizagem da rede ocorre durante seu estado ressonante (26).

Figura 10 - Estrutura básica da rede neural ART.



Fonte: Adaptado de Lopes (2005) (40).

O subsistema de orientação é indispensável para estabilizar o processo de ressonância na memória de curto prazo (STM) e, conseqüentemente, a aprendizagem na memória de longo prazo (LTM), permitindo que a rede aprenda novos padrões de entrada conservando os conhecimentos adquiridos anteriormente.

O subsistema de orientação inibe o subsistema de atenção quando um padrão desconhecido é apresentado à rede e realiza os processos de ressonância e *reset*. O módulo *reset* controla a dinâmica do subsistema de atenção baseado no parâmetro de vigilância (ρ). Enquanto que, o parâmetro de vigilância (ρ possui valor decimal compreendido entre 0 e 1) determina o grau de similaridade entre os vetores padrões de entrada e os pesos sinápticos de F_1 e F_2 , definindo se certo padrão de entrada desconhecido pode ser representado em uma das categorias pré-existentes.

Os nós na camada de reconhecimento (F_2) representam as categorias ou grupos (*clusters*) formados. Quando a rede se estabiliza, os pesos *top-down* (V_{ji}) correspondentes a cada nó em F_2 representam um vetor protótipo para esse nó.

A camada de comparação (F_1) recebe o vetor de entrada e transfere-o para a camada de reconhecimento (F_2), buscando o seu melhor “casamento” ou combinação. O melhor “casamento” acontece quando encontra um único neurônio, cujo conjunto de pesos corresponde o mais próximo do vetor de entrada.

No processo de categorização em um sistema ART, a categoria vencedora é apresentada pelo subsistema de atenção, enquanto que, o subsistema de orientação aceita a categoria indicada ou aciona a busca para a escolha de uma nova categoria, apropriada para o agrupamento da amostra apresentada.

Para o desenvolvimento dos processos de aprendizagem e categorização das redes neurais da família ART, alguns parâmetros são fundamentais, quais sejam:

- Parâmetro de escolha α ($\alpha > 0$): é responsável pela seleção de categorias;
- Parâmetro de vigilância ρ ($\rho \in [0, 1]$): monitora a ressonância da rede, sendo responsável pelo número de categorias criadas na camada F_2 e, conseqüentemente, pela capacidade de generalização da rede. Se ρ for grande, a rede possui baixa capacidade de generalização e muitas categorias são criadas. Caso contrário, se ρ for pequeno, a rede terá alta capacidade de generalização, ou seja, poucas categorias são criadas;
- Parâmetro de treinamento β ($\beta \in [0, 1]$): controla a velocidade de adaptação da rede, ou seja, regula a taxa de aprendizagem. Na aprendizagem rápida, tem-se $\beta = 1$.

O processamento de uma rede ART pode ser descrito, sucintamente, nas seguintes etapas (31, 86, 87):

- Reconhecimento: reconhece os estímulos produzidos na camada F_2 e seleciona a categoria de maior valor após o cálculo da função escolha.
- Comparação: através do parâmetro de vigilância, testa a similaridade entre o vetor de entrada e o vetor protótipo, permitindo ou não a inclusão do padrão de entrada na categoria. Se o valor da comparação for maior do que ρ , então o padrão de entrada é incluído na categoria ativa, caso contrário, a rede entra em fase de busca.

- Busca: decorre da rejeição do neurônio vencedor diante do teste de similaridade. Para cada novo vetor de entrada busca-se outro neurônio na camada F_2 que tenha mais semelhança com o vetor de entrada atual.
- Treinamento: o treinamento só começa após a conclusão do processo de busca. Na rede ART o paradigma de treinamento é não-supervisionado, podendo ser ativado a qualquer momento, o que permite à rede aprender novos padrões continuamente. Na rede ART a aprendizagem pode ser rápida ou lenta (86). Na aprendizagem rápida, geralmente, em apenas um ciclo ou em poucos ciclos de treinamento os pesos das conexões são ajustados para seus melhores valores. Na aprendizagem lenta, os pesos são ajustados lentamente em vários ciclos de treinamento.

Observa-se que nas redes neurais da família ART, os vetores de entrada e saída desejada da rede serão sempre representados por linhas e não por colunas, conforme como habitualmente adotado na literatura.

3.2.2 Rede Neural ART-Fuzzy

A rede neural ART-Fuzzy (25) representa uma evolução da rede neural ART, integrando operações da teoria da lógica Fuzzy (29) em sistemas ART. Isto possibilita a categorização de maneira estável, por meio da auto-organização, de padrões de entrada analógicos e binários e, também, a implementação do algoritmo de classificação não-supervisionado com grande rapidez de aprendizagem.

A diferença básica entre as redes ART e ART-Fuzzy reside na substituição dos operadores de união (\cup) e de intersecção (\cap) utilizados na rede neural ART pelos operadores Fuzzy OR ou máximo (\vee) e Fuzzy AND ou mínimo (\wedge), respectivamente, da teoria dos conjuntos Fuzzy. Essa substituição ocorre na dinâmica de escolha, busca e aprendizagem da rede ART1, tornando a rede ART-Fuzzy uma versão mais poderosa e eficaz da ART 1. Considerando que a rede ART 1 pode aprender categorias estáveis somente em resposta para vetores de entrada binários, a rede ART-Fuzzy pode aprender categorias estáveis em resposta a vetores de entrada analógico ou binário. A rede ART-Fuzzy demonstra um melhor desempenho tanto na realização do treinamento quanto no processamento de dados analógicos (24). Uma comparação entre as redes ART 1 e ART-Fuzzy, conforme (24), é mostrada na Tabela 6.

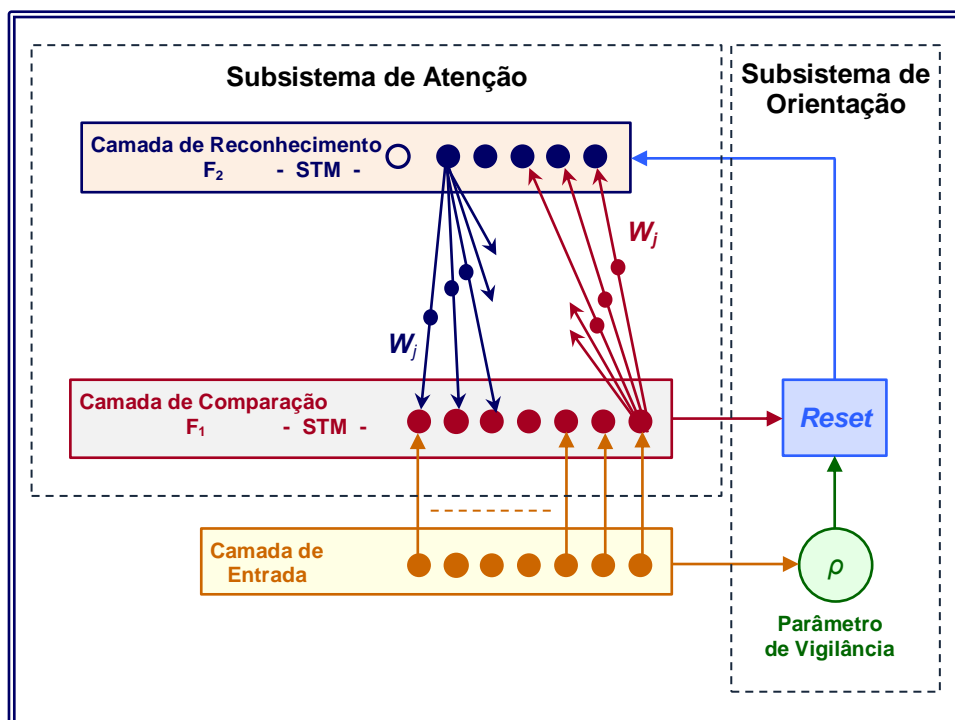
Tabela 6 - Comparação entre as redes ART 1 e ART-Fuzzy.

Fases	Rede ART 1 (Binária)	Rede ART-Fuzzy (Analgógica)
Escolha da Categoria	$T_j = \frac{ I \cap w_j }{\alpha + w_j }$	$T_j = \frac{ I \wedge w_j }{\alpha + w_j }$
Critério de Match	$ I \cap w_j \geq \rho I $	$ I \wedge w_j \geq \rho I $
Treinamento	$w_j^{\text{nov}} = \beta (I \cap w_j^{\text{velho}}) + (1 - \beta) w_j^{\text{velho}}$ <p>\cap = operador lógico AND (intersecção)</p>	$w_j^{\text{nov}} = \beta (I \wedge w_j^{\text{velho}}) + (1 - \beta) w_j^{\text{velho}}$ <p>\wedge = operador Fuzzy AND (mínimo)</p>

Fonte: adaptado de Carpenter *et al.* (24) e Marchiori *et al.* (31).

A rede ART-Fuzzy possui tanto a estrutura quanto o mecanismo de processamento bastante semelhante à rede ART. A estrutura da rede ART-Fuzzy pode ser observada na Figura 11 e o seu algoritmo descrito na sequência.

Figura 11 - Estrutura da rede neural ART-Fuzzy.



Fonte: Adaptado de Lopes (2005) (40).

3.2.2.1 Algoritmo da Rede Neural ART-Fuzzy

O algoritmo da uma rede neural ART *Fuzzy* ou de um módulo ART *Fuzzy* consiste, fundamentalmente, na sequência descrita a seguir (24, 25):

1º - Normalização dos Dados de Entrada

Os dados de entrada da rede neural ART são representados pelo vetor \mathbf{a} , M -dimensional, ou seja, $\mathbf{a} = [a_1 \ a_2 \ a_3 \ . \ . \ . \ a_M]$. Para evitar a proliferação de categorias na saída da rede neural ART *Fuzzy*, faz-se a normalização dos vetores de entrada (\mathbf{a}), conforme equação (2):

$$\bar{\mathbf{a}} = \frac{\mathbf{a}}{|\mathbf{a}|} \quad (2)$$

sendo:

$$|\mathbf{a}| = \sum_{i=1}^M a_i$$

i : número de componentes do \mathbf{a} ;

M : dimensão do vetor \mathbf{a} ;

a_i : i -ésimo elemento do vetor \mathbf{a} ;

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

2º - Codificação do Vetor de Entrada

Após normalizados, os elementos (a_i) do vetor de entrada (\mathbf{a}) são codificados por seu complemento. Esse procedimento, realizado de acordo com a equação (3), tem como finalidade preservar a amplitude da informação, pois todos os vetores com normalização e codificação complementada terão o mesmo comprimento M .

$$\bar{a}_i^c = 1 - \bar{a}_i \quad , \text{ logo: } \quad \bar{\mathbf{a}}^c = [\bar{a}_1^c \ \bar{a}_2^c \ . \ . \ . \ \bar{a}_M^c] \quad (3)$$

sendo:

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

\bar{a}^c : vetor complementar do vetor de entrada normalizado.

Assim, o vetor apresentado à camada de entrada da rede (F_0) será o vetor I , $2M$ -dimensional, como apresentado na equação (4).

$$I = [\bar{a} \quad \bar{a}^c] \quad \therefore I = [\bar{a}_1 \quad \bar{a}_2 \quad \dots \quad \bar{a}_M \quad \bar{a}_1^c \quad \bar{a}_2^c \quad \dots \quad \bar{a}_M^c] \quad (4)$$

sendo:

I : vetor de entrada da rede normalizado e com codificação de complemento.

3º - Vetores de Atividade

O vetor de atividade na camada de entrada da rede F_0 é o vetor $I = [I_1 \quad I_2 \quad \dots \quad I_{2M}]$, considerando M a dimensão do vetor de entrada, ou ainda o número de elementos do vetor a .

Para a camada de comparação F_1 , o vetor de atividade é representado por $x = [x_1 \quad x_2 \quad \dots \quad x_M]$, e obedece a regra descrita na equação (5):

$$x = \begin{cases} I & , \quad \text{se os nós de } F_2 \text{ estão inativos} \\ I \wedge w_j & , \quad \text{se o nó } J \text{ de } F_2 \text{ foi escolhido e está ativo} \end{cases} \quad (5)$$

O vetor de atividade para a camada de reconhecimento F_2 é indicado por $y = [y_1 \quad y_2 \quad \dots \quad y_N]$, sendo N o número de categorias criadas em F_2 . Assim, y assumirá valores de acordo com o estabelecido na equação (6):

$$y_j = \begin{cases} 1 & , \quad \text{se o nó } j \text{ de } F_2 \text{ é ativo, ou seja,} \quad \text{se } j = J \\ 0 & , \quad \text{caso contrário, ou seja, se } j \neq J. \end{cases} \quad (6)$$

4º - Parâmetros da Rede

No processamento de uma rede neural ART-*Fuzzy* três parâmetros são essenciais para

o seu desempenho e aprendizado, são eles:

- Parâmetro de escolha (α): $\alpha > 0$ - é responsável pela seleção de categorias;
- Parâmetro de treinamento (β): $\beta \in [0, 1]$ - controla a velocidade de adaptação da rede, ou seja, regula a taxa de aprendizagem. Na aprendizagem rápida, $\beta = 1$.
- Parâmetro de vigilância (ρ): $\rho \in [0, 1]$ - monitora a ressonância da rede, sendo responsável pelo número de categorias criadas na camada F_2 e, conseqüentemente, pela capacidade de generalização da rede. Se ρ é grande a rede possui baixa capacidade de generalização, pois muitas categorias são criadas. Caso contrário, se ρ é pequeno, a rede terá alta capacidade de generalização, ou seja, poucas categorias são criadas.

5° - Inicialização dos Pesos

Na rede neural ART-*Fuzzy* os pesos das conexões entre as camadas de comparação F_1 e a de reconhecimento F_2 são representados pelo vetor de pesos w_j . Inicialmente, todos os pesos possuem valor igual a 1, indicando que não existe nenhuma categoria ativa, como na equação (7):

$$w_{j1}(0) = w_{j2}(0) = \dots = w_{jM}(0) = 1 \quad (7)$$

A cada nó j da camada F_2 é associado um vetor de pesos w_j , com $j = 1, \dots, N$, onde N é o número de neurônios ou nós em F_2 . O número de neurônios na camada F_1 é igual a $2M$.

6° - Escolha de uma Categoria

Considerando um determinado vetor de entrada I em F_1 , a escolha da categoria j em F_2 atende à função de escolha T_j definida na equação (8):

$$T_j(I) = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (8)$$

sendo:

\wedge - operador AND *Fuzzy*, definido pela equação (9):

$$(I \wedge w)_i \equiv \min(I_i, w_i) \quad (9)$$

O sistema escolhe a categoria como sendo o nó ativo J , correspondente ao maior T_j , ou seja, J representa o índice do neurônio vencedor, conforme a equação (10):

$$J = \arg \max_{j=1, \dots, N} T_j \quad (10)$$

Se mais de um T_j for máximo, ou seja, se mais de um neurônio conseguir a ativação máxima, a categoria escolhida será aquela que possuir o menor índice j .

7º - Ressonância ou *Reset*

A ressonância ocorre se o “casamento” (função *match*) ou combinação da categoria escolhida atender ao critério de vigilância da equação (11).

$$\frac{|I \wedge w_j|}{|I|} \geq \rho \quad (11)$$

Se o critério de vigilância, equação (11), for satisfeito ocorre o aprendizado, o sistema está em estado ressonante e o treinamento é realizado conforme a equação (12).

Caso contrário, se o critério da vigilância não for satisfeito o nó escolhido é desativado, ocorrendo o *reset*. No *reset*, o nó J de F_2 é excluído do processo de busca pela categoria ativa, conforme equação (10), ou seja, T_j assume o valor zero até que o critério de vigilância seja satisfeito para a entrada analisada. Então, é escolhida uma nova categoria J através da aplicação da equação (10) para a realização do processo de ressonância. Este procedimento é realizado até que a rede encontre uma categoria que satisfaça a equação (11).

8° - Aprendizado (Atualização dos Pesos)

O processo de treinamento e aprendizado ocorre somente após o vetor de entrada I ter completado o estado de ressonância. Em decorrência da ressonância e, conseqüentemente, do aprendizado ocorre a modificação do vetor dos pesos, dada pela equação (12).

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

sendo:

J : categoria ativa;

$\mathbf{w}_J^{\text{nov}}$: vetor com pesos atualizados,

$\mathbf{w}_J^{\text{velho}}$: vetor com pesos referentes à atualização anterior.

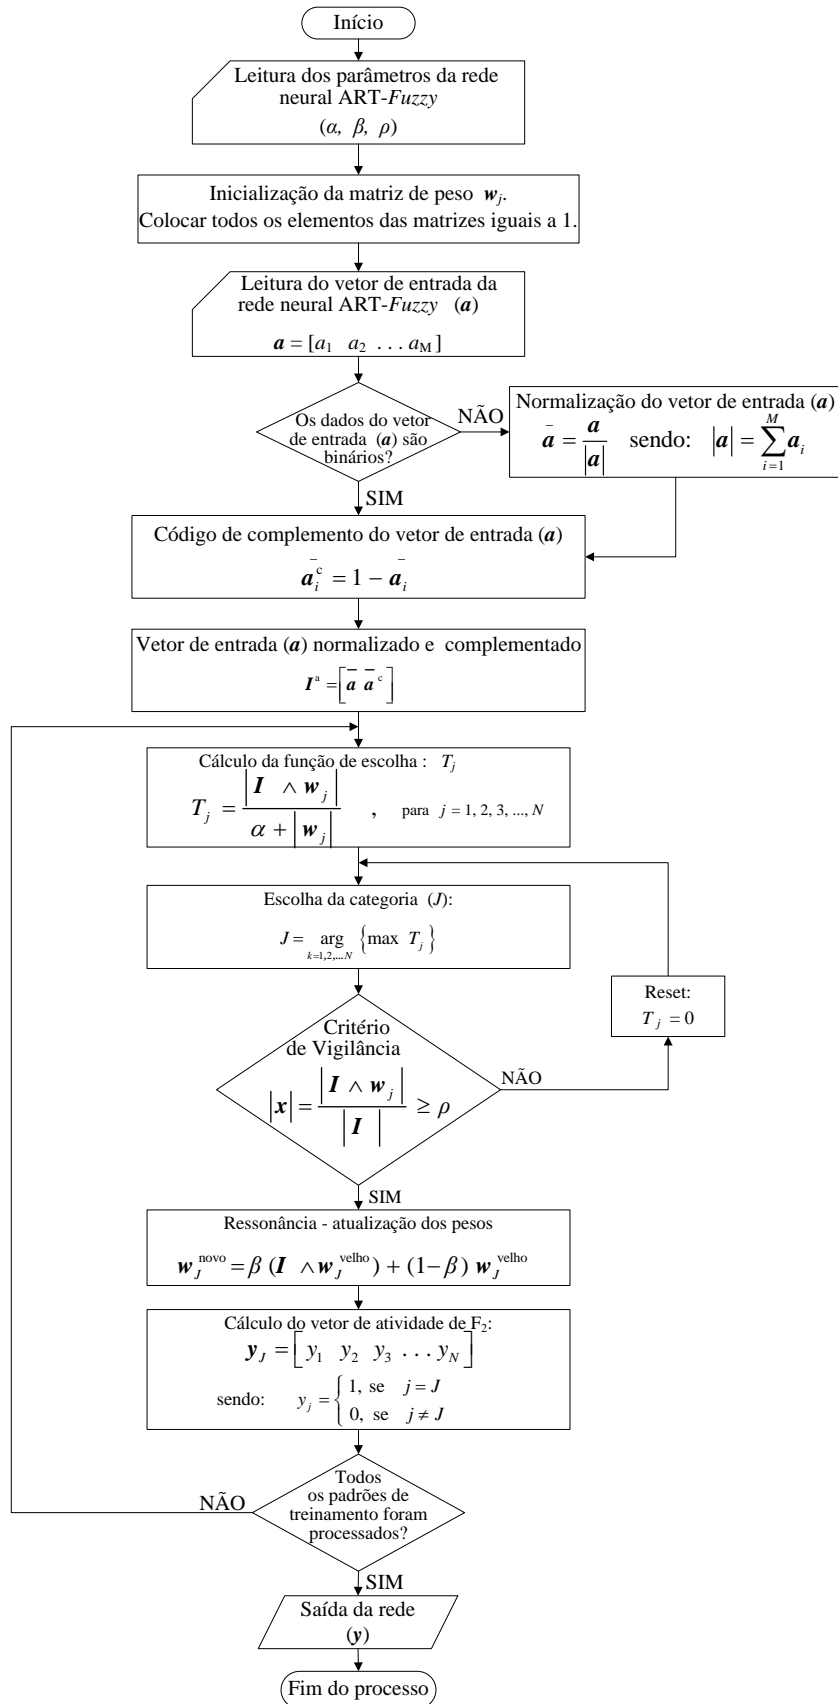
Dependendo do valor do parâmetro de treinamento (β), são possíveis dois tipos de treinamento, são eles:

- Treinamento rápido: se $\beta = 1$ - permite que o sistema se adapte rapidamente;
- Treinamento lento: se $0 < \beta < 1$ - os pesos do sistema se adaptam lentamente.

