

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA
CAMPUS DE ILHA SOLTEIRA**

CARLOS ROBERTO DOS SANTOS JÚNIOR

**UMA NOVA ABORDAGEM DE TREINAMENTO ON-LINE PARA REDE NEURAL
ARTIFICIAL ARTMAP FUZZY**

Ilha Solteira
2017

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

CARLOS ROBERTO DOS SANTOS JÚNIOR

**UMA NOVA ABORDAGEM DE TREINAMENTO ONLINE PARA REDE NEURAL
ARTIFICIAL ARTMAP FUZZY**

Tese apresentada à Faculdade de Engenharia de
Ilha Solteira – UNESP como parte dos requisitos
para obtenção do título de Doutor em Engenharia
Elétrica.

Área de Conhecimento: Automação

Anna Diva Plasencia Lotufo

Orientador

Ilha Solteira
2017

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

- S237n Santos Júnior, Carlos Roberto dos.
Uma nova abordagem de treinamento online para rede neural artificial ARTMAP Fuzzy / Carlos Roberto dos Santos Júnior. -- Ilha Solteira: [s.n.], 2017 57 f. : il.
- Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2017
- Orientador: Anna Diva Plasencia Lotufo
Inclui bibliografia
1. Redes neurais artificiais. 2. ARTMAP Fuzzy. 3. Aprendizagem on-line. 4. Treinamento continuado.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Uma Nova Abordagem de Treinamento Online para Rede Neural Artificial
ARTMAP Fuzzy

AUTOR: CARLOS ROBERTO DOS SANTOS JÚNIOR


ORIENTADORA: ANNA DIVA PLASENCIA LOTUFO

Aprovado como parte das exigências para obtenção do Título de Doutor em ENGENHARIA
ELÉTRICA, área: AUTOMAÇÃO pela Comissão Examinadora:


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


Prof. Dr. FABIO ROBERTO CHAVARETTE
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. MARA LUCIA MARTINS LOPES
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. BENEDITO ISAIAS DE LIMA LOPES
Instituto de Engenharia de Sistemas e Tecnologias da Informação / Universidade Federal de Itajubá


Prof. Dr. GELSON DA CRUZ JUNIOR
Escola de Engenharia Elétrica e de Computação / Universidade Federal de Goiás

Ilha Solteira, 04 de setembro de 2017

DEDICATÓRIA

A Deus

A minha esposa Thays

AGRADECIMENTOS

Primeiramente agradeço a Deus por me fortalecer nos momentos de dificuldade, estar sempre ao meu lado guiando meus passos, e me presentear com pessoas tão especiais que me ensinam a cada dia a me tornar uma pessoa melhor.

Ao meu pai por me mostrar os reais valores de um homem, não apenas com palavras, mas principalmente com atitudes, minha mãe por exercer seu papel de mãe de maneira impecável me incentivando e cobrando nas horas certas; minha irmã, que tenho tanto orgulho e carinho, por ser minha companheira de todas as horas, com quem posso sempre contar. Sem vocês nada disso seria possível.

A minha esposa Thays, que sem dúvida foi uma das pessoas responsáveis pela realização deste sonho, que nunca hesitou em me ajudar, agradeço pelo amor, respeito e carinho.

Aos meus colegas de laboratório, pelos conselhos, companheirismo e cafezinhos.

Em especial agradeço a minha orientadora Anna Diva, pelo companheirismo e confiança depositada em mim ao longo desses anos. A professora Mara e ao professor Minussi pelas dicas e incentivo, e a FEIS por proporcionar toda estrutura para a concretização deste projeto.

“O que sabemos é uma gota; o que ignoramos é um oceano. Mas o que seria o oceano se não infinitas gotas?”

Isaac Newton.

RESUMO

A evolução dos recursos de internet levou ao crescente aumento do fluxo de dados, e por consequência, a necessidade de modelos de classificação ou previsão que suportem uma aprendizagem online. A Rede Neural ARTMAP Fuzzy tem sido utilizada nas mais diversas áreas do conhecimento, no entanto, ainda é pouco explorada em aplicações de tempo real que exigem uma aprendizagem contínua. Neste trabalho, é proposto uma Rede Neural ARTMAP Fuzzy com treinamento continuado, capaz de adquirir conhecimento ao longo da classificação ou previsão. Modificações na arquitetura e no algoritmo de aprendizagem possibilitam à rede neural ativar o treinamento sempre que necessário. Para validar o modelo proposto foram realizadas duas aplicações, uma para previsão e outra para classificação, utilizando bases de dados benchmarks e comparado com a ARTMAP Fuzzy original. Os resultados mostraram a capacidade do modelo proposto em adquirir conhecimento ao longo das amostras apresentadas de forma estável e eficiente. Assim, este estudo contribui para a evolução da rede neural ARTMAP Fuzzy e apresenta o treinamento continuado como uma alternativa eficaz para aplicações de tempo real.

Palavras-chave: Redes neurais artificiais. ARTMAP Fuzzy. Aprendizagem on-line. Treinamento continuado.

ABSTRACT

The evolution of internet resources has led to an increase in the flow of data, and consequently, the need for classification or forecasting models that support an online learning. The ARTMAP Fuzzy Neural Network has been used in several areas of knowledge, however, it is still little explored in real-time applications that require continuous learning. In this work, an ARTMAP Fuzzy Neural Network with continuous training is proposed, able to acquire knowledge along the classification or prediction. Modifications in the architecture and learning algorithm enable the neural network to activate training whenever necessary. To validate the proposed model two experiments were performed, one for forecasting and another for classification, using benchmark databases and compared with the original ARTMAP Fuzzy Neural Network. The results showed the ability of the proposed model to acquire knowledge along the presented samples in a stable and efficient way. Thus, this study contributes to the evolution of the ARTMAP Fuzzy neural network and presents the continuous training as an effective alternative to real-time applications.

Keywords: Artificial neural networks. Fuzzy ARTMAP. Online learning. Continuous training.

LISTA DE FIGURAS

Figura 1	- Família ART.....	22
Figura 2	- RNA ART Fuzzy.....	23
Figura 3	- Camada F_0	25
Figura 4	- Camada F_1	26
Figura 5	- Camada F_2	27
Figura 6	- Fluxograma da RNA ART Fuzzy.....	29
Figura 7	- Arquitetura ARTMAP Fuzzy.....	30
Figura 8	- Módulo Inter-ART.....	31
Figura 9	- Fluxograma da rede ARTMAP Fuzzy.....	33
Figura 10	- Arquitetura da RNA FAM TC.....	35
Figura 11	- Fluxograma do Treinamento Continuado.....	39
Figura 12	- Porcentagem de spams no tráfego global de e-mail no 4º trimestre de 2016 e 1º trimestre de 2017.....	40
Figura 13	- Evolução da acurácia para cada amostra das RNAs FAM TC (azul) e FAM (vermelho).....	45
Figura 14	- Números de neurônios criados no módulo ART_a das RNAs FAM TC e (azul) e FAM (vermelho).....	46
Figura 15	- (a) Previsão da série temporal Mackey Glass através das RNA FAM TC. (b) Previsão da série temporal Mackey Glass através da RNA FAM. O gráfico compara a saída real do conjunto de dados (azul) com a saída prevista.....	49
Figura 16	- Erro na previsão da série temporal Mackey Glass. (a) RNA FAM TC e (b) RNA FAM.....	50
Figura 17	- Números de neurônios criados no módulo ART_b das RNAs FAM TC (azul) e FAM (vermelho).....	50
Figura 18	- Números de neurônios criados no módulo ART_a das RNAs FAM TC e (azul) e FAM (vermelho).....	51