Na rede *ART-Fuzzy* a aprendizagem sempre converge, ou seja, uma solução sempre é encontrada (propriedade de estabilidade).

O processo de treinamento da rede neural *ART-Fuzzy* descrito no algoritmo acima pode ser melhor visualizado e compreendido no fluxograma da Figura 12.

Figura 12 - Fluxograma da rede neural ART-Fuzzy.



3.2.3 Rede Neural ARTMAP-Fuzzy

A rede neural ARTMAP-Fuzzy (24) é baseada em operações da lógica *fuzzy*, operador *fuzzy* AND (\wedge), incorporadas na rede ARTMAP (37), possibilitando ao sistema neural processar e aprender com padrões de entrada tanto binários como analógicos, no intervalo [0, 1] (68). Este modelo de rede pertence à família de redes ART e também é conhecido como rede ART preditiva ou, ainda, sistema ARTMAP-Fuzzy.

A arquitetura da rede neural ARTMAP foi concebida para a realização de aprendizagem supervisionada em um ambiente ou conjunto de dados multidimensional. Trata-se de um sistema auto-organizável, capaz de realizar de maneira estável o reconhecimento de categorias frente à apresentação de uma sequência aleatória de padrões de entrada (37). Essa rede é composta por dois módulos ART, ART_a e ART_b , conectados por meio de um módulo de memória associativa inter- ART_{ab} .

No sistema ARTMAP-Fuzzy, dois módulos ART-Fuzzy, ART_a e ART_b , estão interligados por meio de um módulo de memória associativa inter- ART_{ab} , denominado Mapa de Campo (F^{ab}).

O módulo inter-ART dispõe de um mecanismo autorregulador denominado *match tracking*, que busca “casamentos” ou combinações entre as categorias, tendo como objetivo elevar o grau de generalização e diminuir o erro da rede. Sempre que a rede faz uma predição incorreta, por meio de uma conexão associativa instruída, será acrescido ao parâmetro de vigilância ρ_a , do módulo ART_a -Fuzzy, um valor incremental mínimo (ε) necessário para corrigir o erro preditivo no módulo ART_b -Fuzzy (24).

Em seguida, o módulo ART_a -Fuzzy inicia a busca de uma nova categoria para a entrada que está sendo analisada, até encontrar uma predição correta ou criar uma categoria no módulo ART_a -Fuzzy, e a sua correspondente categoria no módulo ART_b -Fuzzy.

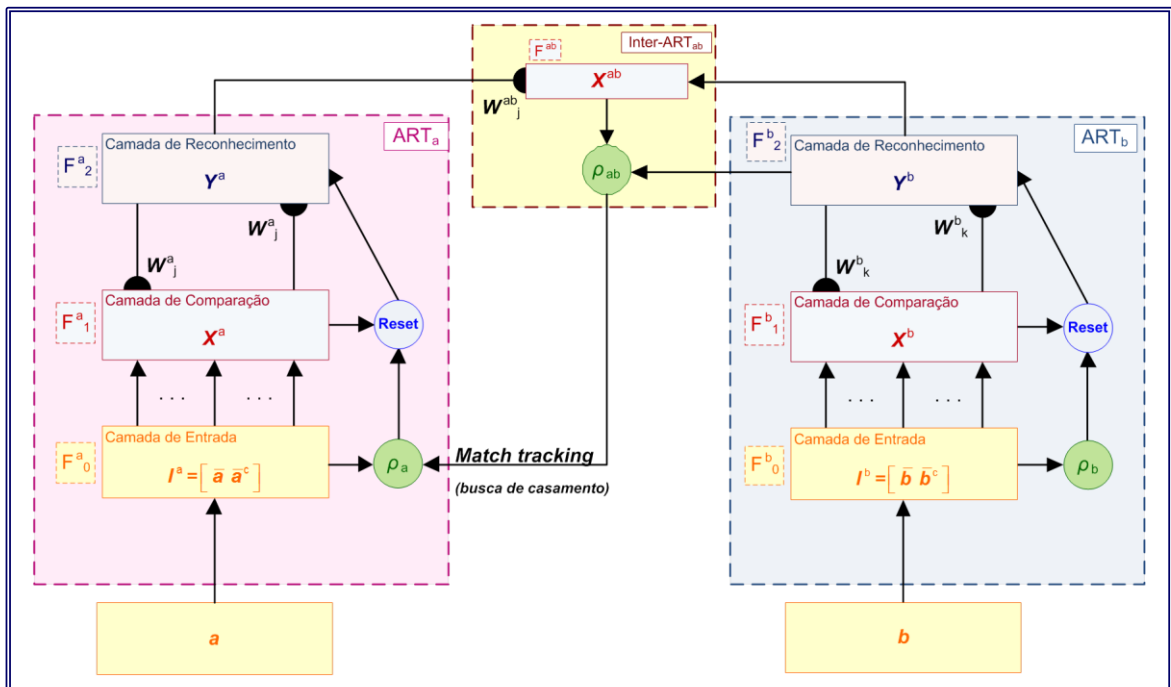
No processo de *match tracking* a rede forma associações preditivas entre as categorias dos módulos ART_a -Fuzzy e ART_b -Fuzzy e realiza um rastreamento e reconhecimento auto-organizado dessas categorias, em busca de “casamento” ou combinação, em relação às sequências aleatórias dos padrões de entrada. Os módulos ART_a -Fuzzy e ART_b -Fuzzy possuem arquitetura igual à rede ART-Fuzzy descrita anteriormente, com a diferença de que no módulo ART_a considera-se um parâmetro de vigilância básico (ρ_{as}) utilizado para controlar o sistema ARTMAP-Fuzzy. Se os módulos ART_a e ART_b são desconectados, cada um deles se

auto-organizaria, agrupando seus respectivos conjuntos de entrada.

A função do módulo $ART_a-Fuzzy$ é aprender a classificar os padrões de entrada apresentados na camada F^a_0 , e a função do módulo $ART_b-Fuzzy$ é desenvolver as categorias referentes aos padrões de saída desejado, apresentados na camada F^b_0 , por meio do parâmetro de vigilância ρ_b . A camada F^a_2 , do módulo $ART_a-Fuzzy$, é conectada ao módulo inter- ART_{ab} (F^{ab}) pelos pesos associativos w_j^{ab} ajustados por meio do treinamento, porém, assumindo inicialmente valores iguais a um, ou seja, $w_j^{ab} = 1$, representando que entre os módulos $ART_a-Fuzzy$ e $ART_b-Fuzzy$ não existe associação alguma. Cada nó da camada F^b_2 , do módulo $ART_b-Fuzzy$, é conectada ao seu nó correspondente no módulo inter- ART_{ab} (F^{ab}) e vice-versa.

A arquitetura da rede neural $ARTMAP-Fuzzy$ é mostrada na Figura 13, seguida da descrição de seu algoritmo de treinamento.

Figura 13 - Arquitetura da rede neural $ARTMAP-Fuzzy$.



Fonte: adaptado de Carpenter *et al.* (1992) (24).

Ressalta-se que, no caso das redes neurais da família ART, a representação vetorial é por linha e não por coluna como habitualmente adotada em representações matemáticas. Essa opção torna a exposição teórica mais fácil de ser entendida.

3.2.3.1 Algoritmo da Rede Neural ARTMAP-Fuzzy

O algoritmo para o processamento de uma rede neural ARTMAP-Fuzzy, mostrada na Figura 14, será descrito a seguir, conforme (24).

1° - Dados de Entrada

Os vetores de entrada da rede ARTMAP-Fuzzy consistem no vetor de entrada do módulo ART_a (vetor \mathbf{a}), que corresponde às amostras dos dados de entrada da rede neural, e no vetor de entrada do módulo ART_b (vetor \mathbf{b}), que corresponde à saída desejada, referente às amostras apresentadas à entrada da rede ART_a. Esses vetores são representados, respectivamente, por $\mathbf{a} = [a_1 \ a_2 \ \dots \ a_{M_a}]$, M_a -dimensional, e por, $\mathbf{b} = [b_1 \ b_2 \ \dots \ b_{M_b}]$, M_b -dimensional.

2° - Matrizes de Pesos

As matrizes de pesos associadas aos módulos ART_a (matriz \mathbf{w}^a) e ART_b (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 categorias encontram-se inativas. Essas atividades são ativadas à medida em que ocorre a ressonância entre os padrões de entrada e saída.

3° - Parâmetros da Rede

No processamento de uma rede neural ARTMAP-Fuzzy os parâmetros são os mesmos usados na rede ART-Fuzzy, porém cada módulo ART_a e ART_b recebem um padrão específico. Além dos parâmetros semelhantes aos módulos ART's, existe o parâmetro de vigilância do módulo Inter-ART (ρ_{ab}), que pode ser fixado em qualquer valor no intervalo $[0, 1]$, ou seja, $\rho_{ab} \in [0, 1]$.

4° - 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 (vencedora) para o módulo $ART_a-Fuzzy$ - J
- categoria ativa (vencedora) para o módulo $ART_b-Fuzzy$ - K

Após a confirmação da ressonância em cada módulo e, conseqüentemente, a ativação das categorias, faz-se necessário verificar se a categoria ativa em ART_a corresponde ao vetor de saída desejado apresentado em ART_b . Esse processo é realizado utilizando a busca por um “casamento” ou o teste do *match tracking*, dado pela equação (13):

$$|x^{ab}|_i = \frac{|y_i^b \wedge w_J^{ab}|}{y_i^b} \quad (13)$$

Pelo critério de vigilância, tem-se que:

- Se, $|x^{ab}|_i \geq \rho_{ab} \rightarrow$ o par de treinamento deve ser confirmado nas matrizes de pesos com índices J e K
- Se, $|x^{ab}|_i < \rho_{ab} \rightarrow$ deve-se buscar outro índice J , com relação aos vetores de entrada a , 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 , o suficiente para excluir a categoria atual e selecionar outra, sendo que esse processo se repetirá até que o critério de vigilância seja satisfeito.

5° - Aprendizado (Atualização dos Pesos)

A atualização dos pesos da rede neural $ARTMAP-Fuzzy$, como ocorre com a $ART-Fuzzy$, somente é realizado após ocorrer a ressonância, pelo critério de vigilância, através da equação (13). Em decorrência da ressonância e, conseqüentemente, do aprendizado, ocorre a modificação do vetor dos pesos.

Nos módulos $ART_a-Fuzzy$ e $ART_b-Fuzzy$ a modificação dos pesos é realizada conforme descrito nas equações (14) e (15):

$$\mathbf{w}_J^{a(\text{novo})} = \beta (\mathbf{I} \wedge \mathbf{w}_J^{a(\text{velho})}) + (1-\beta) \mathbf{w}_J^{a(\text{velho})} \quad (14)$$

$$\mathbf{w}_K^{b(\text{novo})} = \beta (\mathbf{I} \wedge \mathbf{w}_K^{b(\text{velho})}) + (1-\beta) \mathbf{w}_K^{b(\text{velho})} \quad (15)$$

A modificação da matriz dos pesos para o módulo Inter-ART_{ab} é realizada de acordo com as equações (16) e (17):

$$w_{JK}^{ab(\text{novo})} = 1 \quad (16)$$

$$w_{jk}^{ab(\text{novo})} = 0, \text{ para } k=1,2,\dots,N, \quad k \neq K \quad (17)$$

6º - Fase do Treinamento

Conforme descrito anteriormente, no processo de treinamento as matrizes de pesos associadas aos módulos ART_{a-Fuzzy} ($\mathbf{w}_{(N \times 2Ma)}^a$), ART_{b-Fuzzy} ($\mathbf{w}_{(N \times 2Mb)}^b$) e ao módulo Inter-ART_{ab} ($\mathbf{w}_{(N \times N)}^{ab}$) são iniciadas com valores iguais a 1, indicando que todas as categorias encontram-se inativas.

Os vetores de entrada (\mathbf{I}^a), e saída desejada (\mathbf{I}^b) normalizados e com codificação de complemento, apresentados aos módulos ART_{a-Fuzzy} e ART_{b-Fuzzy}, respectivamente, são representados conforme as equações (18) e (19).

$$\mathbf{I}^a = \begin{bmatrix} \bar{a} & \bar{a}^c \end{bmatrix} \quad \therefore \mathbf{I}^a = \begin{bmatrix} \bar{a}_1 & \bar{a}_2 & \dots & \bar{a}_{Ma} & \bar{a}_1^c & \bar{a}_2^c & \dots & \bar{a}_{Ma}^c \end{bmatrix} \quad (18)$$

$$\mathbf{I}^b = \begin{bmatrix} \bar{b} & \bar{b}^c \end{bmatrix} \quad \therefore \mathbf{I}^b = \begin{bmatrix} \bar{b}_1 & \bar{b}_2 & \dots & \bar{b}_{Mb} & \bar{b}_1^c & \bar{b}_2^c & \dots & \bar{b}_{Mb}^c \end{bmatrix} \quad (19)$$

considerando:

$$\bar{a} = \frac{\mathbf{a}}{|\mathbf{a}|}, \text{ sendo: } |\mathbf{a}| = \sum_{i=1}^{Ma} a_i \quad \text{e} \quad \bar{b} = \frac{\mathbf{b}}{|\mathbf{b}|}, \text{ sendo: } |\mathbf{b}| = \sum_{i=1}^{Mb} b_i$$

$$\text{e: } \bar{a}_i^c = 1 - \bar{a}_i, \text{ logo: } \bar{\mathbf{a}}^c = \begin{bmatrix} \bar{a}_1^c & \bar{a}_2^c & \dots & \bar{a}_{Ma}^c \end{bmatrix} \quad \text{e} \quad \bar{b}_i^c = 1 - \bar{b}_i, \text{ logo: } \bar{\mathbf{b}}^c = \begin{bmatrix} \bar{b}_1^c & \bar{b}_2^c & \dots & \bar{b}_{Mb}^c \end{bmatrix}$$

tem-se assim que:

\mathbf{I}^a : vetor de entrada da rede normalizado e com codificação de complemento;

\mathbf{I}^b : vetor de saída desejada da rede normalizado e com codificação de

complemento;

$\bar{a}_i \in [0, 1], i = 1, 2, \dots, Ma;$

$\bar{b}_i \in [0, 1], i = 1, 2, \dots, Mb;$

a_i : i -ésimo elemento do vetor de entrada \mathbf{a} ;

b_i : i -ésimo elemento do vetor de saída desejada \mathbf{b} ;

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

$\bar{\mathbf{b}}$: vetor de saída desejada normalizado;

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

\bar{b}_i^c : elemento complementar do elemento do vetor de saída desejada normalizado;

$\bar{\mathbf{a}}^c$: vetor complementar do vetor de entrada normalizado;

$\bar{\mathbf{b}}^c$: vetor complementar do vetor de saída desejada normalizado;

Ma : dimensão (número de componentes) do vetor de entrada \mathbf{a} ;

Mb : dimensão (número de componentes) do vetor da saída desejada \mathbf{b} ;

N : número de pares de vetores $\{ \mathbf{a}, \mathbf{b} \}$ para o treinamento.