LISTA DE TABELAS

Tabela 1	- Conjunto de dados para treinamento.....	43
Tabela 2	- Parâmetros RNAs FAM TC e FAM.....	43
Tabela 3	- Classificação de Spams.....	47
Tabela 4	- Previsão da série temporal Mackey-Glass.....	51

LISTA DE SIGLAS E ABREVIATURAS

RNA	Rede Neural Artificial
FAM	Fuzzy ARTMAP
RNAs	Redes Neurais Artificiais
ART	Adaptive Resonance Theory
PFAM	Probabilistic Fuzzy ARTMAP
PNN	Probabilistic Neural Network
NPFAM	Non-Proliferation Fuzzy ARTMAP
OELM	Online Extreme Learning Machine
QFAM	Fuzzy ARTMAP Q-Learning
QFAM-GA	Fuzzy ARTMAP Q-Learning e Algoritmo Genético
MAS	Sistema Multiagente
TNC	Trust-Negotiation-Communication
TC	Treinamento Continuado
RMSE	Root Mean Square Error

LISTA DE SÍMBOLOS

F_0	Camada de entrada
F_1	Camada de comparação
F_2	Camada de reconhecimento
a	Vetor de entrada
I	Vetor de atividade da camada F_0
x	Vetor de atividade da camada F_1
y	Vetor de atividade da camada F_2
ρ	Parâmetro de vigilância
β	Taxa de treinamento
α	Parâmetro de escolha
M	Número de neurônios da camada F_0
N	Número de neurônios da camada F_2
T_j	Função de escolha
J	Categoria ativa da camada F_2
w_{ij}	Matriz de pesos
F_0^a	Camada de entrada do módulo ART_a
F_1^a	Camada de comparação do módulo ART_a
F_2^a	Camada de reconhecimento do módulo ART_a
F_0^b	Camada de entrada do módulo ART_b
F_1^b	Camada de comparação do módulo ART_b
F_2^b	Camada de reconhecimento do módulo ART_b
F^{ab}	Camada Inter-ART
b	Vetor de entrada do módulo ART_b
I^a	Vetor de atividade da camada F_0 do módulo ART_a
I^b	Vetor de atividade da camada F_0 do módulo ART_b
x^a	Vetor de atividade da camada F_1 do módulo ART_a
x^b	Vetor de atividade da camada F_1 do módulo ART_b
x^{ab}	Vetor de atividade do módulo Inter-ART
y^b	Vetor de atividade da camada F_2 do módulo ART_b
ρ_a	Parâmetro de vigilância do módulo ART_a

$\bar{\rho}_a$	Parâmetro de vigilância base do módulo ART _a
ε	Valor de incremento e decremento do parâmetro ρ_a
M^a	Número de neurônios da camada F ₀ do módulo ART _a
N^a	Número de neurônios da camada F ₂ do módulo ART _a
M^b	Número de neurônios da camada F ₀ do módulo ART _b
N^b	Número de neurônios da camada F ₂ do módulo ART _b
K	Categoria ativa da camada F ₂ do módulo ART _b
w_j^a	Vetor de pesos do módulo ART _a
w_k^b	Vetor de pesos do módulo ART _b
w_{jk}^{ab}	Matriz de pesos do modulo Inter-ART
N_{min}	Número mínimo de ativações para um neurônio temporário se tornar definitivo
N_{max}	Número máximo de entradas sem ativações de um dado neurônio temporário

SUMÁRIO

1	INTRODUÇÃO.....	14
1.1	OBJETIVOS E CONTRIBUIÇÕES.....	15
1.2	ESTRUTURA DO TEXTO.....	16
2	REVISÃO BIBLIOGRÁFICA.....	17
3	REDES NEURAIS ARTIFICIAIS ART.....	20
3.1	INTRODUÇÃO.....	20
3.2	DILEMA ESTABILIDADE/PLASTICIDADE.....	20
3.3	TEORIA DA RESSONÂNCIA ADAPTATIVA.....	21
3.4	REDE NEURAL ARTIFICIAL ART FUZZY.....	23
3.4.1	Camada de entrada F_0	24
3.4.2	Camada de comparação F_1	25
3.4.3	Camada de reconhecimento F_2	26
3.4.4	Ressonância.....	27
3.4.5	Aprendizagem.....	28
3.5	REDE NEURAL ARTIFICIAL ARTMAP FUZZY.....	30
3.5.1	Módulo Inter-ART.....	30
3.5.1.1	<i>Match Tacking</i>	31
4	TREINAMENTO CONTINUADO.....	34
4.1	ARQUITETURA DA REDE NEURAL ARTIFICIAL ARTMAP FUZZY COM TREINAMENTO CONTINUADO: CAMADA F_2 TEMPORÁRIA.....	34
4.2	MONITORAMENTO DE DADOS ATRAVÉS DO MÓDULO INTER-ART	36
4.3	ALGORITMO DE APRENDIZAGEM E DIAGNÓSTICO DO TREINAMENTO CONTINUADO.....	37
5	RESULTADOS COMPUTACIONAIS.....	40
5.1	CLASSIFICAÇÃO DE SPAMS.....	40
5.2	PREVISÃO DA SÉRIE TEMPORAL MACKEY-GLASS.....	47
6	CONCLUSÕES.....	52
6.1	TRABALHOS FUTUROS.....	53
	REFERÊNCIAS.....	54

1 INTRODUÇÃO

A rede neural artificial (RNA) ARTMAP Fuzzy (FAM) tem sido utilizada com frequência em problemas das mais diversas áreas desde sua primeira versão proposta em CARPENTER et al. (1992). Isso se deve a vantagens importantes em relação a outros modelos de RNAs como, por exemplo, aprendizagem rápida, facilidade de parametrização, depuração e implementação (CARPENTER et al., 1992; BENITES; SAPOZHNIKOVA, 2017). Tais capacidades são decorrentes da Teoria da Ressonância Adaptativa, a qual se baseiam as RNAs da família ART (Adaptive Resonance Theory), e que lhe permitem aprender de forma incremental e estável (CARPENTER; GROSSBERG; ROSEN, 1991). A RNA FAM possui uma estrutura dinâmica, desenvolvida para superar o dilema da estabilidade-plasticidade, ou seja, a medida que a RNA aprende a partir de novas amostras apresentadas, preserva o conhecimento adquirido com dados anteriores (CARPENTER; GROSSBERG; ROSEN, 1991).