As etapas do processo de treinamento da rede neural ARTMAP-*Fuzzy*, descritas no algoritmo anterior, adaptado de Decanini (2012) (88), podem ser melhores visualizadas no fluxograma da Figura 14. Os símbolos contidos no fluxograma e não descritos anteriormente, são elencados abaixo:

\mathbf{w}_i : i -ésima linha da matriz \mathbf{w} ;

$w_{i,j}$: componente da posição (i,j) da matriz \mathbf{w} ;

$\arg \{ \max T_j \}$: obtenção do índice correspondente ao máximo valor entre os coeficientes T_j , $(j=1, 2, \dots, N)$;

T_j : j -ésimo coeficiente da função de escolha;

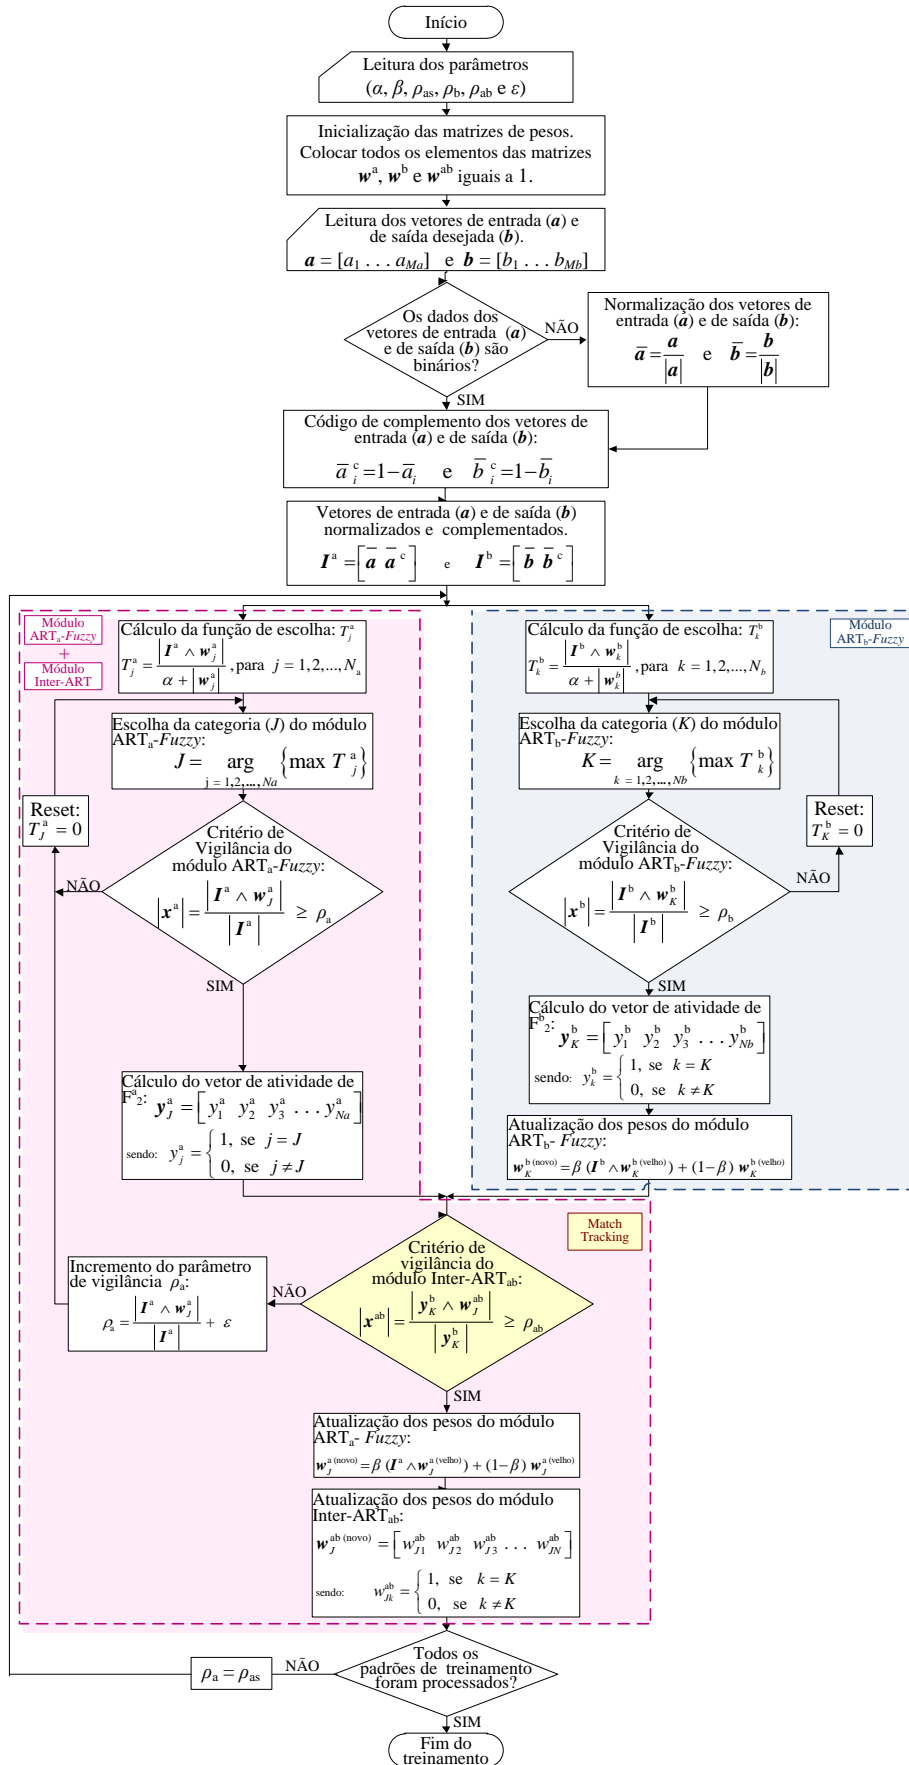
J : número do neurônio vencedor no módulo $\text{Art}_a\text{-Fuzzy}$;

K : número do neurônio vencedor no módulo $\text{Art}_b\text{-Fuzzy}$;

ρ_{as} : valor inicial do parâmetro de vigilância do módulo $\text{Art}_a\text{-Fuzzy}$;

ε : valor positivo e pequeno para incremento do parâmetro ρ_a .

Figura 14 - Fluxograma da rede neural ARTMAP-Fuzzy.



Fonte: Adaptado de Lopes (2005) (40).

IMPLEMENTAÇÃO DO SISTEMA ARTMAP-FUZZY PARA PREDIÇÃO DA EVASÃO ESCOLAR

A coisa mais indispensável a um homem é reconhecer o uso que deve fazer do seu próprio conhecimento.

Platão

Os dados que envolvem o estudo sobre a 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. Para lidar com o problema da predição da evasão escolar, foi implementada uma rede neural ARTMAP-*Fuzzy*. Ela é capaz de processar tanto dados analógicos quanto dados binários. Dentre suas potencialidades, tem-se a possibilidade de tratar problemas onde a relação entre os diferentes conjuntos de dados é complexa e desconhecida; e também, onde a função entre as variáveis de saída e de entrada da rede é desconhecida e multidimensional, como é o caso do problema da evasão, preservando as características de plasticidade e estabilidade. Estas características fundamentais da teoria da ressonância adaptativa asseguram, à rede neural, rapidez de resposta (convergência rápida) e precisão, bem como, novos conhecimentos podem ser, facilmente, incorporados na matriz de pesos, sem destruir o conhecimento previamente adquirido, ou seja, a aquisição do conhecimento é realizada de forma incremental. A rede neural ARTMAP-*Fuzzy* realiza o treinamento de modo supervisionado e auto-organizável, através do “casamento” entre os vetores padrões de entrada e saída da rede. Sua arquitetura e dinâmica de processamento tornam possível a implementação do treinamento continuado. Neste capítulo, tem-se por objetivo descrever a implementação do sistema para o diagnóstico preditivo da evasão discente, considerando-se as etapas da extração das características dos estudantes, construção da base de dados, formulação do problema da evasão, treinamento da rede neural e diagnóstico da evasão.

No Anexo A consta a autorização do IFMT para utilização, nesta pesquisa, das informações contidas nos gerenciadores de bancos de dados Q-Acadêmico e Q-Seleção.

4.1 CONSTRUÇÃO DA BASE DE DADOS

As características dos estudantes, utilizadas como preditoras para análise da evasão, são extraídas de bancos de dados heterogêneos (Q-Seleção e Q-Acadêmico), compostos por dados híbridos, ou seja, dados numéricos e dados textuais.

Portanto, para construir a base de dados para o problema da evasão, foi necessário manipular os dados extraídos dos bancos de dados, tornando-os homogêneos e de natureza numérica.

Na estrutura do sistema, proposto nesta pesquisa, para o diagnóstico preditivo da evasão discente, a rede neural ARTMAP-*Fuzzy* foi concebida para o processamento de dados essencialmente binários. Portanto, a base de dados de natureza numérica foi convertida em uma base de dados binários, composta por um padrão conhecido como zero e um.

Embora esta rede neural ARTMAP-*Fuzzy* possa lidar tanto com dados binários quanto com dados analógicos, a concepção de um sistema neural essencialmente binário é consideravelmente vantajosa. O treinamento é realizado de forma mais simples e mais eficiente (apresenta maior rapidez e melhor precisão) se comparado à formulação da rede neural com dados mistos (binários e analógicos) ou apenas dados analógicos. Essa concepção permitirá, mais facilmente, *a posteriori*, a implementação do treinamento continuado e a inserção de um sistema de pós-análise com o auxílio da lógica *Fuzzy* (29) e/ou da teoria da evidência (30).

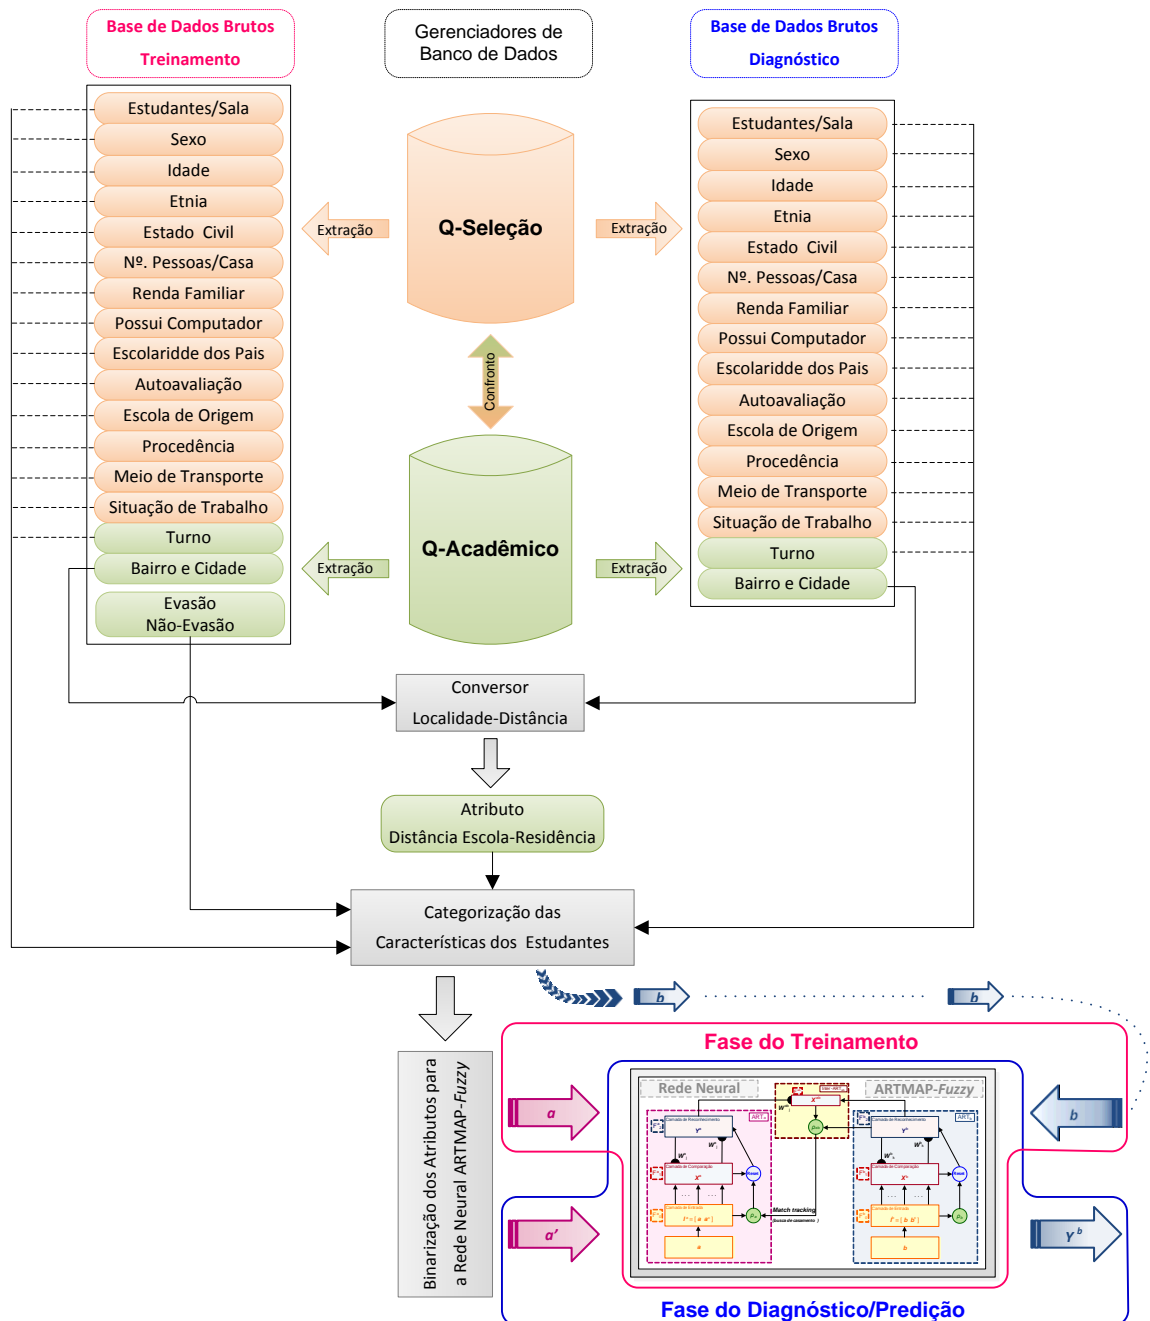
Na Figura 16, apresenta-se um esquema geral da aplicação do sistema de predição da evasão escolar discente usando uma rede neural ARTMAP-*Fuzzy*.

Observando-se o esquema da Figura 15, o processo de implementação do sistema preditivo da evasão discente inicia-se com o confronto entre as informações gerenciadas nas bases de dados (Q-Seleção e Q-Acadêmico). Com esse confronto, realiza-se a substituição e reconstituição de informações errôneas, distorcidas ou perdidas e, em seguida, a extração das características dos estudantes, utilizadas como preditoras para o diagnóstico da evasão. Essas características são, então, compiladas em duas bases de dados brutos: uma para a fase de treinamento e outra para a fase de diagnóstico/validação da rede neural.

Dentre as características selecionadas, as informações sobre o bairro e a cidade onde os estudantes residem foram convertidas em um valor, em quilômetros, que representa a distância aproximada entre a escola e sua residência, constituindo-se em um dos atributos do

vetor de entrada da rede neural (“distância escola-residência”). Esta conversão é realizada através do conversor localidade-distância.

Figura 15 - Esquema geral da aplicação do sistema de predição da evasão escolar discente usando uma rede neural ARTMAP-Fuzzy.

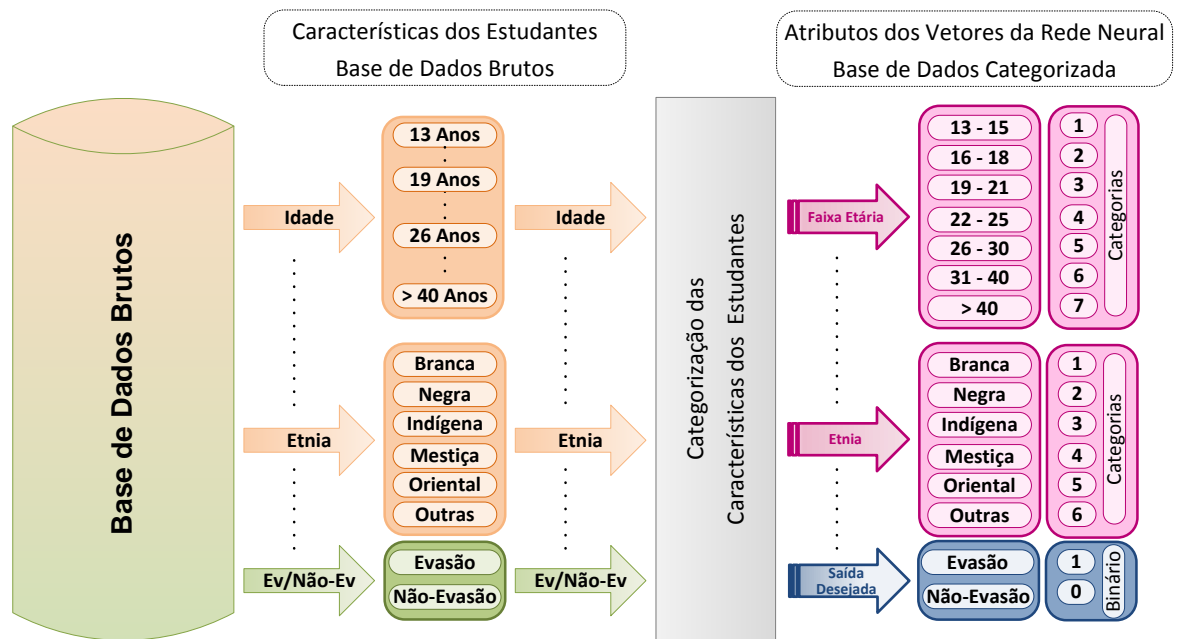


Fonte: da própria autora.

Cada uma das características que compõem a base dos dados brutas, o atributo “distância escola-residência” advindo do conversor de localidade-distância e a informação

sobre a situação evasão/não-evasão de cada estudante foram categorizadas. Esse processo consiste na atribuição de uma numeração do sistema decimal para cada resposta possível do questionário socioeconômico, pertinente à determinada característica, e para cada faixa de valores estabelecida em algumas delas. A Figura 16 ilustra um exemplo desse processo.

Figura 16 - Exemplo do processo de categorização.



Fonte: da própria autora.

Após o processo de categorização, todos os atributos do vetor de entrada da rede neural foram binarizados, isto é, foram convertidos em um padrão do código binário (89), usando até 3 *bits* para a categoria de cada atributo.

Um exemplo da conversão das categorias com números decimais em um padrão binário pode ser observado na Tabela 7. A codificação de todos os atributos utilizados nos padrões de entrada da rede neural pode ser visualizada no Apêndice A.

Em seguida, à codificação binária, os dados foram agrupados e salvos em um arquivo, construindo-se, assim, a base de dados binários para aplicação na análise do problema da evasão escolar e no diagnóstico preditivo do grupo de estudantes em risco de evasão, utilizando uma rede neural ARTMAP-*Fuzzy*.

A base de dados construída representa o conjunto de estudantes matriculados nos

cursos superiores de tecnologia do IFMT - Campus Cuiabá, no período de 2004/2 a 2011/2. Caracteriza-se por uma base de dados essencialmente binária, composta por 1650 linhas e 42 colunas. Quando do processamento da rede, essa base de dados será fragmentada em bases menores para treinamento e diagnóstico, e reagrupadas em função da análise da evasão que se deseja realizar.

Tabela 7 - Exemplo da conversão categoria decimal- padrão binário dos atributos do vetor de entrada da rede neural.

Posição no vetor de entrada da rede (a)		Atributo dos subvetores de entrada da rede	Possibilidades de resposta	Categorias com números decimais	Padrão do código binário - até 3 bits		
					2^2	2^1	2^0
Subvetores do vetor de entrada da rede (a)	a_2	Faixa Etária (FxEt)	13 a 15 Anos	1	001		
			16 a 18 Anos	2	010		
			19 a 21 Anos	3	011		
			22 a 25 Anos	4	100		
			26 a 30 Anos	5	101		
			31 a 40 Anos	6	110		
			> 40 Anos	7	111		
	a_3	Etnia (Etn)	Branca	1	001		
			Negra	2	010		
			Indígena	3	011		
			Mestiça	4	100		
			Oriental	5	101		
Outras			6	110			

Fonte: da própria autora.

Em cada linha do banco de dados estão contidas as características de um estudante, constituindo-se os atributos do vetor padrão de entrada da rede neural e sua respectiva saída desejada, para a fase do treinamento da rede. Os dados das colunas de 1 a 41 representam os atributos correspondentes ao vetor a , entrada do módulo ART_a . Na coluna 42 estão representadas as saídas desejadas, vetor b (entrada do módulo ART_b) da rede neural $ARTMAP-Fuzzy$ aplicada ao problema da evasão.

O resultado do processo de binarização dos atributos dos subvetores do vetor de entrada do módulo ART_a da rede neural $ARTMAP-Fuzzy$ é mostrado na Figura 17.

Figura 17 - Amostra do resultado do processo de codificação decimal-binário dos atributos dos subvetores do vetor de entrada (a) do módulo ART_a.

Características para a entrada da Rede															Vetor de Saída			
Nº Amostras	Sx	FxEt	Etn	EstCiv	PesCs	Rfam	Comp	EscPais	EscOrig	Aaval	Procd	DistER	Transp	Trab	Turno	Na/SI	Final 2009/1	Nº Amostras
1	1	100	010	001	001	010	0	010	001	010	1	001	010	010	11	010	1	1
2	0	100	001	001	011	011	1	010	001	001	1	010	001	001	11	100	0	2
3	1	101	010	001	011	001	0	011	001	010	1	010	001	010	11	100	0	3
4	0	011	100	001	011	100	1	110	001	011	1	001	111	001	01	001	1	4
5	0	011	001	001	010	001	1	100	010	011	1	011	001	001	01	001	1	5
6	1	011	100	001	010	010	1	011	001	010	1	010	001	001	10	100	0	6
7	0	010	001	001	011	001	0	011	001	011	1	010	001	011	11	010	1	7
8	0	101	100	001	011	010	0	100	001	001	1	001	001	001	11	100	0	8
9	0	010	010	001	001	001	0	010	001	010	1	010	101	001	11	100	0	9
10	0	010	010	001	010	010	1	110	010	010	1	010	001	001	11	001	1	10
11	1	010	001	001	010	001	0	100	001	011	1	011	101	001	11	100	0	11
12	0	010	001	001	010	010	0	100	001	010	1	010	001	001	11	100	0	12
13	0	101	001	001	001	001	0	100	010	010	1	010	001	001	11	100	0	13
14	0	010	010	001	010	011	1	010	001	010	1	100	001	001	11	100	0	14
15	0	010	010	001	010	011	0	011	001	001	1	001	111	001	10	001	1	15
16	0	110	001	001	010	100	0	101	010	010	1	011	001	001	11	100	0	16
17	0	100	100	001	011	010	0	100	001	010	1	010	001	001	11	011	1	17
18	0	001	100	001	010	010	1	101	001	010	1	010	001	001	10	100	0	18
19	0	100	010	001	001	100	1	101	001	010	1	010	001	001	11	100	0	19
20	0	110	001	001	010	100	1	100	001	011	1	010	001	001	11	100	0	20
21	0	100	001	001	010	010	0	100	001	010	1	010	001	010	11	001	0	21
22	1	010	010	001	010	011	0	101	001	010	1	010	001	001	01	001	1	22
23	1	011	010	001	011	100	0	100	001	010	1	001	001	001	11	100	0	23
24	0	111	001	001	010	010	1	100	001	010	1	010	001	110	11	100	0	24
25	0	100	001	001	010	011	1	100	001	001	1	001	101	001	11	100	0	25

Fonte: da própria autora.

Considerando-se que o sistema de predição da evasão escolar, desenvolvido nessa pesquisa, está baseado na Teoria da Ressonância Adaptativa, os vetores padrões utilizados no processamento da rede neural ARTMAP-*Fuzzy* são representados por linhas, diferentemente da representação por coluna, usualmente encontrada na literatura. Esta notação segue a recomendação apresentada pelos criadores das redes neurais da família ART, Carpenter e Grossberg (22), tornando a compreensão de tais redes neurais mais inteligível.

Um exemplo da composição dos pares de vetores padrões de entrada-saída desejada apresentados à rede neural ARTMAP-*Fuzzy*, para lidar com o problema da evasão, encontra-se ilustrado na Figura 18.

Figura 18 - Exemplo da composição dos vetores de entrada e saída desejada da rede neural ARTMAP-Fuzzy para aplicação ao problema da evasão discente.

Exemplo da composição do Vetor padrão de entrada (a) e Saída Desejada (b) da rede neural ARTMAP-Fuzzy																	
Entrada módulo ARTa																Entrada módulo ARTb	
Atributos	Sx	FxEt	Etn	EstCiv	PesCs	RFam	Comp	EscPais	EscOrig	Aaval	Procd	DistER	Transp	Trab	Turno	Na/Sl	Evasão / Não-Evasão
Qtde Bits	1 Bits	3 Bits	3 Bits	3 Bits	3 Bits	3 Bits	1 Bits	3 Bits	3 Bits	3 Bits	1 Bits	3 Bits	3 Bits	3 Bits	2 Bits	3 Bits	1 Bits
Subvetores (a_i)	a_1	a_2	a_3	a_4	a_5	a_6	a_7	a_8	a_9	a_{10}	a_{11}	a_{12}	a_{13}	a_{14}	a_{15}	a_{16}	b_1
Exemplo de um vetor padrão	1	100	010	001	001	010	0	010	001	010	1	001	010	010	11	010	1
$a = [a_1 a_2 a_3 a_4 a_5 a_6 a_7 a_8 a_9 a_{10} a_{11} a_{12} a_{13} a_{14} a_{15} a_{16}]$ $\therefore a = [1\ 100\ 010\ 001\ 001\ 010\ 0\ 010\ 001\ 010\ 1\ 001\ 010\ 010\ 11\ 010]$																$b = [b_1]$ $\therefore b = [1]$	

Fonte: da própria autora.

Para preservar a identidade dos estudantes, sujeitos desta pesquisa, utilizou-se uma identificação numérica para cada um deles.

4.2 MODELAGEM DA REDE NEURAL ARTMAP-FUZZY APLICADA AO PROBLEMA DA EVASÃO

Após a construção da base de dados que delinea o problema da evasão discente, o processamento das informações, a extração do conhecimento e o diagnóstico preditivo dos estudantes em risco de evasão concentram-se na operacionalização da rede neural ARTMAP-Fuzzy.

Esse processo é realizado em duas fases: a fase de treinamento e a fase do diagnóstico preditivo dos estudantes propensos à evasão.

Na fase de treinamento, para a análise da evasão, a entrada da rede ARTMAP-Fuzzy é representada pelo vetor a (entrada do módulo ART_a) e sua respectiva saída desejada, representada pelo vetor b (entrada do módulo ART_b), sendo estes vetores descritos da seguinte maneira:

- Vetor padrão de entrada : $a = [a_1 a_2 a_3 a_4 \dots a_{15} a_{16}]$
- Saída desejada : $b = [b]$, sendo: $b = \text{“0”}$ ou “1”

O vetor padrão de entrada a é composto por 16 parâmetros ou atributos, representados pelos subvetores $a_1, a_2, a_3, \dots, a_{16}$. Esses subvetores são vetores linhas que contêm a representação binária das características dos estudantes, compondo o vetor de entrada a com 41 bits. Cada bit corresponde a um componente do vetor associado.

O vetor \mathbf{b} , saída desejada na fase de treinamento, é representado por apenas um componente, podendo assumir valores “0” ou “1”, de acordo com a situação acadêmica do estudante constante na base de dados, indicando, respectivamente, “não-evasão” e “evasão”.

Os vetores \mathbf{a} e \mathbf{b} constituem os estímulos da rede neural ARTMAP-*Fuzzy* na fase do treinamento.

Na fase do diagnóstico da evasão, o vetor padrão de entrada da rede neural é representado por \mathbf{a}_d e a saída da rede, por sua vez, é representada pelo vetor atividade da camada F_2^b (\mathbf{y}^b), assim definidos:

- Vetor padrão de entrada para o diagnóstico : $\mathbf{a}_d = [a_{d1} \ a_{d2} \ a_{d3} \ . \ . \ . \ a_{d15} \ a_{d16}]$
- Vetor de saída do diagnóstico : $\mathbf{y} = [y]$

Esse vetor \mathbf{y} é representado por um escalar “y”, e constitui a saída da rede ARTMAP-*Fuzzy* após o diagnóstico da evasão 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.

O código-fonte da rede neural ARTMAP-*Fuzzy* aplicada ao estudo e análise da evasão foi desenvolvido de maneira flexível, permitindo a inserção de novas variáveis e/ou substituição das variáveis utilizadas nesta pesquisa. Esta intencional flexibilidade foi idealizada com o intuito de socializar e permitir a aplicação do sistema de diagnóstico da evasão em outras instituições, cursos e níveis de ensino, resguardando suas especificidades. Essa ação permite encontrar os estímulos que geram os melhores resultados do diagnóstico e, conseqüentemente, o melhor desempenho da rede neural para cada situação analisada.

Ressalta-se que a concepção da rede neural, para aplicação nesta pesquisa, conforme mencionado anteriormente, é essencialmente binária, o que possibilita, a princípio, um treinamento mais rápido e um diagnóstico mais confiável, no sentido de assegurar uma solução para a situação apresentada.

Considerando a concepção binária, durante o pré-processamento dos dados de estímulos da rede, os vetores \mathbf{a} e \mathbf{b} não precisam ser normalizados, pois estão representados em código do padrão binário. Após a codificação de complemento, os vetores de entrada e saída desejada para o treinamento e os vetores de entrada para o diagnóstico são expressos conforme segue.

Para a fase do treinamento:

- Vetor padrão de entrada : $A = [a_1 \ a_2 \ \dots \ a_{16} \ a^c_1 \ a^c_2 \ \dots \ a^c_{16}]$
- Saída desejada : $B = [b]$, sendo: $b = "0"$ ou $"1"$

Para a fase do diagnóstico:

- Vetor padrão de entrada diagnóstico : $A_d = [a_{d1} \ a_{d2} \ \dots \ a_{d16} \ a^c_{d1} \ a^c_{d2} \ \dots \ a^c_{d16}]$

Os processos de ressonância, aprendizagem e atualização dos pesos seguem a dinâmica tradicional das redes baseadas na teoria da ressonância adaptativa, conforme descrito anteriormente.

A ferramenta utilizada nesta pesquisa (rede neural ARTMAP-*Fuzzy*) e os dados apresentados e processados por ela distinguem-se, diante do resultado da pesquisa bibliográfica realizada, do que existe na literatura, quanto à predição da evasão escolar, na modalidade presencial, no ensino superior. Assim, esta pesquisa contribui com o desenvolvimento de um novo método para predição da evasão escolar e, também, demonstra como sendo uma possibilidade exequível o diagnóstico precoce da evasão escolar utilizando os dados fornecidos pelos estudantes no ato da inscrição, ainda como candidatos ao curso pleiteado.

4.3 APLICAÇÃO DO SISTEMA NEURAL ARTMAP-*Fuzzy* PARA O DIAGNÓSTICO DA EVASÃO

Para o processamento da rede neural ARTMAP-*Fuzzy* e, conseqüentemente, o diagnóstico da evasão foi utilizado um microcomputador com sistema operacional Windows 7 Home Premium de 64 *Bits*, processador Intel (R) Core (TM) i7 - 2630, CPU de 2GHz e 4GB de memória RAM.

A aplicação do sistema preditivo para análise da evasão é realizada em duas fases: Fase de Treinamento e Fase de Diagnóstico.

Na fase de treinamento um conjunto de dados constituído por pares de padrões de entrada-saída desejada, oriundos da base de dados já construída, é apresentado como estímulo à rede neural. A rede neural ARTMAP-*Fuzzy* aprende com a experiência. Portanto, utiliza os pares de treinamento como exemplos para seu aprendizado. O treinamento é supervisionado

pelo módulo inter-ART da rede ARTMAP, buscando o “casamento” entre os estímulos de entrada e de saída apresentados a ela. Concluída a fase de treinamento pode-se realizar o diagnóstico preditivo dos estudantes propensos à evasão.

Para o treinamento foram utilizados dois conjuntos de dados, sendo:

- Treinamento I (T-I) - conjunto de dados com 1151 linhas e 42 colunas, composto pelas características dos estudantes matriculados nos CST do IFMT, com exceção dos estudantes de Automação e Controle, no período de 2004 a 2011.
- Treinamento II (T-II) - conjunto de dados com 389 linhas e 42 colunas, composto pelas características dos estudantes matriculados no CST em Automação e Controle, no período de 2004 a 2010.

Ressalta-se que, para o treinamento, cada linha representa os pares de vetores padrão de entrada e sua respectiva saída desejada, constituindo-se, cada um deles, em uma amostra ou estímulo para a rede. Os dados das colunas de 1 a 41 representam os atributos correspondentes ao vetor \mathbf{a} , entrada do módulo ART_a. Na coluna 42 estão representadas as saídas desejadas, vetor \mathbf{b} (entrada do módulo ART_b) da rede neural ARTMAP-*Fuzzy*.

Na fase do diagnóstico foram realizadas sete simulações, D-I a D-VII, com conjuntos de dados desconhecidos, ou seja, que não pertenciam à base de dados de treinamento, para a predição dos estudantes em risco de evasão, atribuindo-se o *status* “evasão” ou “não-evasão” para cada um deles. Para o diagnóstico o conjunto dos dados é formado por 41 colunas, haja vista que, *a priori*, não se conhece a saída correspondente ao vetor padrão de entrada.

Os dados utilizados para testar o sistema proposto são referentes aos estudantes do Curso Superior de Tecnologia em Automação e Controle do IFMT, contidos na base de dados previamente construída.

Os números que retratam o fenômeno da evasão no Curso de Automação estão compilados na Tabela 8.

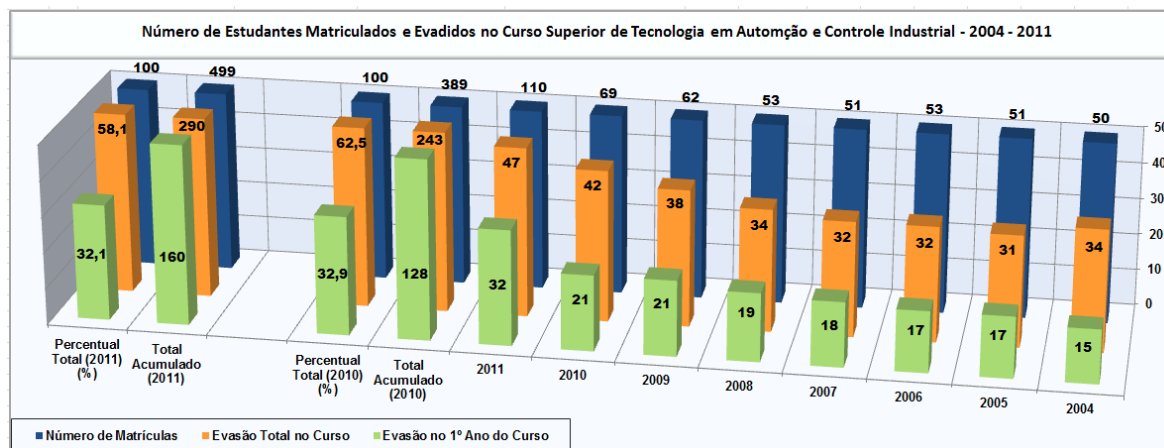
Tabela 8 - Números da evasão no CST em Automação e Controle do IFMT - 2004 a 2011.

Curso Superior de Tecnologia em Automação e Controle - IFMT			
Ano de Ingresso	Número de Matrículas	Evasão Total no Curso	Evasão no 1º Ano do Curso
2004	50	34	15
2005	51	31	17
2006	53	32	17
2007	51	32	18
2008	53	34	19
2009	62	38	21
2010	69	42	21
2011	110	47	32
Total Acumulado (2010)	389	243	128
Percentual Total (2010)	100 %	62,47 %	32,90 %
Total Acumulado (2011)	499	290	160
Percentual Total (2011)	100 %	58,12 %	32,06 %

Fonte: Q-Acadêmico.

Na Figura 19, ilustra-se graficamente a situação da evasão discente no Curso de Automação e Controle, no período de 2004 a 2011.

Figura 19 - Número de estudantes matriculados e evadidos no CST de Automação e Controle do IFMT - 2004 a 2011.



Fonte: Q-Acadêmico.

A composição do conjunto de estímulos para o treinamento da rede neural ARTMAP-*Fuzzy* e para o diagnóstico da evasão por meio dela, está baseada na real situação do curso, quanto à evasão. Na fase do diagnóstico da evasão e validação do sistema utilizou-se um conjunto de amostras com cerca de 30% a 45% da quantidade total das amostras do treinamento. Evidencia-se que, as amostras para o diagnóstico não fazem parte do conjunto de dados do treinamento, a referência percentual (entre 30% e 45%) refere-se somente à quantidade, ou seja, ao números de amostras utilizadas no treinamento e no diagnóstico. A indicação desses conjuntos de dados e um esboço das fases de treinamento e aplicação para o diagnóstico preditivo da evasão estão dispostos na Tabela 9.

Tabela 9 - Composição dos conjuntos de treinamento da rede neural ARTMAP-*Fuzzy* e diagnóstico da evasão.

Treinamento da Rede Neural ARTMAP- <i>Fuzzy</i>			Aplicação - Diagnóstico Preditivo da Evasão					
ID*	Sementes	Amostras Período	ID*	Amostras Período	Não-Evasão	Evasão Total	Evasão 1º Ano	Evasão 1º semestre.
T-I	1235 2014 4500 6900 9999	1151 2004-2011	D-I	389 2004 - 2010	146	243	-	-
			D-II	389 2004 - 2010	261	-	128	-
			D-III	499 2004 - 2011	209	290	-	-
			D-IV	499 2004 - 2011	339	-	160	-
			D-V	499 2004 - 2011	409	-	-	90
			D-VI	110 2011	63	47	-	-
T-II	750 1036 5678 9500 81420	389 2004-2010	D-VII	110 2011	63	47	-	-

(*) - (ID): Identificação do treinamento (T) e identificação do diagnóstico (D).

Fonte: da própria autora.

Os conjuntos de dados para análise do problema da evasão podem ser, por vezes, pequenos, ruidosos (errôneos ou com variações aleatórias) ou incompletos, como é o caso da aplicação proposta nesta pesquisa. Para assegurar que as predições geradas pela rede neural ARTMAP-*Fuzzy*, advindas destes conjuntos de dados, sejam confiáveis utilizou-se uma

estratégia que melhora a estimativa de confiabilidade, denominada “estratégia de votação” (24).

Essa estratégia de votação é baseada na observação de que a rede ARTMAP, durante o processo de aprendizagem rápida, geralmente, indica diferentes pesos adaptativos e diferentes categorias de reconhecimento para ordenações diferentes de um determinado conjunto de treinamento. As diferentes estruturas de categoria fazem com que a classificação dos atributos do conjunto de teste, onde os erros ocorrem, varie de uma simulação para a próxima (24).

A aplicação da estratégia de votação consiste em treinar a rede ARTMAP várias vezes (de acordo com Carpenter (24) cinco vezes são suficientes), com o mesmo conjunto de dados para o treinamento apresentado à rede com diferentes ordenações, ou seja, os vetores são apresentados à rede em ordem aleatória ou pseudoaleatória. A predição final para um determinado conjunto de teste é dada pelas respostas geradas com maior frequência, dentre as simulações realizadas. Uma vez que o conjunto de elementos sujeitos a predições errôneas varia de uma simulação para outra, a estratégia de votação anula muitos dos erros que ocorrem na fase de diagnóstico.