Desta forma, a RNA FAM foi utilizada em diversas aplicações distintas, como: monitoramento de danos estruturais (OLIVEIRA; INMAN, 2017), diagnóstico de falhas de rolamentos (XU et al., 2016; JIN et al., 2014), previsão de cargas elétricas (LOPES; MINUSSI; LOTUFO, 2005), reconhecimento de manuscrito (KEF; CHERGUI; CHIKHI, 2016), classificação de movimentos das mãos (FARIMAN et al., 2016), caracterização de regime de onda (SANTOS et al., 2016), classificação de imagens (ANITHA; CHILAMBUCHELVAN, 2015) e reconhecimento de emoções audiovisuais (GHARAVIAN; BEJANI; SHEIKHAN, 2015).

Em alguns dos trabalhos citados acima, modificações e/ou adições de outros métodos, como por exemplo, metodologia híbrida, foram utilizados a fim de aumentar a eficiência do modelo. Em outros, modificações mais profundas foram realizadas com o objetivo de tratar possíveis situações de deficiência da RNA FAM como a proliferação de categorias, sensibilidade a dados ruidosos e aprendizagem dependente da ordem de apresentação das amostras.

Além disto, com o crescente aumento dos dados industriais e científicos, problemas em que há necessidade de trabalhar com grandes volumes de dados e, muitas vezes, em tempo real, aumentam exponencialmente. Por consequência, novas versões da RNA FAM foram propostas a fim de lidar não só com estes novos desafios, mas também com outros até então não explorados com a RNA, contribuindo assim com sua evolução da área a qual foi utilizada.

As modificações propostas mais recentes para a RNA FAM, frequentemente tratam esses novos desafios através de metodologias focadas no problema de proliferação de categorias, aprendizagem dependente da ordem de apresentação dos dados e redução do tempo de aprendizagem e classificação (BENITES; SAPOZHNIKOVA, 2017; POURPANAH; LIM; SALEH, 2016; ANITHA; CHILAMBUCHELVAN, 2015; ZHANG; JI; ZHANG, 2014; JIN et al., 2013; MOKHTAR; HOWE, 2013; VIGDOR; LERNER, 2006; PARRADO-HERNÁNDEZ; GÓMEZ-SÁNCHEZ; DIMITRIADIS, 2003; GÓMEZ-SÁNCHEZ et al., 2002; DAGHER et al., 1999). Todavia, propostas com o objetivo de contribuir com a evolução da aprendizagem online para problemas de tempo real são pouco abordados na literatura (WONG et al., 2015; WANG; GUO; QIAN, 2014; LIM; HARRISON, 2003).

A necessidade de modelos que suportem uma aprendizagem online torna-se cada vez mais essencial nos dias de hoje. O avanço da tecnologia na aquisição e transmissão de dados favorecem o aumento de dispositivos conectados gerando e recebendo informações com as mais diversas finalidades, contribuindo para o aumento do fluxo de informações nas várias áreas do conhecimento. Desse modo, tem impulsionado a pesquisa em sistemas capazes de aprender e ajustar sua estrutura em tempo real. Neste sentido, a proposta de um algoritmo de aprendizagem online aplicado a arquitetura da RNA FAM é de fato importante para seu aperfeiçoamento, buscando melhor desempenho nos novos desafios de problemas em tempo real.

Desta forma, este trabalho tem o objetivo de apresentar uma nova metodologia de aprendizagem online para a RNA FAM e validar sua eficiência com dois problemas benchmarks, a classificação do dataset Spambase do repositório UCI Machine Learning (LICHMAN, 2013) e a previsão da série temporal de MACKEY e GLASS (2011).

1.1 OBJETIVOS E CONTRIBUIÇÕES

Esta tese de doutorado tem por objetivo e contribuições:

- Apresentar uma nova arquitetura da rede neural artificial FAM;
- Apresentar um novo algoritmo de aprendizagem online para uma arquitetura modificada da RNA FAM;
- Apresentar resultados da detecção de spams, de modo a validar a eficiência e precisão do algoritmo;

- Apresentar resultados da previsão da série temporal Mackey-Glass, de modo a analisar a eficiência e robustez do algoritmo;
- Contribuir com a linha de pesquisa em sistemas inteligentes, apresentando uma nova abordagem da rede neural artificial FAM para sistemas online.

1.2 ESTRUTURA DO TEXTO

Esta tese de doutorado é composta por seis capítulos da seguinte maneira descrito a seguir:

Capítulo 2: Revisão bibliográfica

Neste capítulo, apresenta-se uma revisão bibliográfica abordando os principais artigos relevantes que utilizaram em sua metodologia a RNA ARTMAP Fuzzy.

Capítulo 3: Redes neurais artificiais ART

Este capítulo tem por objetivo apresentar a arquitetura e algoritmo de aprendizagem das redes neurais artificiais pertencentes à família ART, concentrando-se nas redes ART Fuzzy e ARTMAP Fuzzy.

Capítulo 4: Treinamento continuado

No capítulo 4, encontra-se uma descrição detalhada da abordagem de aprendizagem online proposta neste trabalho.

Capítulo 5: Resultados computacionais

As aplicações realizadas a fim de avaliar o desempenho da metodologia são apresentados neste capítulo.

Capítulo 6: Conclusões

Finalmente, no capítulo 6, encontram-se as conclusões desta pesquisa e sugestões para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo, apresenta-se, em ordem cronológica, uma revisão bibliográfica com os principais trabalhos publicados na literatura que propuseram modificações para a RNA FAM.

Em Dagher et al. (1999) foi apresentado um algoritmo para otimização da ordenação dos padrões de entrada baseado no método de agrupamento Min-Max.

Em Gómez-Sánchez et al. (2002), para o problema de proliferação de categorias o mecanismo math tracking foi removido e as associações entre os módulos não-supervisionados mantidos. O treinamento off-line é reiniciado com um novo valor do parâmetro de vigilância (ρ) até que se atinja um valor de erro adequado predefinido.

Lim, Harrison (2003) realiza um estudo experimental da RNA Híbrida PFAM (Probabilistic Fuzzy ARTMAP), originada a partir da combinação das RNAs FAM e Probabilística (PNN), para classificação de padrões online em ambientes não estacionários. A cada amostra apresentada é realizada a previsão, e em sequência o treinamento. Assim, uma mesma amostra é utilizada para o treinamento bem como para o teste.

No trabalho de Parrado-Hernández, Gómez-Sánchez e Dimitriadis (2003), uma aprendizagem distribuída foi utilizada para atenuar a problema de proliferação de categorias. Aqui, a função de escolha ativa um grupo de neurônios para que ocorra a aprendizagem distribuída.

Em Vigdor e Lerner (2006) é investigado o desempenho da RNA FAM utilizando as estratégias de ordenação média e votação para a apresentação dos dados de treinamento, e também os modos de treinamento por época, com validação e até conclusão.

Mokhtar e Howe (2013) substitui a regra de aprendizagem Min-Max da ARTMAP Fuzzy por um classificador gaussiano, dando origem à ARTMAP Gaussiana. Essa modificação resultou em uma redução no problema de proliferação de categorias.