Nesta pesquisa, a estratégia de votação foi utilizada executando-se cinco treinamentos, sendo o conjunto de dados apresentado à rede em sequência natural e em ordem pseudoaleatória, através da variação da semente. A identificação do *status* da amostra em “evasão” e “não-evasão” foi adotada em função da maior incidência das classes “1” e “0”, respectivamente, construindo-se a saída da rede neural e resposta ao problema da evasão. 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.

A semente é uma subrotina contida no código-fonte da rede neural ARTMAP-*Fuzzy* com o objetivo de ordenar aleatoriamente a sequência em que os padrões de entrada de dados são processados pela rede. Com a variação da semente tem-se uma variação na sequência de processamento dos padrões de entrada.

Os parâmetros da rede ARTMAP-*Fuzzy* utilizados para os treinamentos T-I e T-II estão especificados na Tabela 10. Estes parâmetros foram definidos por meio do resultado de simulações da rede, foram adotados os valores que proporcionaram o melhor desempenho do sistema.

Tabela 10 - Valores dos parâmetros para o treinamento da rede neural ARTMAP-*Fuzzy*.

Parâmetros da Rede Neural ARTMAP- <i>Fuzzy</i>		
Parâmetros e Valores de Referência	Parâmetros do Treinamento	
	T-I	T-II
Parâmetro de escolha α ($\alpha > 0$)	0,001	0,01
Taxa de treinamento β ($\beta \in [0,1]$)	1,0	1,0
Parâmetro de vigilância inicial do módulo ART _a - ρ_{as} ($\rho_{as} \in [0,1]$)	0,2	0,2
Incremento do parâmetro de vigilância ρ_a (ε)	0,05	0,001
Parâmetro de vigilância do módulo ART _b - ρ_b ($\rho_b \in [0,1]$)	0,999	0,999
Parâmetro de vigilância do módulo inter-ART _{ab} - ρ_{ab} ($\rho_{ab} \in [0,1]$)	0,7	0,8

Fonte: da própria autora.

Concluída as fases do treinamento e do diagnóstico da evasão por meio de uma rede neural ARTMAP-*Fuzzy* os resultados foram compilados em tabelas e ilustrados graficamente. Os resultados dos processamentos e as análises pertinentes e necessárias à compreensão do comportamento da rede quanto à evasão e não-evasão discente serão apresentados e discutidos no próximo Capítulo.

AVALIAÇÃO DE DESEMPENHO DA REDE NEURAL ARTMAP-FUZZY E ANÁLISE COMPREENSIVA DOS RESULTADOS

*Se quisermos alcançar resultados nunca antes alcançados,
devemos empregar métodos nunca antes testados.*

Francis Bacon

Neste capítulo apresentar-se-á os resultados obtidos com a aplicação do sistema neural ARTMAP-*Fuzzy* para o diagnóstico preditivo da evasão escolar, considerando os dados dos estudantes do Curso Superior de Tecnologia em Automação e Controle do IFMT. Bem como, a análise compreensiva desses resultados e uma avaliação de desempenho da rede utilizada. Os critérios utilizados para avaliar o desempenho da rede quanto ao diagnóstico preditivo da evasão foram: acurácia global, sensibilidade ou eficiência e precisão. Após a avaliação da rede, os índices encontrados serão comparados com os resultados das pesquisas de Lykourantzou *et al.* (2009) (60) e Mustafa, *et al.* (2012) (61). Dentre as publicações encontradas na literatura, estas são as que mais se aproximam da proposta apresentada nesta pesquisa.

Ressalta-se que a intenção desta pesquisa é propor e disponibilizar um método eficiente para o diagnóstico preditivo da evasão discente, que produza resultados fidedignos, confiáveis e com alto índice de acurácia, podendo contribuir para que medidas proativas sejam adotadas no sentido de reduzir ou, até mesmo, mitigar o fenômeno da evasão.

5.1 CRITÉRIOS PARA AVALIAÇÃO DE DESEMPENHO

O desempenho do sistema neural ARTMAP-*Fuzzy* quanto ao diagnóstico preditivo da evasão discente foi avaliado considerando a medida de acurácia global apresentada pela rede,

a sensibilidade ou eficiência e a precisão da rede (60). Estes critérios utilizados para avaliação de desempenho estão descritos a seguir.

5.1.1 Acurácia Global (A_g)

O critério de acurácia global visa medir o percentual total de diagnósticos de evasão e não-evasão corretamente previstos pela rede neural, ou seja, avalia o desempenho do sistema preditor da evasão escolar quanto à taxa global de acertos nas predições, medindo o percentual de proximidade entre os números reais e os números obtidos experimentalmente quanto à evasão e não-evasão. A acurácia global é calculada usando-se a equação (20):

$$A_g = \frac{NAPe + NAPne}{NTAm} \times 100\% \quad (20)$$

sendo:

- A_g : Acurácia global dada em percentual (%);
- $NAPe$: Número de acertos na predição da evasão;
- $NAPne$: Número de acertos na predição da não-evasão;
- $NTAm$: Número total de amostras analisadas.

5.1.2 Sensibilidade (S)

O critério de sensibilidade foi adotado para medir a eficiência que a rede apresenta ao diagnosticar corretamente os estudantes em risco de evasão, ou seja, avalia a capacidade que a rede demonstra de apresentar a solução do problema com erro mínimo. O percentual de sensibilidade da rede é encontrado de acordo com (21):

$$S = \frac{NAPe}{NRe} \times 100\% \quad (21)$$

sendo:

- S : Sensibilidade da rede dada em percentual (%);

$NAPe$: Número de acertos na predição da evasão;

NRe : Número real de amostras de evasão.

5.1.3 Precisão (P)

Quando o sistema preditor da evasão identifica os estudantes ou as amostras propensas à evasão, podem ocorrer, na realidade, duas situações: 1 - os estudantes identificados como evadidos realmente evadiram, portanto a rede acertou a predição; ou, 2 - os estudantes identificados como evadidos estão frequentando o curso ou já se formaram, portanto a rede errou a predição.

Com o critério de precisão é possível avaliar o quanto dos estudantes identificados pela rede como evadidos realmente evadiram, ou seja, o quanto a rede é capaz de identificar os estudantes que realmente abandonam o curso. Quanto maior o percentual de precisão, mais confiável é o sistema, pois isso demonstra que ele é capaz de identificar e classificar como evasão apenas os estudantes que realmente evadem. A precisão da rede é calculada como mostrado em (22).

$$P = \frac{NAPe}{NEPe + NAPe} \times 100\% \quad (22)$$

sendo:

P : Precisão da rede dada em percentual (%);

$NAPe$: Número de acertos na predição da evasão;

$NEPe$: Número de erros na predição da evasão.

5.2 RESULTADOS EXPERIMENTAIS

A rede neural, do sistema neural ARTMAP-*Fuzzy* proposto, foi treinada com dois conjuntos de dados de treinamento, T-I e T-II. Com o treinamento T-I foram realizadas seis simulações e com o treinamento T-II uma simulação para o diagnóstico da evasão. Após as fases do treinamento (T) da rede neural e das simulações de diagnóstico (D) da evasão os

resultados foram compilados em tabelas e reproduzidos graficamente, sendo apresentados a seguir.

5.2.1 Resultados dos Diagnósticos (D) realizados após o Treinamento (T-I)

Para o treinamento T-I foram utilizadas 1151 amostras, que representam a totalidade das matrículas nos CST do IFMT, com exceção das matrículas no Curso de Automação e Controle, no período de 2004 a 2011. Os estudantes deste curso constituem o objeto de análise e diagnóstico da evasão, razão pela qual foram excluídos do conjunto de treinamento. Os resultados dos diagnósticos advindos desse treinamento são detalhados a seguir.

- **Diagnóstico (D-I)**

O conjunto de dados para o diagnóstico D-I foi composto por 389 amostras, no período de 2004 a 2010, tendo como objetivo identificar a evasão total do CST em Automação e Controle, nesse período. Os resultados são mostrados na Tabela 11.

Tabela 11 - Resultados quantitativos e em percentuais do diagnóstico da evasão total no período de 2004 a 2010.

Diagnóstico da Evasão Total 2004-2010	Saída da Rede - Resultado do diagnóstico D-I					
	Valores Quantitativos e Percentuais					
	Evasão Total		Não-Evasão		Total de Amostras	
	Quantidade	%	Quantidade	%	Quantidade	%
Amostras	243	100	146	100	389	100
Acertos	231	95,06	135	92,47	366	94,09
Erros	12	4,94	11	7,53	23	5,91

Fonte: da própria autora.

Analisando os resultados do diagnóstico D-I, transcritos para a Tabela 11, percebe-se que a rede apresentou 94,09% do total de diagnósticos corretos, classificando acertadamente, em evasão e não-evasão, 366 amostras de um total de 389 do conjunto de teste.

A evasão total no período analisado é representada por 243 amostras. Dentre estas, 231 amostras foram reconhecidas como possibilidades de evasão e 12 amostras evadidas não foram identificadas pela rede neural, acarretando uma taxa de acerto de 95,06%.

O índice de acertos para as amostras de não-evasão foi de 92,47%, sendo identificadas 135 amostras de não-evasão e “ignoradas” 11 amostras, de um total de 146 amostras realmente evadidas no período de 2004 a 2010.


Esta categoria do diagnóstico, a não-evasão, requer uma análise compreensiva mais minuciosa, pois o olhar ligeiro e superficial aponta que a rede errou em 11 predições. Sim, de fato, a rede errou em 11 predições de não-evasão, mas o que isso significa? Qual a compreensão desse erro? Será que não se constitui em um alerta?

Neste caso, quando se analisa a não-evasão identificada, lida-se com amostras de estudantes que ainda estão no curso ou que já graduaram, haja vista que no conjunto de teste algumas amostras fazem parte de turmas que ainda não concluíram o curso. Portanto, a situação de não-evasão do conjunto de testes se refere ao período em análise, logo essa condição poderá se tornar evasão em um período subsequente ou posterior ao da análise.

Assim, as 11 predições “erradas” ou “ignoradas” pela rede neural podem constituir um alerta de que aquelas amostras (estudantes) fazem parte do grupo de risco evasivo. Essa percepção será essencial quando da análise da evasão discente em turmas que estão em processo de andamento no curso.

Os resultados quantitativos e em percentuais do diagnóstico preditivo da evasão total no período de 2004 a 2010 podem ser percebidos, mais claramente, nos gráficos da Figura 20.

Figura 20 - Resultados quantitativos e em percentuais do diagnóstico da evasão total no período de 2004 a 2010.



Fonte: da própria autora.

- **Diagnóstico (D-II)**

No diagnóstico D-II buscou-se identificar a evasão ocorrida no 1º ano do CST em Automação e Controle, acumulada no período de 2004 a 2010, utilizando-se o mesmo

conjunto de dados do diagnóstico D-I. Na Tabela 12 são apresentados os resultados do diagnóstico.

Tabela 12 - Resultados quantitativos e em percentuais do diagnóstico da evasão no 1º ano do curso - acumulada no período de 2004 a 2010.

Diagnóstico da Evasão no 1º Ano Acumulada 2004-2010	Saída da Rede - Resultado do diagnóstico D-II Valores Quantitativos e Percentuais					
	Evasão no 1º Ano		Não-Evasão		Total de Amostras	
	Quantidade	%	Quantidade	%	Quantidade	%
Amostras	128	100	261	100	389	100
Acertos	124	96,88	135	51,72	259	66,58
Erros	4	3,13	126	48,28	130	33,42

Fonte: da própria autora.

No período compreendido entre 2004 e 2010 o conjunto de teste para o diagnóstico preditivo da evasão foi composto por 389 amostras. Considerando os resultados transcritos na Tabela 12, pode-se inferir que a rede neural foi capaz de diagnosticar corretamente 96,88% da incidência de evasão no 1º ano do curso, reconhecendo corretamente 124 amostras de evasão, das 128 amostras em situação real de evasão.

Para identificar a evasão ocorrida no 1º ano do CST em Automação e Controle, acumulada no período de 2004 a 2010, apresentou-se à rede um conjunto de testes com todas as amostras do período, ou seja, utilizou-se uma amostra global para uma investigação específica. Portanto, o diagnóstico de não-evasão apresentado pela rede refere-se às amostras que não evadiram em todo interstício de tempo analisado e não, especificamente, a não-evasão ocorrida e acumulada nos primeiros anos do curso, conforme pode ser constatado na Tabela 11.

Assim, os resultados deste diagnóstico D-II não serão considerados quanto à análise da situação de não-evasão e índices de acerto global da rede neural, pois levaria a uma inferência distorcida quanto ao desempenho da rede neural ARTMAP-*Fuzzy* para a predição da evasão discente.

A motivação para este diagnóstico foi a necessidade e a oportunidade de testar, verificar e comprovar o potencial que o sistema neural ARTMAP-*Fuzzy* possui em prever as possíveis ocorrências de evasão ainda nos semestres iniciais do curso. Nesta simulação

96,88% das situações de evasão nos primeiros anos do curso foram identificadas corretamente.

- **Diagnóstico (D-III)**

Para os diagnósticos D-III, D-IV e D-V utilizou-se o mesmo conjunto de dados a ser diagnosticado, sendo este constituído por 499 amostras, entre 2004 e 2011. Diagnosticar a evasão total, acumulada no período das amostras, foi o objetivo da simulação D-III. Seus resultados podem ser observados na Tabela 13.

Tabela 13 - Resultados quantitativos e em percentuais do diagnóstico da evasão total no período de 2004 a 2011.

Diagnóstico da Evasão Total 2004-2011	Saída da Rede - Resultado do diagnóstico D-III Valores Quantitativos e Percentuais					
	Evasão Total		Não-Evasão		Total de Amostras	
	Quantidade	%	Quantidade	%	Quantidade	%
Amostras	290	100	209	100	499	100
Acertos	276	95,17	195	93,30	471	94,39
Erros	14	4,83	14	6,70	28	5,61

Fonte: da própria autora.

A leitura, interpretação e análise dos dados contidos na Tabela 13 mostram que de um total de 499 amostras, 290 delas correspondem a estudantes evadidos e, 209 amostras representam estudantes já graduados ou em curso, ou seja, não evadidos, no período de 2004 a 2011.

Das 290 amostras de evasão, o sistema neural preditivo proposto identificou corretamente 276 possibilidades de evasão e desconsiderou 14 ocorrências de evasão, alcançando um índice de acerto de 95,17%.


Dentre as 209 amostras de não-evasão, a rede proposta reconheceu 195 amostras nessa situação e não atingiu o alvo em 14, acertando 93,3% dos casos. Isso significa uma indicação de que ainda poderão ocorrer outros 14 casos de evasão, dentre as amostras do período analisado.

Nesta simulação a rede ARTMAP-*Fuzzy* alcançou um percentual de acerto global de 94,39%, encontrando corretamente 471 amostras de um total de 499. Os índices de acertos

encontrados neste diagnóstico corroboram os resultados do diagnóstico D-I.

Os resultados quantitativos e em percentuais do diagnóstico preditivo de estudantes com possibilidades de evasão podem ser percebidos, com maior clareza, nos gráficos da Figura 21.

Figura 21 - Resultados quantitativos e em percentuais do diagnóstico da evasão total no período de 2004 a 2011.



Fonte: da própria autora.

- **Diagnóstico (D-IV)**

Na Tabela 14 estão registrados os resultados do diagnóstico D-IV, relativo à predição da evasão no 1º ano do curso, acumulada entre 2004 e 2011.

Tabela 14 - Resultados quantitativos e em percentuais do diagnóstico da evasão no 1º ano do curso - acumulada no período de 2004 a 2011.

Diagnóstico da Evasão no 1º Ano Acumulada 2004-2011	Saída da Rede - Resultado do diagnóstico D-IV					
	Valores Quantitativos e Percentuais					
	Evasão no 1º Ano		Não-Evasão		Total de Amostras	
	Quantidade	%	Quantidade	%	Quantidade	%
Amostras	160	100	339	100	499	100
Acertos	154	96,25	195	57,52	349	69,94
Erros	6	3,75	144	42,48	150	30,06

Fonte: da própria autora.

Observando-se os registros na Tabela 14, percebe-se que a rede apontou corretamente 154 amostras de evasão, das 160 realmente ocorridas, acertando 96,25% dos casos de evasão.

Com o conjunto de teste processado e utilizado para este diagnóstico não é possível inferir corretamente sobre as 339 amostras de não-evasão apresentadas na Tabela 14. O

resultado obtido, 195 amostras de não-evasão, já identificados na Tabela 13, representa o número de estudantes já graduados ou em curso, ou seja, estudantes não evadidos, no período de 2004 a 2011, e não especificamente nos primeiros anos do curso

Os índices de acertos e erros do diagnóstico de não-evasão e acerto global da rede, contidos na Tabela 14, considerados isoladamente, induzem a uma interpretação errônea e equivocada do desempenho da sistema neural ARTMAP-*Fuzzy* para predição da evasão.

O interesse quanto a esse diagnóstico e sua contribuição foi a constatação da capacidade da rede em realizar o diagnóstico preditivo da evasão no primeiro ano do curso, indicando corretamente 96,25% das situações de evasão.

- **Diagnóstico (D-V)**

O que se pretende com este diagnóstico é verificar o comportamento da rede neural quanto a predição da possibilidade de ocorrência da evasão no 1º semestre do CST em Automação e Controle, no período de 2004 a 2011. O resultado do diagnóstico D-V está representado na Tabela 15.

Tabela 15 - Resultados quantitativos e em percentuais do diagnóstico da evasão no 1º semestre do curso - acumulada no período de 2004 a 2011.

Diagnóstico da Evasão no 1º Semestre Acumulada 2004-2011	Saída da Rede - Resultado do diagnóstico D-V					
	Valores Quantitativos e Percentuais					
	Evasão no 1º Sem.		Não-Evasão		Total de Amostras	
	Quantidade	%	Quantidade	%	Quantidade	%
Amostras	90	100	409	100	499	100
Acertos	88	97,78	195	47,68	283	56,71
Erros	2	2,22	214	52,32	216	43,29

Fonte: da própria autora.

Analisando os resultados do diagnóstico D-V, apresentados na Tabela 15, observa-se que de um total de 499 amostras, matrículas no período de 2004 a 2011, 90 delas correspondem a estudantes evadidos no 1º semestre do curso e as 409 amostras de não-evasão representam a soma dos estudantes não evadidos em cada 1º semestre do curso, no período mencionado.

Das 90 amostras de evasão, no 1º semestre do curso, o sistema proposto identificou 88

possibilidades de evasão e ignorou 2, obtendo um índice de acerto de 97,8%.

De maneira análoga ao exposto na análise do diagnóstico D-IV, não é possível inferir corretamente sobre as 409 amostras de não-evasão apresentadas na Tabela 15. O resultado obtido, 195 amostras de não-evasão, representa, conforme já mencionado, o número de estudantes já graduados ou em curso, ou seja, estudantes não evadidos, no período de 2004 a 2011, e não especificamente nos primeiros semestres do curso.

Neste diagnóstico, o que é relevante para a análise é a capacidade demonstrada pela rede neural de identificar precocemente a evasão, ainda no 1º semestre do curso, com um índice de acerto de 97,8%.

- **Diagnóstico (D-VI)**

Na simulação D-VI foi apresentado à rede um conjunto de teste formado por 110 amostras, que representam o total de matrículas no ano letivo de 2011. A evasão ocorrida neste ano foi identificada e apresentada na Tabela 16.

Tabela 16 - Resultados quantitativos e em percentuais do diagnóstico da evasão no ano letivo de 2011 - com o treinamento T-I.

Diagnóstico da Evasão no Ano Letivo de 2011	Saída da Rede - Resultado do diagnóstico D-VI					
	Valores Quantitativos e Percentuais					
	Evasão		Não-Evasão		Total de Amostras	
	Quantidade	%	Quantidade	%	Quantidade	%
Amostras	47	100	63	100	110	100
Acertos	46	97,87	58	92,06	104	94,55
Erros	1	2,13	5	7,94	6	5,45

Fonte: da própria autora.

Nesta simulação, diferentemente dos diagnósticos D-II, D-IV e D-V, pode-se inferir sobre as situações de evasão e não-evasão no primeiro ano do curso, pois as amostras do conjunto de teste são todas e tão-somente do primeiro ano do curso.


O conjunto de teste possui 110 amostras, das quais 47 amostras correspondem a incidência de evasão e 63 amostras a não-evasão. A rede classificou corretamente 46 amostras de evasão e 58 de não-evasão, obtendo índices de acerto de 97,87% e 92,06%, respectivamente. As 5 amostras incorretas na categoria de não-evasão podem representar

situações futuras de evasão, incluindo essas amostras no grupo de risco dos estudantes propensos à evasão.

No total das amostras a rede diagnosticou de maneira correta, entre evasão e não-evasão, 104 amostras, o que corresponde a um índice de acerto de 94,55%.

Os resultados qualitativos e quantitativos do diagnóstico D-VI podem ser observados graficamente na Figura 22.

Figura 22 - Resultados quantitativos e em percentuais do diagnóstico da evasão no ano letivo de 2011 - com o treinamento T-I.



Fonte: da própria autora.

Considerando as simulações, D-I até D-VI, realizadas com o conjunto de treinamento T-I, observa-se que em todas elas o sistema neural ARTMAP-*Fuzzy* consegue realizar o diagnóstico preditivo da evasão, desde os primeiros anos, de maneira satisfatória, com índice de acertos entre 92% e 97%. O conjunto de teste do diagnóstico D-VI apresentou o melhor resultado para a evasão no primeiro ano do curso, apesar de ser composto pela menor quantidade de amostras, todas elas faziam parte e estavam contidas tão-somente no conjunto de teste relativo ao período da análise em questão.

5.2.2 Resultado do Diagnóstico D-VII Realizado após o Treinamento T-II

O treinamento T-II foi realizado utilizando 389 amostras, composta por estudantes matriculados no CST em Automação e Controle, no período de 2004 a 2010. Após o treinamento da rede com este conjunto de amostras foi realizada a simulação para diagnóstico D-VII.

- **Diagnóstico (D-VII)**

Para o diagnóstico D-VII foi utilizado o mesmo conjunto de dados da simulação D-VI, ou seja, 110 amostras relativas ao total de matrículas no ano letivo de 2011. A evasão ocorrida em 2011 foi diagnosticada, também, na simulação D-VII e apresentada na Tabela 17.

Tabela 17 - Resultados quantitativos e em percentuais do diagnóstico da evasão no ano letivo de 2011 - com o treinamento T-II.

Diagnóstico da Evasão no Ano Letivo de 2011	Saída da Rede - Resultado do diagnóstico D-VII Valores Quantitativos e Percentuais					
	Evasão		Não-Evasão		Total de Amostras	
	Quantidade	%	Quantidade	%	Quantidade	%
Amostras	47	100	63	100	110	100
Acertos	47	100	60	95,24	107	97,27
Erros	0	0	3	4,76	3	2,73

Fonte: da própria autora.

Analisando os resultados apontados na Tabela 17, percebe-se que a rede acertou 100% das amostras de evasão e 95,24% das amostras de não-evasão, atingindo um índice de 97,27% de acerto geral.

Com o resultado deste diagnóstico, de um total de 110 amostras, 50 amostras deveriam fazer parte do grupo de risco de evasão discente identificadas pela aplicação e diagnóstico do sistema neural preditivo da evasão. Dessas 50 amostras, 47 fazem parte do grupo dos concretamente evadidos e 3 estão entre as amostras que na realidade ainda estão frequentando o curso, porém estão em risco de evasão segundo a identificação e análise da rede.


Os resultados quantitativos e percentuais da simulação D-VII podem ser visualizados na Figura 23.

Nesta simulação a rede foi treinada somente com os dados do CST em Automação e Controle e foi realizado o diagnóstico da evasão para o mesmo curso. O resultado, registrado na Tabela 17, foi superior aos resultados das demais simulações realizadas nesta pesquisa.

Diante das circunstâncias em que as simulações foram realizadas, uma dedução e inferência quanto a esse superior desempenho no diagnóstico D-VII, que se acredita plausível, esta relacionado com as especificidades da evasão para ou em cada curso. Nos diagnósticos D-I até D-VI buscava-se identificar a evasão no CST em Automação e Controle com um

conjunto de dados de treinamento dos demais curso de tecnologia. No diagnóstico D-VII aliou-se os dados do treinamento e o conjunto de teste ao mesmo curso.

Figura 23 - Resultados quantitativos e em percentuais do diagnóstico da evasão no ano letivo de 2011 - com o treinamento T-II.



Fonte: da própria autora.

Em síntese, a aplicação do sistema neural ARTMAP-*Fuzzy* para o diagnóstico preditivo da evasão discente pode ser generalizada para todos os CST do IFMT. Ressaltando-se que o treinamento com dados específicos de cada curso poderá proporcionar uma resposta ainda melhor na predição da evasão para o curso em questão.

5.3 AVALIAÇÃO DO DESEMPENHO DO SISTEMA NEURAL ARTMAP-*FUZZY* PROPOSTO

Considerando os resultados dos treinamentos e diagnósticos para a predição da evasão escolar discente por meio do sistema neural ARTMAP-*Fuzzy* foi possível fazer a avaliação de seu desempenho. A medida de acurácia global (Ag) apresentada pela rede, a sensibilidade (S) ou eficiência e a precisão (P) da rede (60) foram os critérios adotados para avaliar o desempenho do sistema. Estes índices de desempenho apresentados pelo sistema estão dispostos na Tabela 18.

Observando a Tabela 18 nota-se que algumas de suas células estão hachuradas. Os valores nelas existentes induzem a uma interpretação errônea e equivocada do sistema e, portanto, não serão utilizados na medida de desempenho da rede.

Analisando os demais índices de desempenho do sistema neural para o diagnóstico da evasão discente, contidos na Tabela 18, percebe-se que os três critérios adotados para avaliar o desempenho do sistema estão acima de 91%.

Tabela 18 - Índices de desempenho do sistema neural ARTMAP-*Fuzzy*.

Etapas do Processamento da Rede Neural ARTMAP- <i>Fuzzy</i>		Critérios para Avaliação de Desempenho		
Treinamento	Diagnóstico	Acurácia global (Ag) (%)	Sensibilidade (S) (%)	Precisão (P) (%)
T-I	D-I	94,09	95,06	90,95
	D-II	66,58	96,88	48,81
	D-III	94,39	95,17	90,79
	D-IV	69,94	96,25	50,65
	D-V	56,71	97,78	28,95
	D-VI	94,55	97,87	88,46
T-II	D-VII	97,27	100	94
Índices Médios de Desempenho (errôneos)		81,93	97	70,37
Índices Médios de Desempenho (válidos)		95,08	97,03	91,05

Fonte: da própria autora.

A acurácia global do sistema variou entre 94% e 97%, mantendo um índice percentual médio em torno de 95%, para as simulações e diagnósticos realizados nesta pesquisa. Este critério indica, no geral, o quanto os acertos de evasão e não-evasão encontrados pelo sistema estão próximos das situações reais de evasão e não-evasão. Neste caso, por exemplo, para cada cem diagnósticos o sistema consegue reconhecer e classificar corretamente em média 95 amostras.

Pode-se inferir, baseado no índice de acurácia global médio (95%), que o sistema neural preditor da evasão demonstrou ser confiável, retratando de maneira fidedigna a realidade da evasão escolar para as situações analisadas.

A capacidade do sistema preditor de identificar corretamente as amostras em risco de evasão, com um reduzido índice de erro, foi comprovada por meio do critério da sensibilidade, que nesta pesquisa atingiu uma média de 97%, com faixa de variação entre 95% e 100%. Este índice de desempenho demonstra o quanto das situações reais de evasão são acertadamente diagnosticadas pelo sistema.

O índice médio de sensibilidade (97%), apresentado nas simulações, permite a dedução de que o sistema neural ARTMAP-*Fuzzy* é um sistema eficiente, ou seja, capaz de

gerar uma solução real, útil e correta para o problema da evasão e com baixo número de erros em seu diagnóstico.

O critério de precisão determina o rigor e o grau de exatidão com que as amostras de evasão são identificadas. Nesta pesquisa, o índice de precisão esteve entre 89% e 94%, estabelecendo uma média em torno de 91%.

Diante da análise dos critérios de desempenho pode-se inferir que o sistema neural ARTMAP-*Fuzzy*, utilizado com um sistema preditor de evasão, é um sistema confiável, acurado, fidedigno, eficiente e preciso.

5.4 ANÁLISE COMPARATIVA COM RESULTADOS DA LITERATURA

O desempenho do sistema preditivo proposto nesta pesquisa foi constatado após análise dos resultados apresentados pela rede neural do sistema e a aplicação dos critérios adotados como indicadores de desempenho.

Com o objetivo perceber a profícua contribuição desta pesquisa, quanto a proposta de uma nova metodologia para o diagnóstico preditivo da evasão discente em cursos superiores presenciais, foi realizada uma comparação com resultados de investigações encontrados na literatura.

Dentre as publicações mais recentes, encontradas na literatura, consideradas na revisão bibliográfica para esta investigação, as que parcialmente se aproximam da proposta apresentada nesta pesquisa e que possibilitam mensurá-la qualitativamente são os trabalhos de Lykourantzou *et al.* (2009) (60) e Mustafa, *et al.* (2012) (61). Para melhor visualização e posterior análise comparativa, as características mais relevantes e os resultados das três pesquisas foram compilados e registrados na Tabela 19.

Analisando o conteúdo da Tabela 19, pode-se inferir que os índices de desempenho apresentados pelo método proposto nesta pesquisa são qualitativamente, em sua essência, significância e representatividade superiores aos relatados nas investigações em comparação. Esclarecendo, o método proposto utiliza apenas uma técnica, a rede neural ARTMAP-*Fuzzy*, com atributos invariáveis no tempo, apresentando índices de desempenho acima de 90% para o diagnóstico tanto dos conjuntos de teste das séries iniciais do curso quanto para o diagnóstico das amostras totais.

Tabela 19 - Características e resultados - métodos preditivos da evasão escolar.

Características	Métodos Preditivos da Evasão Discente				
	Lykourantzou <i>et al.</i> (2009) (60)	Mustafa, <i>et al.</i> (2012) (61)	Método Proposto nesta Pesquisa		
Nível de Educação	- Superior	- Superior	- Superior		
Modalidade de Ensino	- e-learning	- Clássica Presencial	- Clássica Presencial		
Técnica Empregada	- Rede Neural <i>Feedforward</i> - Máquina de Vetor de Suporte - Rede Neural ARTMAP Simplificada	- Árvores de Classificação e Regressão	- Rede Neural ARTMAP- <i>Fuzzy</i>		
Atributos Invariantes no Tempo	- Faixa Etária - Sexo - Procedência - Situação de Trabalho - Escolaridade - Nota do Ens. Médio	- Faixa Etária - Sexo - Apoio Financeiro - Deficiência (PNE)	- Faixa etária - Sexo - Etnia - Nº pessoas/casa - Renda Familiar - Tem Computador - Escolaridade dos pais - Escola de Origem - Autoavaliação - Procedência - Dist. Esc.- Resid. - Meio Transporte - Situação Trabalho - Turno de Estudo - Alunos/ Sala		
Atributos Invariantes no Tempo	-	-	-		
Atributos Variantes no Tempo (características dos estudantes durante curso, coletadas online)	- Notas de testes multiescolha - Nota de projetos - Capacidade de cumprir prazos - Avaliação das atividades durante o curso	- Neste método não se aplica.	- Neste método não se aplica.		
-	Invariantes Tempo	Variantes Tempo		-	
		Fases Iniciais	Fases Finais	-	
Acurácia global (<i>Ag</i>) (%)	41 - 50 (66)	75 - 82 (79)	97	38,1	94 - 97,5 (95,1)
Sensibilidade (<i>S</i>) (%)	60 - 63 (61,5)	70 - 74 (72)	95-100 (97,5)	53,85	95 - 100 (97,5)
Precisão (<i>P</i>) (%)	43	64 - 88 (76)	88 - 100 (94)	25,92	90 - 95,5 (94)

Características	Métodos Preditivos da Evasão Discente		
	Lykourantzou <i>et al.</i> (2009) (60)	Mustafa, <i>et al.</i> (2012) (61)	Método Proposto nesta Pesquisa
Observações	<ul style="list-style-type: none"> - Entradas compostas somente com dados invariantes no tempo, e não forneceram resultados com desempenho significativo. - Para os métodos adotados, os dados invariantes no tempo são indicadores menos precisos na predição da evasão, em comparação com os dados variantes no tempo obtidos com o progresso do curso. 	<ul style="list-style-type: none"> - Árvores de decisão baseadas somente nos dados de matrícula não são boas na classificação de estudantes bem ou mal sucedidos. - A precisão não foi muito boa. - Em outras pesquisas incluir: etnia, escolaridade, situação de trabalho e ambiente de estudo. 	<ul style="list-style-type: none"> - As entradas são compostas somente com dados invariantes no tempo e apresentaram desempenho satisfatório.

Obs. Os índices de desempenho registrados para a investigação de Lykourantzou *et al.* (2009) foram os maiores encontrados em sua pesquisa, dentre as três técnicas utilizadas.

Fonte: Colunas 2 e 3 Lykourantzou *et al.* (2009) e Mustafa, *et al.* (2012), respectivamente, e coluna 4 da própria autora.

No relato de Lykourantzou *et al.* (2009) os índices de desempenho das técnicas utilizadas, com entradas compostas somente com dados invariantes no tempo, estiveram entre 41% e 63%, ou seja, não forneceram resultados com desempenho significativo. Para melhorar os índices de desempenho das técnicas empregadas para o diagnóstico da evasão, os conjuntos de dados foram compostos por atributos variantes no tempo, coletados de maneira contínua e *on-line*, tendo em vista que se trata de uma análise para cursos e-learning.

A investigação realizada por Mustafa, *et al.* (2012) foi em um curso na modalidade presencial, com reduzidos atributos não-variantes no tempo, utilizando árvores de classificação e regressão. Os resultados produzidos demonstraram que as técnicas utilizadas, baseadas somente nos dados de matrícula, não são eficientes para classificar os estudantes quanto à evasão, atingindo índices de desempenho entre 26% e 54%. Sugere a aplicação de redes neurais para a análise em questão e a inclusão de atributos como etnia, escolaridade, situação de trabalho e ambiente de estudo na composição da base de dados.

Percebe-se que a seleção e união dos atributos que compõem a base de dados utilizada nesta pesquisa e a junção com a rede neural ARTMAP-*Fuzzy* para aplicação ao problema da evasão, fortaleceram o sistema neural proposto para predição da evasão, produzindo resultados com índices de desempenho qualitativamente bem melhores que os encontrados na literatura.

Destaca-se, portanto, que frente aos trabalhos científicos sobre os métodos preditivos da evasão, a inovação, a pertinência, a audácia e a pujança científica desta pesquisa estão na utilização de uma rede neural *ARTMAP-Fuzzy*, com uma base de dados composta essencialmente por dados da inscrição do candidato, como possibilidade de identificar precoce e acuradamente, ainda no primeiro semestre do curso, os estudantes do ensino superior presencial propensos à evasão.

Apesar da constatação da consistência dos resultados, da acurácia e da eficiência do sistema, lidar com a predição da evasão escolar é lidar com a previsão de ações advindas de deliberações, decisões e livre arbítrio de seres humanos. Portanto, reconhecem-se as limitações da metodologia e suas possíveis falhas, haja vista que as previsões fogem ao completo determinismo, sendo a evasão o resultado de um processo estocástico.

As considerações finais sobre a pesquisa, a conclusão e as ideias para trabalhos futuros serão evidenciadas no capítulo seguinte.

CONSIDERAÇÕES FINAIS

*Lutemos por um mundo novo...
um mundo bom que a todos assegura o ensejo de trabalho,
que dê futuro a juventude e segurança à velhice.*

Charles Chaplin

Apresentar-se-á, nesta seção, o arremate do processo de construção de algo, que no início era meramente uma ideia, talvez até utópica, o vislumbre de contribuir com a possibilidade de gerar oportunidades que propiciem o exercício da cidadania com dignidade. Essa ideia se materializou, tomou consistência, ganhou corpo e forma, constituindo-se em um projeto de pesquisa. O projeto se norteou na busca de uma proposta de solução exequível para o problema da evasão escolar discente. O desafio, aliar uma técnica, no escopo da Engenharia, a uma aplicação prática, no real concreto da Educação. Não foi fácil, mas foi possível. Um sistema neural ARTMAP-*Fuzzy* capaz de prever o grupo de estudantes em risco de evasão, utilizando-se basicamente as informações fornecidas pelo candidato no ato de sua inscrição, foi concebido, desenvolvido e tornou-se real. Os resultados foram avaliados utilizando-se três critérios de desempenho e aferidos por meio da comparação com relatos de pesquisas encontradas na literatura. Chegou-se ao ponto de síntese e fechamento de um processo; porém, com possibilidades futuras de novos trabalhos, que serão evidenciadas ao final deste capítulo.

6.1 CONCLUSÃO

Nesta pesquisa foi desenvolvido um novo método para predição da evasão escolar baseado na Teoria da Ressonância Adaptativa (ART). O sistema neural ARTMAP-*Fuzzy* é capaz de identificar, de maneira proativa, continuada e acurada, o grupo de risco de evasão

discente, da educação clássica-presencial, no ensino de nível superior, utilizando uma base de dados composta basicamente por informações fornecidas pelo candidato no ato de sua inscrição.

A análise dos resultados e a avaliação de desempenho demonstrou que o sistema proposto é robusto, eficiente e com significativo grau de confiabilidade. Alcançou índices médios de acurácia global, sensibilidade e precisão, em torno de 95%, 97% e 91%, respectivamente, possibilitando identificar precocemente, ainda no primeiro semestre do curso, o grupo de estudantes em risco de evasão.