Em Jin et al. (2013), um grupo de RNAs FAMs recebem o mesmo conjunto de dados para o treinamento cuja ordenação é única para cada uma delas. Em seguida, o método de inferência bayesiana é utilizado para selecionar a classificação com melhor precisão entre as RNAs FAM. Dessa forma, reduz-se a influência da ordenação das amostras.

Em Zhang, Ji e Zhang (2014) o processo de competição entre as categorias para ativação foi modificado a fim de reduzir o problema de proliferação de categorias. O mecanismo combina a regra Q-max dinâmica e probabilidade posterior para aperfeiçoar a escolha da categoria e evitar as áreas de sobreposição.

No trabalho de Wang, Guo e Qian (2014) uma RNA FAM modificada foi utilizada na classificação de condições de ferramentas. Uma das modificações da RNA está em sua arquitetura, sendo removido o módulo ART_b e as categorias relacionadas diretamente pelo mapeamento. Além disso o autor apresenta uma aprendizagem incremental online, de forma que é possível prever categorias e manter a aprendizagem incremental simultaneamente.

Em Li, Yang e Wang (2015), os autores apresentam um sistema de sensoriamento remoto para estatística de área de produção e previsão de rendimento agrícola. Em sua metodologia a RNA FAM é utilizada para classificação, sendo que em sua aprendizagem uma estratégia de reforço adaptativo é adicionada.

No trabalho de Anitha e Chilambuchelvan (2015), uma nova versão da RNA FAM é utilizada em um sistema de recuperação de imagens. A versão proposta, denominada NPFAM, tem o objetivo de evitar a proliferação de categorias através de informações adicionais probabilísticas armazenadas no módulo Inter-ART e a relação one-to-many entre os módulos ART_a e ART_b .

Em Wong et al. (2015) o autor apresenta uma metodologia de aprendizagem online combinando a RNA FAM e OELM (Online Extreme Learning Machine). O modelo permite que a aprendizagem online inicie a partir das primeiras amostras de dados e também que a classificação possa ocorrer durante qualquer momento do treinamento.

No trabalho de Pourpanah, Lim e Saleh (2016), a técnica Q-learning é utilizada na fase de aprendizagem a fim de reduzir o número de categorias. As categorias com baixo valor de Q são removidas e por consequência a complexidade da RNA FAM diminuída.

Fariman et al. (2016) utiliza uma combinação das RNAs baseadas na teoria da ressonância adaptativa, FAM, Distributed ARTMAP, ART-EMAP e ARTMAP-IC, dando origem a RNA Best-ART. O modelo realiza a classificação de movimentos para aplicação em prótese de mão.

Kef, Chergui e Chikhi (2016) realiza o reconhecimento de caracteres árabes através de um conjunto de FAMs. O autor utiliza uma técnica de agrupamento baseado em características estruturais sendo que cada grupo alimenta uma das FAMs. Essa modificação proporcionou uma boa taxa de acertos principalmente para classificação de bases de dados extensas.

No trabalho de XU et al. (2016) um conjunto de FAMs realiza a classificação e um seletor com base no método de correlação e inferência bayesiana é utilizado para identificar casos anormais no diagnóstico de falhas em rolamentos.

Pourpanaha et al. (2017) utiliza três redes FAM Híbridas, QFAM, Pruned QFAM e QFAM-GA, como agentes de aprendizagem em um sistema multiagente (MAS). Para combinação das previsões para tomada de decisão final é utilizado o método TNC (trust-negotiation-communication) com medida de confiança baseada em Q-learning e formalismo bayesiano.

Em Benites e Sapozhnikova (2017), uma nova camada é adicionada à estrutura da RNA FAM, com o objetivo de criar uma arquitetura hierárquica que permite somente uma porção das categorias competirem à ativação.

3 REDES NEURAIIS ARTIFICIAIS ART

3.1 INTRODUÇÃO

As RNAs são modelos computacionais inspirados no sistema nervoso dos seres vivos. Possuem a capacidade de aquisição e manutenção de conhecimento e podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais (HAYKIN, 1999).

As principais características das RNAs são: aprendizado e generalização, processamento paralelo, não linearidade, robustez e flexibilidade. Os tipos de aprendizado mais utilizados de uma rede neural são realizados da forma supervisionado ou não supervisionado. No treinamento supervisionado para cada padrão de entrada obtém-se a respectiva saída desejada. Já a rede neural que possui treinamento não supervisionado é auto organizada, sendo capaz de descobrir novos padrões em resposta aos dados de entrada (HAYKIN, 1999).

Carpenter e Grossberg foram responsáveis por apresentar um conjunto de RNAs conhecido como família ART (Adaptive Resonance Theory). As redes ART permitem a aprendizagem incremental em ambientes que variam no tempo, aprendizagem estável rápida, escalas de generalização múltipla e convergência rápida com um número relativamente pequeno de padrões de treinamento (AMORIM, 2006). A razão pela qual as RNAs da família ART foram projetadas com tais características se deve ao dilema da plasticidade-estabilidade (GROSSBERG, 1976a, 1976b), uma vez que a busca pela solução do dilema orientou o desenvolvimento do modelo.

O dilema da plasticidade-estabilidade e a teoria da ressonância adaptativa são abordados nas sessões seguintes.

3.2 DILEMA ESTABILIDADE/PLASTICIDADE

A capacidade de adquirir o conhecimento de forma contínua e autônoma sem corromper ou esquecer o conhecimento previamente adquirido é essencial no tratamento de problemas em que os dados evoluem com o tempo. Para isso, um sistema de aprendizagem deve ser capaz de preservar seu conhecimento ao mesmo tempo em que assimila novas informações relevantes para o bom funcionamento do sistema. A ausência de tais habilidades em uma RNA pode levá-la a sofrer de um fenômeno conhecido como esquecimento

catastrófico em que as novas informações adquiridas substituem ou corrompem o conhecimento estabelecido na RNA através de dados anteriores (SHARKEY, N.; SHARKEY, A., 1995).

A estabilidade de uma RNA está associada à garantia de agrupamento de todos os elementos nas categorias criadas pelo modelo, tendo em vista que os pesos da rede possuem a característica somente de decrescimento, ou seja, à medida que as adaptações dos pesos são realizadas, os novos valores tendem sempre a diminuir até a estabilização. A plasticidade é a característica que a rede possui de aprender um novo padrão, em qualquer tempo de sua operação, sem perder o aprendizado adquirido anteriormente (AMORIM, 2006; LOPES, 2005).

O dilema da plasticidade-estabilidade tem como suas principais questões (AMORIM, 2006):

- I. Como um sistema de aprendizagem pode manter sua plasticidade (ser adaptável) em resposta às informações novas, ainda não conhecidas, e manter sua estabilidade diante da apresentação de informação irrelevante?
- II. Como pode um sistema preservar seu conhecimento adquirido e ao mesmo tempo ser suficientemente flexível para armazenar uma nova informação?
- III. Como o sistema pode decidir quando alternar do estado de estabilidade à plasticidade e vice-versa?

A resposta de Carpenter e Grossberg a este dilema foi a Teoria da Ressonância Adaptativa (Adaptive Resonance Theory, ART) (GROSSBERG, 1982a; GROSSBERG, 1982b) que será apresentada na próxima secção.

3.3 TEORIA DA RESSONÂNCIA ADAPTATIVA


O conceito de ressonância corresponde a “oscilações” que ocorrem em um sistema físico quando o mesmo é submetido a uma entrada de frequência específica (frequência de ressonância), usualmente definida pelas propriedades físicas do sistema (materiais, dimensões, disposição geométrica, etc.). Em uma rede ART, a aprendizagem ocorre quando as informações, na forma de saída das unidades de processamento (neurônios), “oscilam” entre as camadas de unidades da rede, desenvolvendo um estado de ativação de equilíbrio. Essas “oscilações” seriam o equivalente neural à ressonância em um sistema físico (AMORIM, 2006).

O trabalho de Carpenter e Grossberg a princípio gerou três classes de arquiteturas ART: ART1, ART2, e ART Fuzzy. A partir dessas, surgiram variações com objetivo de apresentar melhorias das já existentes ou propondo adaptações para problemas específicos.

Dentre alguns modelos que fazem parte da família ART, destacam-se:

- a) Rede neural ART1: rede que possui treinamento não-supervisionado. Possui a capacidade de reconhecer padrões de entrada binários de forma arbitrária (CARPENTER; GROSSBERG, 1987a);
- b) Rede neural ART2: rede que também possui treinamento não-supervisionado e emprega tanto padrões de entrada binários como padrões de entrada analógicos (CARPENTER; GROSSBERG, 1987b);
- c) Rede neural ART Fuzzy: rede baseada no treinamento não-supervisionado e que engloba em sua arquitetura cálculos baseados na lógica Fuzzy (CARPENTER; GROSSBERG; ROSEN, 1991);
- d) Rede neural ARTMAP: rede que possui treinamento supervisionado. É composta por dois módulos ART interconectados, através do módulo Inter-ART. Esta rede também pode identificar padrões de entradas binários ou analógicos (CARPENTER; GROSSBERG; REYNOLDS, 1991);
- e) Rede neural ARTMAP Fuzzy: esta rede possui treinamento supervisionado como a rede neural ARTMAP, porém, todos os cálculos são fundamentados na lógica nebulosa (CARPENTER et al., 1992).

Figura 1 - Família ART



Fonte: Próprio autor

3.4 REDE NEURAL ARTIFICIAL ART FUZZY


A rede ART Fuzzy, assim como as demais RNAs não-supervisionadas da família ART, é baseada em um sistema de aprendizagem competitivo que auto-organiza categorias de forma estável em resposta a sequências de padrões de entrada analógicos com componentes compreendidos entre 0 e 1. Estes padrões agregam-se em categorias ou agrupamentos com forma de hiper-retângulos, que cobrem distintas regiões do espaço de entrada. A formação de grupos é uma maneira de compressão, na qual se formam regras abstratas sobre a distribuição dos dados que permite certa generalização (AMORIM, 2006; LOPES, 2005; CARPENTER et al., 1992).

O uso de operadores difusos $\text{MIN}(\wedge)$ e $\text{MAX}(\vee)$ advindos da teoria de lógica difusa em conjunto com a codificação em complemento que preserva a amplitude da informação ao mesmo tempo que normaliza os vetores de entrada, permitem implementar o algoritmo de classificação não supervisionado com grande rapidez de aprendizagem (LOPES, 2005; CARPENTER et al., 1992).

A arquitetura de uma RNA ART Fuzzy é formada por três camadas, conforme figura (2), denominadas F_0 , F_1 e F_2 , que juntas implementam a verificação de similaridade entre um novo padrão apresentado a RNA e um padrão já representado por algum neurônio. Para cada camada existem sinais de controle visando à interconexão entre elas e a manipulação do fluxo de dados. A interconexão das camadas F_1 e F_2 são constituídas de pesos de tipo feedforward (w_i) e feedback (w_j), responsáveis pelo armazenamento das informações (CARPENTER et al., 1992).

A figura (2) apresenta a arquitetura da RNA ART Fuzzy.

Figura 2 - RNA ART Fuzzy



Fonte: Próprio autor

O processo de classificação de padrões da rede ART consiste em várias etapas divididas entre as camadas F_0 , F_1 e F_2 , cada uma delas com suas funções específicas.

3.4.1 Camada de entrada F_0

É responsável pelo tratamento do vetor de entrada a de dimensão M por meio da normalização e codificação em complemento que resultam no vetor de atividade I (CARPENTER et al., 1992).

$$I = \frac{a}{|a|} \quad (1)$$

sendo:

a = vetor de entrada;

$I = [I_1 \ I_2 \ \dots \ I_M]$ (Normalizado);

$|\cdot|$ = Função norma definida por:

$$|p| = \sum_{i=1}^M |p_i| \quad (2)$$

No processo de codificação em complemento do padrão de entrada a , sendo cada elemento a_i um número real pertencente ao intervalo $[0,1]$, produz um vetor de entrada I com $2M$ elementos tais como (CARPENTER et al., 1992):

$$I = (a, a^c) = (a_1, \dots, a_M, a_1^c, \dots, a_M^c) \quad (3)$$

sendo:


$$a_i^c = 1 - a_i \quad (4)$$

A codificação em complemento e a regra de normalização preservam a amplitude do padrão de entrada (CARPENTER et al., 1992):

$$|I| = |a, a^c| = \sum_{i=1}^M a_i + \left(M - \sum_{i=1}^M a_i \right) = M \quad (5)$$

A saída da camada F_0 é dada por seu vetor de atividade I , em um processo bottom-up em direção à camada superior F_1 .

Segue abaixo a figura (3) que descreve os processos na camada F_0 .

Figura 3 - Camada F_0 

Fonte: Próprio autor

3.4.2 Camada de comparação F_1

A camada F_1 ou camada de comparação, recebe sinais de baixo para cima (bottom-up) da camada F_0 , e de cima para baixo (top-down) da camada F_2 (camada de saída, que representa a categoria ativa), denotada por pelo vetor de ativação $y = y_1, \dots, y_N$ da camada F_2 (CARPENTER et al., 1992).

O vetor de ativação da camada F_1 é dado por $x = x_1, \dots, x_{2M}$, esse vetor resultante da operação fuzzy AND entre o vetor de entrada, ou vetor de atividade I da camada F_0 , e o vetor de pesos w_j referente à categoria ativa J da camada F_2 obedece a equação (6) (CARPENTER et al., 1992):

$$x = \begin{cases} I & \text{se } F_2 \text{ estiver inativa} \\ I \wedge w_j & \text{se existir categoria ativa em } F_2 \end{cases} \quad (6)$$

sendo:

I : Vetor de ativação da camada F_0 ;

w_j : Vetor de pesos entre as camadas F_1 e F_2 ;

$\wedge$: operador fuzzy AND definido por:


$$(p \wedge q)_i = \min(p_i, q_i) \quad (7)$$

para quaisquer vetores M -dimensionais p e q .