A identificação antecipada desse grupo de estudantes propicia que a instituição de ensino, juntamente com uma equipe multidisciplinar, possa articular uma rede de apoio psicossocial, econômico e educacional envolvendo os estudantes pertencentes ao grupo de risco evasivo, intervindo nesse processo na tentativa de minimizar o índice de evasão. Vislumbrando, inclusive, o desenvolvimento de programas de apoio que possam atender as necessidades específicas dos novos estudantes que se matricularem na instituição.

Observa-se que não se identificou, na literatura pesquisada, nenhuma proposta de sistema de predição com as características e peculiaridades do sistema desenvolvido nessa pesquisa. O confronto dos resultados obtidos nesta pesquisa com relatos de outras pesquisas encontradas na literatura foi possível levando-se em conta que algumas particularidades das mesmas são contempladas pelo sistema proposto. A parametrização dos resultados demonstra a qualidade e relevância do sistema neural ARTMAP-*Fuzzy*, com índices de desempenho qualitativamente bem melhores do que os encontrados na literatura. Portanto, evidencia-se que esta proposta 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.

Frente aos resultados obtidos, acredita-se que o método pode ser estendido e recomendado para implementação a outros grupos onde se observam consideráveis níveis de evasão, ajustando-o para as especificidades de cada grupo a ser investigado.

Uma limitação do sistema proposto é a dificuldade na obtenção e compilação dos dados para a composição da base de dados. A implementação de um sistema de coleta de dados *online*, pode ser a solução de melhoria quanto a essa questão.

Em síntese, a inovação, a pertinência, a audácia e a pujança científica desta pesquisa estão na utilização de uma Rede Neural ARTMAP-*Fuzzy*, com uma base de dados composta,

essencialmente, por dados advindos da inscrição do candidato, e que possibilitem identificar precoce e acuradamente, ainda no primeiro semestre do curso, os estudantes do ensino superior presencial propensos à evasão. E, ainda, respondendo a pergunta inicial, “em que medida e aspecto o sistema poderá contribuir efetivamente para manter o estudante na instituição e minimizar o fenômeno da evasão escolar?”.

Acredita-se, fortemente, que identificando precoce e precisamente os estudantes com potencial evasivo é possível adotar um conjunto de medidas e estratégias de intervenção proativas e individualizadas, com o intuito de reduzir os índices de evasão ou, até mesmo, mitigar este fenômeno. A predição da evasão possibilita atender individualmente cada estudante, suprimindo suas necessidades específicas e possibilitando sua permanência na instituição, tornando as medidas adotadas mais eficazes, contribuindo-se, assim, com algo que seja útil para a sociedade. Haja vista que, com uma ação proativa, conseguir com que um estudante, com potencial de evadir, tenha sucesso é uma missão nobre, pois são sonhos que se realizam, minimizando os prejuízos sociais, acadêmicos e financeiros advindos da evasão e contribuindo para o nível de escolaridade no país.

Ademais, a concretude desta pesquisa e sua aplicabilidade constitui-se uma experiência instituinte permeada pela prática da alteridade, tendo em vista que se trata de um instrumento inédito, que possibilita a ultrapassagem de situações-limite no que se refere a história de vida dos discentes, no tocante à possibilidade de superação da cultura do abandono em vista da instauração de projetos educativos possíveis de serem trilhados e, também, o exercício da alteridade no sentido de ser capaz de apreender o outro na plenitude da sua dignidade, dos seus direitos e das suas diferenças, considerando e valorizando suas experiências particulares.

6.2 SUGESTÕES PARA TRABALHOS FUTUROS

A resolução do problema sobre a predição de grupo de risco de evasão discente, baseada no emprego da rede neural ARTMAP-*Fuzzy*, demonstrou-se eficiente, acurado e com altos índices de desempenho, conforme os resultados apresentados e discutidos anteriormente. Porém, acredita-se que o mesmo possa se tornar ainda mais robusto com a implementação de algumas melhorias, sugeridas a seguir:

- Implementar uma rede neural ART-*Fuzzy* (módulo não-supervisionado) na arquitetura do sistema de predição atual, como mecanismo que possibilita a categorização da base de dados brutos e a transformação dos dados analógicos em dados binários, baseado em um dispositivo denominado código-ativo (24);
- Implementar, na saída do sistema de predição atual, um módulo baseado na Teoria da Evidência de Dempster-Shafer (TDS) (30) e, posteriormente, um módulo da Lógica *Fuzzy* (29), com o objetivo de identificar quais dos atributos considerados no diagnóstico são mais significativos na decisão de evasão. Testar o desempenho e inferir sobre a eficácia de cada um dos dois módulos quanto ao diagnóstico da evasão;
- Estudar e implementar um sistema de treinamento com uma estrutura de redes neurais modulares, inserindo no sistema uma sub-rede para cada curso em análise, considerando a especificidade de cada curso para o qual será realizada a predição da evasão escolar;
- Desenvolver estratégias para a implementação do sistema de coleta de dados *on-line*;
- Melhorar o sistema de predição proposto implementando o módulo de treinamento continuado, eliminando a necessidade de retreinar a rede quando novos padrões são considerados e, tirando proveito das características de plasticidade e de estabilidade apresentadas pelas redes ART;
- Implementar o sistema proposto em outras instituições e/ou cursos de diferentes especificidades que apresentem índices de evasão consideráveis;
- Propor, ao gestor do IFMT, a criação de gerências de “retenção”, para que se possa implementar o sistema proposto, acompanhar e assistir os estudantes diagnosticados como propensos à evasão e, assim, gerenciar o fenômeno da evasão em todos os câmpus da instituição;
- Propor mecanismos de intervenção e suporte para atendimento dos estudantes visando à mitigação do fenômeno e do processo de evasão escolar e a manutenção do estudante na instituição.

REFERÊNCIAS

As referências estão organizadas em sequência numérica correspondente à ordem de citação no texto e alinhadas a esquerda, seguindo as orientações da biblioteca da Unesp na preparação de trabalhos acadêmicos de acordo com as normas da ABNT quanto às Referências - ABNT 6023/2002.

1 FREIRE, P. *Política e educação: ensaios*. 5. ed. São Paulo: Cortez, 2001. v. 53, 57 p. (Coleção questões de nossa época).

2 BRANDÃO, C. R. *O que é educação*. 34. ed. São Paulo: Brasiliense, 2007. 120 p.

3 GADOTTI, M. *Perspectivas atuais da educação*. Porto Alegre: Artmed, 2000. 294 p.

4 MARTINHO, V. R. C. *Sistema Inteligente para predição do grupo de risco de evasão discente*. 2012. 58 f. Exame de Qualificação (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia, PPGEE, Universidade Estadual Paulista, Ilha Solteira, 2012.

5 ROSS, T.; KENA, G.; RATHBUN, A.; KEWALRAMANI, A.; ZHANG, J.; KRISTAPOVICH, P.; MANNING, E. *Higher education: gaps in access and persistence study*. Washington: Government Printing Office, 2012. 329 p.

6 GIER, N. The crisis in Idaho higher education: a lack of faculty autonomy as well as funding. *Idaho State Journal*, Idaho, 2009. Disponível em: <<http://www.home.roadrunner.com/~nickgier/HighEdCrisis.htm>>. Acesso em: 12 fev. 2014.

7 SILVA FILHO, R. L. L.; LOBO, M. B. C. M. *Como a mudança na metodologia do Inep altera o cálculo da evasão*: Instituto Lobo para o desenvolvimento da educação, da ciência e da tecnologia. São Pulo: Lobo & Associados consultoria e Participação, 2012. 11 p.

8 BRASIL. Ministério da Educação - MEC. *Resumo técnico: censo da educação superior 2010*. Brasília: INEP. 2011. 23 p.

9 ORGANIZAÇÃO DAS NAÇÕES UNIDAS PARA A EDUCAÇÃO- UNESCO. *Higher education in the twenty-first century: vision and action*. In: WORLD CONFERENCE ON HIGHER EDUCATION, 1998, Paris. Paris: UNESCO, 1998. 138 p.

10 BRASIL. Ministério da Educação - MEC. SESu. *Reestruturação e expansão das universidades federais - REUNI*. 2007, Brasília: MEC. Disponível em: <<http://portal.mec.gov.br/sesu/arquivos/pdf/diretrizesreuni.pdf>>. Acesso em: 15 maio 2013.

- 11 BRASIL. Ministério da Educação - MEC. SETEC. *Termo de acordo de metas e compromissos*. 2009, Brasília: MEC. Disponível em: <http://portal.ifrn.edu.br/reitoria/arquivos/ACORDO%20DE%20METAS%20E%20COMPRMISSOS.PDF/at_download/file>. Acesso em: 05 nov. 2011.
- 12 BRASIL. Ministério da Educação - MEC. CNE. CES. *Desenvolvimento, aprimoramento e consolidação de uma educação nacional de qualidade: Relação oferta-demanda de cursos da educação superior*. Relatório técnico. 2013, Brasília: MEC. Disponível em: <http://portal.mec.gov.br/index.php?option=com_content&view=article&id=19042:projeto-cneunesco&catid=323:orgaos-vinculados&Itemid=1228>. Acesso em: 10 nov. 2013.
- 13 LOBO, M. B. D. C. M. Panorama da evasão no ensino superior brasileiro: aspectos gerais das causas e soluções. *Revista da ABMES*, Brasília, v. 1, n. 25, 2012. Disponível em: <http://www.institutolobo.org.br/imagens/pdf/artigos/art_087.pdf>. Acesso em: 12 jan. 2014.
- 14 SILVA FILHO, R. L. L.; MONTEJUNAS, P. R.; HIPÓLITO, O.; LOBO, M. B. C. M. A evasão no ensino superior brasileiro. *Cadernos de Pesquisa*, São Paulo, v. 37, p. 641-659, set-dez 2007.
- 15 BERGER, J. B.; RAMIREZ, G. B.; LYONS S. Past to present: a historical look at retention. In: SEIDMAN, A. (Ed.). *College student retention: formula for student success*. Rowman & Littlefield Publishers Westport, 2012 . p. 1-30.
- 16 PORTELA, S. *Evasão ou retenção?* uma questão crucial à sustentabilidade das instituições de ensino superior. São Paulo: Humus, 2013. 86 p.
- 17 BRASIL. MINISTÉRIO DA EDUCAÇÃO – MEC. SESu, *Comissão especial de estudos sobre a evasão nas universidades públicas brasileiras: diplomação, retenção e evasão nos cursos de graduação em instituições de ensino superior públicas*. 1997, Brasília: MEC. 134 p.
- 18 INSTITUTO NACIONAL DE ESTUDOS E PESQUISAS EDUCACIONAIS ANÍSIO TEIXEIRA – INEP. Disponível em: <<http://www.inep.gov.br/>>. Acesso em: 05 nov. 2011.
- 19 BRASIL. MINISTÉRIO DA EDUCAÇÃO – MEC. Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira - INEP. *Censo da educação superior 2012*. Primeiros resultados. 2013. Brasília, DF: INEP. 114 p. Disponível em: <<http://www.abmes.org.br/abmes/documentos/visualizar/id/273>> Acesso em: 15 nov. 2013.
- 20 ORGANIZAÇÃO DAS NAÇÕES UNIDAS PARA A EDUCAÇÃO, A CIÊNCIA E A CULTURA - UNESCO. *Relatório de monitoramento global de educação para todos: alcançar os marginalizados*. Brasil: UNESCO, 2010. 41 p.
- 21 CAPELATO, R. *O que os números revelam sobre o perfil da evasão no ensino superior brasileiro*. Palestra. Seminário ABMES: Evasão e retenção: problemas e soluções. Brasília: ABMES, 2011.
- 22 BARBOSA, J. O. *Identificação e análise dos fatores determinantes da evasão escolar no CST em automação industrial no IFMT - 2004-2010*. Cuiabá: Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso - IFMT, 2011. 40 p. (Relatório Interno).
- 23 ORGANIZAÇÃO DAS NAÇÕES UNIDAS PARA A EDUCAÇÃO, A CIÊNCIA E A CULTURA- UNESCO. INSTITUTO INTERNACIONAL DE LA UNESCO PARA LA EDUCACIÓN SUPERIOR EN AMÉRICA LATINA Y EL CARIBE – IESALC. *Informe*

sobre la educación superior en América Latina y el Caribe 2000-2005: la metamorfosis de la educación superior. Caracas: Metrópolis, 2006.

24 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 Networks and Learning Systems*, Piscataway, v. 3, n. 5, p. 698-713, 1992.

25 CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. *Fuzzy ART*: Fast stable learning and categorization of analog patterns by an adaptive resonance system. *Neural Network*, Kidlington, v. 6, n. 4, p. 759-771, 1991.

26 CARPENTER, G. A.; GROSSBERG, S. A self-organizing neural network for supervised learning, recognition, and prediction. *Communications Magazine IEEE*, New York, v. 30, n. 9, p. 38-49, 1992.

27 HAYKIN, S. S. *Redes neurais: princípios e prática*. 2. ed. Porto Alegre: Bookman Companhia, 2001. 900 p.

28 NILSSON, N. J. *Artificial intelligence: a new synthesis*. San Francisco: Morgan Kaufman Publ Incorporated, 1998. 513 p.

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

30 BARNETT, J. A. Computational methods for a mathematical theory of evidence, In: YAGER, R. R.; LIU, L. (Ed.). *Studies in fuzziness and soft computing: classic works of the dempster-shafer theory of belief functions*. New York: Springer Science, 2008. p. 197-216.

31 MARCHIORI, S. C. *Desenvolvimnto de sistema para análise da estabilidade transitória de sistemas de energia elétrica via redes neurais*. 2006. 130 f. Tese (Doutorado) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2006.

32 MORENO, A. L. *Análise da estabilidade transitória via rede neural ART-ARTMAP Fuzzy Euclidiana modificada com treinamento continuado*. 2010. 143 f. Tese (Doutorado) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2010.

33 MARCHIORI, S. C.; SILVEIRA, M. C. G.; LOTUFO, A. D. P.; MINUSSI, C. R.; LOPES, M. L. M. Neural network based on adaptive resonance theory with continuous training for multi-configuration transient stability analysis of electric power systems. *Applied Soft Computing*, Amsterdam, v. 11, p. 706-715, 2011.

34 ANDRADE, M. M. *Introdução à metodologia do trabalho científico*. 10. ed. São Paulo: Atlas, 2010. 174 p.

35 BOGDAN, R.; BIKLEN, S. *Investigação qualitativa em educação*. Porto: Porto Editora, 1994. 336 p.

36 CARPENTER, G. A.; GROSSBERG, S. A massively parallel architecture for a self-organizing neural pattern recognition machine. *Computer Vision, Graphics and Image Processing*. New York, v. 37, n. 1, p. 54-115, 1987.

- 37 CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: supervised real-time learning and classification of nonstationary data by a self-organizing neural network. *Neural Networks*, Kidlington, v. 4, n. 5, p. 565-588, 1991.
- 38 CARPENTER, G. A.; GROSSBERG, S.; IIZUKA, K. Comparative performance measures of fuzzy ARTMAP, learned vector quantization, and back propagation for handwritten character recognition in neural networks. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS - IJCNN, 1, 1992, Baltimore. *Proceedings of the IJCNN*. Baltimore: IEEE, 1992. p. 794-799. Disponível em: <
<http://open.bu.edu/xmlui/bitstream/handle/2144/2085/92.005.pdf?sequence=1>>. Acesso em: 12 dez. 2013.
- 39 GROSSBERG, S. Adaptive resonance theory: how a brain learns to consciously attend, learn, and recognize a changing world. *Neural Networks*, Kidlington, v. 37, p. 1-47, 2013.
- 40 LOPES, M. L. M. *Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica*. 2005. 169 f. Tese (Doutorado) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2005.
- 41 LOPES, M. L. M.; MINUSSI, C. R.; LOTUFO, A. D. P. Electric load forecasting using a fuzzy ART&ARTMAP neural network. *Applied Soft Computing*, Amsterdam, v. 5, n. 2, p. 235-244, 2005.
- 42 BAGGI, C. A. S. *Evasão e avaliação institucional: uma discussão bibliográfica*. Pontifícia Universidade Católica de Campinas. 2010. 80 f. Dissertação (Mestrado em Educação) - Centro de Ciências Sociais, Pontifícia Universidade Católica de Campinas, Campinas, 2010.
- 43 SOUZA, C. T.; PETRÓ, C. S.; GESSINGER, R. M. Um estudo sobre evasão no ensino superior do Brasil nos últimos dez anos: as possíveis causas e fatores que influenciam no abandono. Prevendo o risco do abandono. In: CONFERÊNCIA LATINOAMERICANA SOBRE EL ABANDONO EM LA EDUCACION SUPERIOR – CLABES, 2, 2012, Porto Alegre. **Anais CLABES**. Porto Alegre: Pontifícia Universidade Católica do Rio Grande do Sul, 2012.
- 44 GAIOSO, N. P. L. *Evasão discente na educação superior: a perspectiva dos dirigentes e dos alunos*. 2005. 99 f. Dissertação (Mestrado em Educação) - Faculdade de Educação, Universidade Católica de Brasília, Brasília, DF, 2005.
- 45 SEIDMAN, A. *College student retention: formula for student success*. Westport: Praeger, 2005. 364 p. (American Council on Education).
- 46 SPADY, W. G. Dropouts from higher education: an interdisciplinary review and synthesis. *Interchange*, Ontario, v. 1, n. 1, p. 64-85, 1970.
- 47 SPADY, W. G. Dropouts from higher education: toward an empirical model. *Interchange*, Ontario, v. 2, n. 3, p. 38-62, 1971.
- 48 BEAN, J. P. Dropout and turnover: the synthesis and test of a causal model of student attrition. *Research in Higher Education*, New York, v. 12, p. 155-187, 1980.
- 49 BEAN, J. P. Interaction effects based on class level in a exploratory model of college student dropout syndrome. *American Educational Research Journal*, Washington, v. 22, n. 1, p. 35-64, 1985.

50 BEAN, J. P.; Metzner, B. S. A conceptual model of nontraditional undergraduate student attrition. *Review of Educational Research*, Washington, v. 55, p. 485-540, 1985.

51 NORA, A. Determinants of retention among Chicago college students: a structural model. *Research in Higher Education*, New York, v. 26, n. 1, p. 31-59, 1987.

52 NORA, A.; BARLOW, E.; CRISP, G. Student persistence and degree attainment beyond the first year in college. In: SEIDMAN, A. *College student retention - formula for student success*. Westport: Praeger. 2005. 364 p. (American Council on Education)

53 CABRERA, A. F.; NORA, A.; CASTAÑEDA, M. B. The role of finances in the persistence process: a structural model. *Research in Higher Education*, New York, v. 33, n. 5, p. 571-593, 1992.

54 TINTO, V. Dropout from higher education: a theoretical synthesis of recent research. *Review of Educational Research*, Washington, v. 45, n. 1, p. 89-125, 1975.