Os pesos entre as camadas F_1 e F_2 , são responsáveis pelo armazenamento das informações, ou seja, representa a memória da rede ART Fuzzy. São representados pela matriz w_{ji} , sendo que i de dimensão $2M$ definida no início do processo, representa cada elemento da categoria armazenada, e j de dimensão N representa cada categoria, dimensão essa que aumenta a cada nova categoria armazenada na matriz de pesos w pela RNA (CARPENTER et al., 1992).

A figura (4) descreve os processos na camada F_1 .

Figura 4 - Camada F_1



Fonte: Próprio autor

3.4.3 Camada de reconhecimento F_2

A camada F_2 , também chamada de camada de reconhecimento, possui N unidades de processamento que classificam os padrões de treinamento em categorias de reconhecimento aprendidas pela RNA (AMORIM, 2006; CARPENTER et al., 1992).

A categoria ativa J é selecionada através de um processo que atribui o valor da função de escolha T_j a cada unidade de processamento da camada F_2 , onde somente a unidade J com maior valor da função de escolha T_j é a ganhadora (em caso de empate, ganha a categoria J).

com $T_j = \max_j\{T_j\}$ e índice J mínimo). O neurônio da camada F_2 selecionado, envia à camada F_1 seu protótipo através do vetor de ativação $y = y_1, \dots, y_N$ da camada F_2 e o vetor de pesos w_j correspondente ao neurônio selecionado (CARPENTER et al., 1992).

A função de escolha de categoria é definida pela equação (8).


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

sendo:

α : parâmetro de escolha ($\alpha \geq 0$).

A figura (5) descreve os processos na camada F_2 .

Figura 5 - Camada F_2



Fonte: Próprio autor

3.4.4 Ressonância

O grau de semelhança entre o padrão de entrada e a categoria J ativa da camada F_2 determina se a RNA ativa o estado de ressonância ou reset. A RNA entra em ressonância caso a similaridade entre o padrão de entrada e a categoria J ativa atenda a exigência imposta pela RNA, caso contrário ocorre o chamado reset, que procura um novo neurônio na camada F_2 . O neurônio anterior, rejeitado no teste de similaridade é desabilitado até o final do processo corrente. Este processo é repetido, desabilitando neurônios da camada F_2 , até encontrar um neurônio que seja aprovado no teste de similaridade. Caso nenhum neurônio seja encontrado,

o vetor de entrada é então considerado de uma classe desconhecida, sendo criada uma nova categoria na camada F_2 associada ao padrão de entrada corrente (CARPENTER et al., 1992).

O grau de semelhança exigido no teste de similaridade é definido pelo parâmetro de vigilância (ρ), se o valor da comparação for maior do que ρ ($0 \leq \rho \leq 1$), então o padrão de entrada é incluído na categoria ativa e conseqüentemente no processo de aprendizagem, caso contrário, ocorre o reset, (CARPENTER et al., 1992).

O teste de similaridade é dado pela equação (9):

$$\frac{|I \wedge w_j|}{|I|} \geq \rho \quad (9)$$

Sendo:

I : Vetor de ativação da camada F_0 ;

w_j : Vetor de pesos da categoria ativa;

ρ : Parâmetro de vigilância.

3.4.5 Aprendizagem

O algoritmo de aprendizado da RNA ART é não-supervisionado e pode ser ativado a qualquer momento, permitindo que a rede aprenda novos padrões continuamente. Há dois tipos de treinamento para a rede neural ART: aprendizado rápido e aprendizado lento. No aprendizado rápido, os pesos de conexão são ajustados para seus valores ótimos em poucos ciclos, geralmente em apenas um ciclo de treinamento. No aprendizado lento, os pesos são ajustados lentamente em vários ciclos de treinamento, possibilitando um ajuste melhor dos pesos da rede aos padrões de treinamento (LOPES, 2005; CARPENTER; GROSSBERG, 1991).

Finalizado o processo de escolha de categoria e teste de vigilância, o vetor de pesos w_j é atualizado de acordo com a equação (10):


$$w_j^{novo} = \beta(I \wedge w_j^{velho}) + (1 - \beta)w_j^{velho} \quad (10)$$

em que $\beta \in [0,1]$ é a velocidade da aprendizagem e é especificada na etapa de aprendizagem da ART Fuzzy. A aprendizagem rápida ocorre quando $\beta = 1$, equação (11).

$$w_j^{novo} = I \wedge w_j^{velho} \quad (11)$$

O processo de aprendizagem da RNA ART Fuzzy é representado através do fluxograma dado pela seguinte figura (6):

Figura 6 - Fluxograma da RNA ART Fuzzy




Fonte: Lopes (2005)

3.5 REDE NEURAL ARTIFICIAL ARTMAP FUZZY

A RNA ARTMAP Fuzzy permite a aprendizagem supervisionada baseado nos princípios e conceitos que aparecem nas redes ART não supervisionadas. O modelo consiste em dois módulos ART Fuzzy, designados ART_a e ART_b , além do módulo Inter-ART. A figura (7) apresenta a arquitetura da RNA ARTMAP Fuzzy, sendo as entradas apresentadas no módulo ART_a e suas saídas correspondentes no módulo ART_b . O módulo Inter-ART determina o mapeamento entre os padrões de entrada e saída (CARPENTER et al., 1992).

Figura 7 - Arquitetura ARTMAP Fuzzy



Fonte: Próprio autor

3.5.1 MÓDULO Inter-ART

Após o processo de ressonância dos módulos ART_a e ART_b , o módulo Inter-ART verifica a correspondência entre as categorias ativas dos módulos ART_a e ART_b , resultando no vetor de ativação x^{ab} do módulo Inter-ART, equação (12) (CARPENTER et al., 1992):

$$x^{ab} = \begin{cases} y^b \wedge w_j^{ab} & F_2^a \text{ ativo e } F_2^b \text{ ativo} \\ w_j^{ab} & F_2^a \text{ ativo e } F_2^b \text{ inativo} \\ y^b & F_2^a \text{ inativo e } F_2^b \text{ ativo} \\ 0 & F_2^a \text{ inativo e } F_2^b \text{ inativo} \end{cases} \quad (12)$$

sendo:


y^b : Vetor de ativação da camada F_2^b do módulo ART_b ;

w_j^{ab} : Vetor do índice J da matriz de pesos do módulo Inter-ART, w^{ab} .

A matriz binária de pesos w^{ab} do módulo Inter-ART mapeia as categorias do módulo ART_a com sua respectiva categoria em ART_b . Portanto, uma vez ativada as categorias escolhidas em ART_a e ART_b , o módulo Inter-ART confirma a correspondência entre as categorias através do vetor w_j^{ab} . Caso contrário, o vetor x^{ab} assume o valor 0, e um novo processo de busca por categorias no módulo ART_a é executado até que seja validada a correspondência entre entrada e saída. Este mecanismo é denominado Match Tracking (CARPENTER et al., 1992).

A figura (8) descreve os processos do módulo Inter-ART.

Figura 8 - Módulo Inter-ART



Fonte: Próprio autor

3.5.1.1 Match Tracking

O objetivo do mecanismo é forçar a escolha de outra categoria no módulo ART_a em resposta ao erro de correspondência entre as categorias ativas em ART_a e ART_b . Como mencionado anteriormente, a categoria ativa do ART_a satisfaz o teste de vigilância, ou seja, o grau de semelhança entre o padrão de entrada do ART_a , vetor I^a , e a categoria ativa do ART_a ,

J^a , é maior do que o exigido no parâmetro de vigilância ρ_a . Logo, a fim de forçar a RNA a escolher outra categoria, o parâmetro ρ_a é incrementado com o valor estipulado no parâmetro de incremento ε até que a classe ativa atual não satisfaça mais o teste de vigilância (CARPENTER et al., 1992).

No início de cada padrão de entrada apresentado à ART_a , o parâmetro de vigilância ρ_a será igual ao valor de vigilância base, $\bar{\rho}_a$. Se a equação (13) é satisfeita, então ρ_a é ligeiramente incrementado com o valor de ε até que a equação (14) seja satisfeita (CARPENTER et al., 1992).

$$|x^{ab}| < \rho_{ab} |y^b| \quad (13)$$

sendo:

ρ_{ab} : parâmetro de vigilância do módulo Inter-ART.

$$|I^a \wedge w_j^a| < \rho_a |I^a| \quad (14)$$

Quando isso ocorre, o módulo ART_a busca novamente outra categoria para ativação, e o módulo Inter-ART realiza uma nova verificação de correspondência entre o padrão de entrada e saída (CARPENTER et al., 1992).

Após os processos de ressonância nos módulos ART_a e ART_b e o Match Tracking no módulo Inter-ART, a RNA está pronta para adquirir novas informações através da adaptação dos pesos w_j^a e w_{jk}^{ab} , referente aos módulos ART_a e Inter-ART, conforme as equações (15) e (16) (CARPENTER et al., 1992).

$$w_j^{novo} = \beta (I \wedge w_j^a) + (1 - \beta) w_j^a \quad (15)$$

$$w_{jk}^{novo} = 1 \quad (16)$$

sendo:


β : a taxa de treinamento ($\beta \in [0 \ 1]$).

A adaptação dos pesos do módulo ART_b é independente do módulo Inter-ART, haja vista que a classe ativa em ART_b não é mais alterada até a próxima entrada. Logo, sua adaptação de pesos é realizada após a ressonância de ART_b , conforme a equação (17) (CARPENTER et al., 1992).

$$w_k^{novo} = \beta (I \wedge w_k^b) + (1 - \beta) w_k^b \quad (17)$$

O processo de aprendizagem da RNA ARTMAP Fuzzy é representado através do fluxograma apresentado na figura (9):

Figura 9 - Fluxograma da rede ARTMAP Fuzzy



Fonte: LOPES (2005)

4 TREINAMENTO CONTINUADO

O treinamento continuado é um mecanismo que proporciona à RNA FAM a capacidade de realizar sua aprendizagem de forma online a partir das primeiras amostras de dados apresentadas à rede. Neste mecanismo, a cada padrão de entrada, a RNA realiza a previsão ou classificação, e em sequência o treinamento. Portanto, um mesmo padrão de entrada é utilizado tanto para o diagnóstico quanto para o treinamento.

A aprendizagem online permite a extração ininterrupta do conhecimento em relação ao problema abordado, favorecendo a adaptação da RNA a possíveis mudanças de comportamento dos dados de entrada no decorrer do diagnóstico. No entanto, requer que o modelo possua uma arquitetura flexível e algum mecanismo que evite a proliferação de categorias. A RNA FAM, devido a sua arquitetura originada a partir da ART, dispõe das características essenciais para um modelo com aprendizagem online, porém tende a apresentar o problema de proliferação de categorias, resultado da sobreposição das áreas de representação de cada categoria (GÓMEZ-SÁNCHEZ et al., 2002; PARRADO-HERNÁNDEZ; GÓMEZ-SÁNCHEZ; DIMITRIADIS, 2003).

Diante disto, modificações foram realizadas na arquitetura da RNA FAM e em seu algoritmo de aprendizagem com a finalidade de selecionar os dados de acordo com sua relevância e garantir a boa qualidade no processo de aprendizagem da RNA. O módulo ART_a passa a contar com duas camadas F_2 , denominadas, F_2 definitiva e F_2 temporária, além da adição dos parâmetros, N_{min} e N_{max} , responsáveis por ajustar o fluxo de informação entre as camadas.

4.1 ARQUITETURA DA REDE NEURAL ARTIFICIAL ARTMAP FUZZY COM TREINAMENTO CONTINUADO: CAMADA F_2 TEMPORÁRIA


A mudança da arquitetura da RNA ocorre na camada F_2 do módulo ART_a , que além da camada F_2 já existente é adicionada a camada F_2 temporária, responsável por categorias temporárias.

Uma vez que a RNA cria um novo neurônio em ART_a em virtude de não encontrar uma categoria compatível com o padrão de entrada, essa nova categoria é denominada como temporária e será representada por um vetor de pesos temporários, w_{temp} , pertencente à camada F_2 temporária. A nova categoria pode vir a ser incorporada à RNA em definitivo após

ser selecionada para representar novos padrões apresentados à RNA por um número mínimo de vezes, predefinido através do parâmetro N_{min} . Ou ainda, excluída permanentemente caso o número de padrões apresentados à rede ultrapasse o valor estipulado no parâmetro N_{max} , sem que a categoria temporária tenha sido utilizada. Portanto, categorias temporárias que satisfaçam os critérios estabelecidos pelos parâmetros, N_{min} e N_{max} , são incorporadas à camada F_2 definitiva e tornam-se parte do conhecimento permanente da RNA. Estas ações evitam que ocorra a proliferação de categorias e consequentemente uma possível sobrecarga de memória, além de reduzir o custo computacional e melhorar o desempenho da RNA.

A nova arquitetura é apresentada pela figura (10).

Figura 10 - Arquitetura da RNA FAM TC



Fonte: Próprio autor

Categorias temporárias representam informações recentes apresentados à RNA em que ainda não se sabe sua influência no desempenho do modelo, visto que, o aumento da frequência de entradas de características semelhantes pressupõe a tendência à um determinado comportamento do problema. Logo, se caracteriza como uma informação de boa qualidade para se associar ao conhecimento permanente da RNA. Já padrões de entradas únicos ou com baixa frequência de entradas com características semelhantes, pressupõe que sejam dados ruidosos e, portanto, com baixa qualidade para influenciar positivamente no bom desempenho

da RNA. Os parâmetros, N_{min} e N_{max} , determinam as frequências, mínima e máxima, para aquisição de novas informações pela RNA.

- N_{min} : número mínimo que uma categoria deve ser selecionada como vencedora para se tornar uma categoria definitiva (MARCHIORI et al., 2011).
- N_{max} : número máximo de entradas que uma categoria permanece como temporária sem que tenha atingido o valor de N_{min} . Após esse prazo a categoria é rejeitada (MARCHIORI et al., 2011).