55 TINTO, V. Limits of theory and practice in student attrition. *The Journal of Higher Education*, Columbus, v. 53, p. 687-700, 1982.

56 TINTO, V. *Leaving College: rethinking the causes and cures of college attrition*. 2. ed. Chicago: University of Chicago Press, 1993.

57 TINTO, V. Classrooms as communities: exploring the educational character of student persistence. *Journal of Higher Education*, Columbus, v. 68, n. 6, p. 599-624, 1997.

58 TINTO, V. *Student success and the construction of inclusive educational communities*. [S.l.]: American Association of State Colleges and Universities - AASCU, 2005. Disponível em: < <http://survey.csuprojects.org/uploads/HO/RQ/HORQxb19ritxiGXPo8yi7g/Tinto-re-Inclusive-Educational-Communities.pdf>>. Acesso em: 12 jan. 2014.

59 TINTO, V. Research and practice of student retention: what next? *Journal of College Student Retention: Research, Theory and Practice*, Amityville, v. 8, n. 1, p. 1-19, 2006.

60 LYKOURANTZOU, I.; GIANNOUKOS, I.; NIKOLOPOULOS, V.; MPARDIS, G.; LOUMOS, V. Dropout prediction in e-learning courses through the combination of machine learning techniques. *Journal Computers & Education*, New York, v. 53, n. 3, p. 950-965, 2009.

61 MUSTAFA, M. N.; CHOWDHURY, L.; KAMAL, S. Students dropout prediction for intelligent system from tertiary level in developing country. In: INTERNATIONAL CONFERENCE ON INFORMATICS, ELECTRONICS & VISION- ICIEV, 12, 2012, Dhaka. Dhaka: IEEE, 2012. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6317441>>. Acesso em: 14 jan. 2014.

62 KARAMOUZIS, S. T.; VRETTOS, A. An artificial neural network for predicting student graduation outcomes. In: WORLD CONGRESS ON ENGINEERING AND COMPUTER SCIENCE – WCECS, 2008, San Francisco. *Proceedings of the WCECS*. San Francisco: Newswood Limited, 2008. p. 991-994. Disponível em: < http://www.iaeng.org/publication/WCECS2008/WCECS2008_pp991-994.pdf>. Acesso em: 15 jan. 2014.

- 63 JADRIĆ, M.; GARAČA, Ž.; ĆUKUŠIĆ, M. Student dropout analysis with application of data mining methods. *Journal of Contemporary Management*, Cresta, v. 15, n. 1, p. 31-46, 2010.
- 64 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*, Town, v. 9, n. 1, p. 72-79, 2008.
- 65 DEKKER, G. W.; PECHENIZKIY, M.; VLEESHOUWERS, J. M. *Predicting students drop out: a case study*. Educational Data Mining. 2009. p. 41-50. Disponível em: <http://www.win.tue.nl/~mpechen/projects/edm/internshipreport_090409.pdf>. Acesso em: 12 fev. 2014.
- 66 HANEWICZ, C. *Identifying student retention patterns using GIS technology*. In: PORTLAND INTERNATIONAL CONFERENCE ON MANAGEMENT OF ENGINEERING & TECHNOLOGY, PICMET, Portland. *Proceedings of the...* Portland: IEEE, 2009. p. 2231-2239.
- 67 FU, J. H.; CHANG, J. H.; HUANG, Y. M.; CHAO, H. C. *A support vector regression-based prediction of students' school performance*. In: INTERNATIONAL SYMPOSIUM ON COMPUTER, CONSUMER AND CONTROL, IS3C, 2012, Taichung. *Proceedings of the...* Taichung : IEEE, 2012. p. 84-87.
- 68 BENDER, E. A. *Mathematical methods in artificial intelligence*. Califórnia: IEEE Computer Society, 1996. 636 p.
- 69 SIMPSON, P. K. *Artificial neural systems: foundations, paradigms, applications, and implementations*. New York: Pergamon Press, 1989.
- 70 WASSERMAN, P. D. *Neural computing: theory and practice*. New York: Van Nostrand Reinhold, 1989.
- 71 WIDROW, B.; LEHR, M. A. 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. *Proceedings of the IEEE*, New York, v. 78, n. 9, p. 1415-1442, 1990.
- 72 KUNG, S. Y. *Digital neural networks*. Englewood Cliffs: PTR Prentice-Hall, 1993. 444 p.
- 73 JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. Artificial neural networks: a tutorial. *IEEE Computer*, New York, v. 29, n. 3, p. 31-44, 1996.
- 74 KARTALOPOULOS, S. V. *Understanding neural networks and fuzzy logic*. New York: IEEE Press, 1996. 232 p.
- 75 KING, R. L. Artificial neural networks and computational intelligence. *IEEE Computer Application in Power*, New York, p. 14-29, 1998.
- 76 GROSSBERG, S. Adaptive pattern classification and universal recoding,I: Parallel development and coding of neural feature detectors. *Biological Cybernetics*, Heildelberg, v. 23, p. 121-134, 1976.
- 77 GROSSBERG, S. Adaptive pattern recognition and universal recoding,II: Feedback, expectation, olfaction, and illusions. *Biological Cybernetics*, Heildelberg, v. 23, p. 187-202, 1976.

- 78 GROSSBERG, S. Behavioral contrast in short-term memory: serial binary memory models or parallel continuous memory models. *Journal of Mathematical Psychology*, Maryland Heights, v. 17, n. 3, p. 199-219, 1978.
- 79 GROSSBERG, S. A theory of human memory: In: _____. *Self-organization and performance of sensor-motor codes, maps, and plans*. Boston: Reidel, 1982, p. 498–639. (Studies of mind and brain.).
- 80 GROSSBERG, S. Nonlinear neural networks: Principles, mechanisms, and architectures. *Neural Networks*, Oxford, v. 1, p. 17–61, 1988.
- 81 CARPENTER, G. A.; GROSSBERG, S. The ART of adaptive pattern recognition by a self-organizing neural network. *IEEE Computer*, New York, v. 21, n. 3, p. 77-88, 1988.
- 82 CARPENTER, G. A.; GROSSBERG, S. ART 2: stable self-organization of pattern recognition codes for analog input patterns. *Applied Optics*, Washington, v. 26, n. 23, p. 4919-4930, 1987, 1987. Disponível em: <<http://www.opticsinfobase.org/abstract.cfm?URI=ao-26-23-4919>>. Acesso em: 05 nov. 2011.
- 83 CARPENTER, G. A.; GROSSBERG, S. ART 2-A: an adaptive resonance algorithm for rapid category learning and recognition. *Neural Networks*, Washington, v. 4, n. 4, p. 493-504, 1991. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0893608091900457>>. Acesso em: 05 nov. 2011.
- 84 CARPENTER, G. A.; GROSSBERG, S. ART 3: hierarchical search using chemical transmitters in self-organizing pattern recognition architectures. *Neural Networks*, Washington, v. 3, n. 2, p. 129-152, 1990. Disponível em: <<http://www.sciencedirect.com/science/article/pii/089360809090085Y>>. Acesso em: 05 nov. 2011.
- 85 CARPENTER, G. A.; GROSSBERG, S. e ROSEN, D. B. Fuzzy ART: an adaptive resonance algorithm for rapid, stable classification of analog patterns. In: CONFERENCE ON NEURAL NETWORKS, SEATTLE INTERNATIONAL JOINT conference, 1991, Seattle. *Proceedings of the...* Seattle: IEEE, 1991. p. 411-416.
- 86 CARPENTER, G. A.; GROSSBERG, S. *Pattern recognition by self-organizing neural networks*. Cambridge: The MIT Press, 1991. 691 p.
- 87 MARTINHO, V. R.; NUNES, C.; MINUSSI, C. R. Predição do grupo de risco de evasão discente em cursos superiores presenciais utilizando uma rede neural ARTMAP-Fuzzy. In: CONGRESSO BRASILEIRO DE EDUCAÇÃO EM ENGENHARIA - COBENGE'2013, 41, 2013, Gramado. *Anais COBENGE*. Gramado: FEDEP, 2013. 12 P. Disponível em: <http://www.fadep.br/engenharia-eletrica/congresso/pdf/118051_1.pdf>. Acesso em: 12 fev. 2014.
- 88 DECANINI, J. G. M. S. *Deteção, classificação e localização de faltas de curto circuito em sistemas de distribuição de energia elétrica usando sistemas inteligentes*. 2012. 124 f. Tese (Doutorado) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2012.
- 89 IODETA, I. V.; CAPUANO, F. G. *Elementos de eletrônica digital*. 34. ed. São Paulo: Érica, 2001. 524 p.

APÊNDICE A

**CODIFICAÇÃO DECIMAL-BINÁRIA DOS ATRIBUTOS UTILIZADOS NOS
PADRÕES DE ENTRADA DA REDE NEURAL ARTMAP-*FUZZY***

Apêndice A - Codificação decimal para padrão binário dos atributos do vetor de entrada da rede neural.

Posição no vetor de entrada da rede (a)	Atributo dos subvetores de entrada da rede	Possibilidades de resposta	Categorias com números decimais	Padrão do código binário - até 3 bits			
				2^2	2^1	2^0	
Subvetores do vetor de entrada da rede (a)	a_1	Sexo (Sx - 1 bit)	Feminino	1	1		
			Masculino	0	0		
	a_2	Faixa Etária (FxEt - 3 bits)	13 a 15 Anos	1	001		
			16 a 18 Anos	2	010		
			19 a 21 Anos	3	011		
			22 a 25 Anos	4	100		
			26 a 30 Anos	5	101		
			31 a 40 Anos	6	110		
			> 40 Anos	7	111		
	a_3	Etnia (Etn - 3 bits)	Branca	1	001		
			Negra	2	010		
			Indígena	3	011		
			Mestiça	4	100		
			Oriental	5	101		
			Outras	6	110		
	a_4	Estado Civil (EstCiv - 3 bits)	Solteiro (a)	1	001		
			Casado (a)	2	010		
			Amasiado (a)	3	011		
			Separado (a)	4	100		
			Viúvo (a)	5	101		
	a_5	Número de Pessoas na Residência (PesCs - 3 bits)	Até 2	1	001		
			3 a 4	2	010		
			5 a 7	3	011		
> 7			4	100			

Subvetores do vetor de entrada da rede (\mathbf{a})	a_6	Renda Familiar (Rfam - 3 bits)	Rf \leq 1,5 s.m.	1	001
			1,5 s.m. < Rf \leq 3 s.m.	2	010
			3 s.m. < Rf \leq 5 s.m.	3	011
			5 s.m. < Rf \leq 7 s.m.	4	100
			7 s.m. < Rf \leq 10 s.m.	5	101
			Rf > 10 s.m.	6	110
	a_7	Possui Computador (Comp - 1 bit)	Sim	1	1
			Não	0	0
	a_8	Escolaridade dos Pais (EscPais - 3 bits)	Não Informado	0	000
			Não Estudou	1	001
			Até 4ª série	2	010
			Entre 5ª e 8ª série	3	011
			Nível Médio	4	100
			Nível Superior	5	101
	a_9	Escola de Origem (EscOrig - 3 bits)	Não informado	0	000
			Pública - Regular	1	001
			Particular - Regular	2	010
			Pública - Supletivo	3	011
			Particular - Supletivo	4	100
	a_{10}	AutoAvaliação (AAval - 3 bits)	Não Informado	0	000
			Ótimo	1	001
			Bom	2	010
			Regular	3	011
			Ruim	4	100
Péssimo			5	101	
a_{11}	Procedência (Procd - 1 bit)	Urbana	1	1	
		Rural	0	0	

Subvetores do vetor de entrada da rede (\mathbf{a})	\mathbf{a}_{12}	Distância Escola - Residência (DistER - 3 bits)	DistER \leq 5 km	1	001
			5 < DistER \leq 10 km	2	010
			10 < DistER \leq 20 km	3	011
			20 < DistER \leq 30 km	4	100
			30 < DistER \leq 40 km	5	101
			DistER > 50 km	6	110
	\mathbf{a}_{13}	Meio de Transporte (Transp - 3 bits)	Não Informado	0	000
			Ônibus	1	001
			Motocicleta	2	010
			Carro Próprio	3	011
			Bicicleta	4	100
			À pé	5	101
			Carona	6	110
			Transporte Escolar	7	111
	\mathbf{a}_{14}	Situação de Trabalho (Trab - 3 bits)	Não Informado	0	000
			Não Trabalha	1	001
			Integral	2	010
			Parcial	3	011
			Eventual	4	100
			Voluntário	5	101
			Desempregado	6	110
	\mathbf{a}_{15}	Turno de estudo (Turno - 2 bits)	Matutino	1	01
			Vespertino	2	10
			Noturno	3	11
\mathbf{a}_{16}	Alunos por Sala (Al/SI - 3 bits)	Al/SI \leq 25	1	001	
		25 < Al/SI \leq 50	2	010	
		50 < Al/SI \leq 75	3	011	
		Al/SI > 75	4	100	
Saída (\mathbf{y})	\mathbf{y}	1 bit	Não-Evasão (NEv)	0	0
			Evasão (Ev)	1	1

Fonte: da própria autora.

APÊNDICE B

ARTIGOS PUBLICADOS DURANTE O DESENVOLVIMENTO DA PESQUISA

Apêndice B - Relação das publicações durante o desenvolvimento da pesquisa do doutorado.

- **Publicações Relacionadas com a Tese**

- (1) **MARTINHO, V. R. C.**; NUNES, C.; MINUSSI, C. R. Prediction of school dropout risk group using Neural Network. In: INTERNATIONAL SYMPOSIUM ADVANCES IN ARTIFICIAL INTELLIGENCE AND APPLICATIONS - AAIA, 8th, 2013, Kraków. *Proceedings of the 2013 Federated Conference on Computer Science and Information Systems - FedCSIS*. Kraków: IEEE, 2013, v. 1, p. 111-114.
- (2) **MARTINHO, V. R. C.**; NUNES, C.; MINUSSI, C. R. An Intelligent System for Prediction of School Dropout Risk Group in Higher Education Classroom Based on Artificial Neural Networks. In: INTERNATIONAL CONFERENCE ON TOOLS WITH ARTIFICIAL INTELLIGENCE - ICTAI, 25th, 2013, Washington. IEEE Computer Society, 2013, v. 1, p. 159-166.
- (3) **MARTINHO, V. R. C.**; NUNES, C.; MINUSSI, C. R. A new method for prediction of school dropout risk group using neural network Fuzzy. In: INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE - ICAI, 15th, 2013, Las Vegas. *Proceedings of the 2013 International Conference On Artificial Intelligence - ICAI*. Las Vegas: CSREA Press, 2013, v. 1, p. 359-365.
- (4) **MARTINHO, V. R. C.**; NUNES, C.; MINUSSI, C. R. Um sistema inteligente usando redes neurais ARTMAP-Fuzzy para predição do grupo de risco de evasão discente em cursos superiores presenciais. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE - SBAI, XI, 2013, Fortaleza. *Anais do Congresso*. Fortaleza: 2013, v.1, p. 1-6.
- (5) **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: CONGRESSO BRASILEIRO DE EDUCAÇÃO EM ENGENHARIA - COBENGE, XLI, 2013, Gramado. *Anais: Educação em Engenharia na Era do Conhecimento*. Gramado: 2013, v. 1, p. 1-6.
- (6) **MARTINHO, V. R. C.**; NUNES, C.; MINUSSI, C. R. Um novo método para predição da evasão escolar usando redes neurais. In: CONGRESSO BRASILEIRO EM INTELIGÊNCIA COMPUTACIONAL - CBIC, XI, 2013, Porto de Galinhas. *Anais do Congresso*. Porto de Galinhas: 2013, v.1, p. 1-6.

- **Publicações em área de afinidade com a pesquisa - Redes Neurais Artificiais**

- (7) NUNES, C.; **MARTINHO, V. R. C.**; MINUSSI, C. R. A new method for the prediction of carbon sequestration in reforested areas using a Fuzzy-ART-BP neural network. In: INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE - ICAI, 15th, 2013, Las Vegas. *Proceedings of the 2013 International Conference On Artificial Intelligence - ICAI*. Las Vegas: CSREA Press, 2013, v. 1, p. 825-831.
- (8) NUNES, C.; **MARTINHO, V. R. C.**; MINUSSI, C. R. Predição do sequestro de carbono com espécies arbóreas nativas da Amazônia por redes neurais artificiais. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE - SBAI, XI, 2013, Fortaleza. *Anais do Congresso*. Fortaleza: 2013, v.1, p. 1-6.
- (9) NUNES, C.; **MARTINHO, V. R. C.**; MINUSSI, C. R. Um Novo Método para a Predição do Sequestro de Carbono em áreas Reflorestadas usando uma Rede Neural ART-Fuzzy-BP. In: CONGRESSO BRASILEIRO EM INTELIGÊNCIA COMPUTACIONAL - CBIC, XI, 2013, Porto de Galinhas. *Anais do Congresso*. Porto de Galinhas: 2013, v.1, p. 1-6.

- **Publicações no âmbito da Educação**

- (10) MONTANUCCI, R.; STERING, S. M. S.; SILVA, S. A.; **MARTINHO, V. R. C.** A oferta da EaD no Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso: um olhar pedagógico sobre a prática docente. In: COLÓQUIO INTERNACIONAL SOBRE GESTÃO UNIVERSITÁRIA NAS AMÉRICAS, XIII, 2013, Buenos Aires. *Anais do Congresso: Rendimientos Académicos y Eficacia Social de la Universidad*. Buenos Aires: 2013, v.1, p. 1-22.

ANEXO A

**AUTORIZAÇÃO DO IFMT PARA UTILIZAÇÃO DOS BANCOS DE DADOS
Q-ACADÊMICO E Q-SELEÇÃO**



SERVIÇO PÚBLICO FEDERAL
MEC – SETEC
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE MATO GROSSO
CAMPUS CUIABÁ – Cel. OCTAYDE JORGE DA SILVA
GABINETE DO DIRETOR

Tendo em vista a realização do Doutorado Interinstitucional por Valquíria Ribeiro de Carvalho Martinho na perspectiva da parceria entre o IFMT - Instituto Federal de Mato Grosso e UNESP – Universidade Júlio de Mesquita Filho, Campus Ilha Solteira -SP, no Departamento de Engenharia Elétrica sob a orientação do Professor Doutor Carlos Roberto Minussi, em que a mesma desenvolve a tese intitulada "Sistema inteligente para a predição de grupo de risco de evasão discente" autorizo a docente a utilizar os dados do Sistema de Informação, gestão e controle integrado do IFMT, onde se concentra toda história acadêmica dos estudantes do IFMT e o Q-Seleção - Sistema gerenciador de banco de dados que controla os processos seletivos do IFMT, a fim de obter os dados necessários para compor a pesquisa para o desenvolvimento do produto proposto na tese em desenvolvimento.

Cuiabá, 01 de Fevereiro de 2011.

A handwritten signature in blue ink, appearing to read 'Nelson Yoshio Ito Suzuki', written over a horizontal line.

Nelson Yoshio Ito Suzuki

Diretor Substituto do Campus Cuiabá