4.2 MONITORAMENTO DE DADOS ATRAVÉS DO MÓDULO INTER-ART

O módulo Inter-ART especifica as combinações entre as categorias dos módulos ART_a e ART_b através de seus pesos obtidos na fase de treinamento. Além disso, na RNA FAM com treinamento continuado, o módulo Inter-ART passa a monitorar a disponibilidade de padrões de entrada nos módulos ART_a e ART_b a fim de ativar as seguintes sequências de procedimentos:

- Diagnóstico e treinamento supervisionado;
- Diagnóstico e treinamento não-supervisionado do módulo ART_a .

A RNA FAM, na sua concepção original, possui somente a aprendizagem supervisionada. Para que ocorra, é necessário que sempre exista padrões de entradas disponíveis para os módulos ART_a e ART_b . No caso de haver somente o padrão de entrada para o módulo ART_a , a RNA FAM irá iniciar a fase de diagnóstico. Portanto, a disponibilidade de padrões de entrada para o módulo ART_b determina se a RNA está na fase de treinamento supervisionado ou de diagnóstico. Já na RNA FAM com treinamento continuado, um mesmo padrão de entrada é utilizado tanto para o diagnóstico quanto para o treinamento, unificando os procedimentos. Dessa forma, o módulo Inter-ART monitora os módulos para ativar a sequência de procedimentos de forma correta através da equação (18):

$$x^{ab} = \begin{cases} y^b \wedge w_j^{ab} & F_2^a \text{ ativo e } F_2^b \text{ ativo} \\ w_j^{ab} & F_2^a \text{ ativo e } F_2^b \text{ inativo} \end{cases} \quad (18)$$

A equação (18) apresenta a saída dada pelo módulo Inter-ART de acordo com a disponibilidade de dados nos módulos ART_a e ART_b . De maneira que se existirem padrões de entrada atuais nos dois módulos ambos estarão ativados e a RNA executará os seguintes passos:

- Passo 1. Execução do procedimento de diagnóstico utilizando as categorias já existentes na RNA.
- Passo 2. Execução do procedimento de treinamento supervisionado da RNA utilizando os dados atuais disponíveis nos módulos ART_a e ART_b .

Uma vez que somente o módulo ART_a esteja ativado, ou seja, não há um padrão de entrada disponível no módulo ART_b , a RNA executará os seguintes passos:

- Passo 1. Execução do procedimento de diagnóstico utilizando as categorias já existentes na RNA.
- Passo 2. Execução do procedimento de treinamento do módulo ART_a (atualização dos pesos temporários ou definitivos).

O processo de monitoramento do módulo Inter-ART além de contribuir com melhorias para a implementação da aprendizagem online, permite à RNA FAM maior flexibilidade em relação ao fluxo de dados, já que não necessariamente exige o fluxo contínuo de dados nos módulos ART_a e ART_b . A execução dos procedimentos de treinamento supervisionado, treinamento não-supervisionado e de diagnóstico, podem se alternarem em resposta aos padrões de entrada disponíveis para ambos os módulos.

4.3 ALGORITMO DE APRENDIZAGEM E DIAGNÓSTICO DO TREINAMENTO CONTINUADO

Na aprendizagem online, o procedimento de treinamento e diagnóstico são executados de forma conjunta, de modo que para um mesmo padrão de entrada os dois procedimentos são executados em sequência. No diagnóstico, a RNA ativa a categoria que melhor representa o padrão de entrada por meio da função escolha e verifica se o grau de semelhança entre o padrão de entrada e a categoria ativa atende ao valor definido no parâmetro ρ_a . Neste processo, é previsto que surjam padrões de entrada com características muito distintas das categorias existentes, de maneira que é possível que nenhuma das categorias seja semelhante o suficiente para aprovação no teste de vigilância.

Diante disso, um novo mecanismo para o decremento automático do parâmetro ρ_a é implementado. Dessa forma, caso nenhuma das categorias existentes tenha a compatibilidade

suficiente com o novo padrão exigido pelo parâmetro ρ_a , o valor é decrementado gradualmente até que a categoria mais próxima se torne compatível.

A execução da RNA FAM TC (Rede Neural ARTMAP Fuzzy com Treinamento Continuado) pode ser descrito através dos seguintes passos:


- Passo 1. Apresentação do vetor de entrada para a RNA FAM TC.
- Passo 2. Se nenhuma categoria é compatível com o padrão de entrada atual, então o parâmetro ρ_a é decrementado com o valor de ε até que uma das categorias existentes seja aprovada no teste de vigilância. Na sequência o diagnóstico é realizado.
- Passo 3. Se, para a escolha da categoria vencedora no passo 2, o parâmetro ρ_a foi decrementado, então uma nova categoria temporária é criada. Caso contrário, os pesos da categoria vencedora são atualizados. Se existir dados de entrada no módulo ART_b , o treinamento será supervisionado.
- Passo 4. Se a categoria vencedora for definida como temporária, verifica-se o número de vezes que foi vencedora, caso tenha atingido o valor do parâmetro N_{min} , os pesos se tornam definitivos.
- Passo 5. Eliminam-se as categorias temporárias caso não cumpram os critérios estabelecidos pelos parâmetros N_{min} e N_{max} .

O conceito de treinamento continuado foi originalmente proposto por MARCHIORI et al. (2011) para análise de estabilidade transitória de sistemas de energia elétrica. No entanto, modificações importantes foram realizadas no processo. Em Marchiori et al. (2011), o treinamento continuado foi implementado sob a arquitetura da RNA ARTMAP Euclidiana, rede também pertencente à família ART. No processo de aprendizagem, parte do conjunto de amostras é destinado ao treinamento offline, nessa fase são criadas categorias nos módulos ART_a e ART_b e, posteriormente, na fase de diagnóstico, a RNA permite a atualização dos pesos das categorias pertencentes ao módulo ART_a caso identifique novas informações relevantes. Desse modo, segue as principais modificações proposta neste trabalho:

- Treinamento online a partir das primeiras amostras;
- Mecanismo de decremento do parâmetro ρ_a ;
- Treinamento supervisionado ativado em conjunto com o treinamento online;

Monitoramento da disponibilidade de dados nos módulos ART_a e ART_b a fim de ativar o treinamento supervisionado ou não-supervisionado. O fluxograma do treinamento continuado é apresentado pela figura (11).

Figura 11 - Fluxograma do Treinamento Continuado



Fonte: Próprio autor

5 RESULTADOS COMPUTACIONAIS

O desempenho da RNA FAM TC é avaliado por duas aplicações benchmarks, o dataset Spambase do repositório UCI Machine Learning (LICHMAN, 2013) e a série temporal de Mackey e Glass (1977). Para seleção das bases de dados preocupou-se em abordar tanto classificação quanto previsão com o objetivo de melhor avaliar o modelo.

A fim de viabilizar a comparação entre as RNAs FAM TC e FAM, cada dataset é dividido em duas partes, treino e teste.


A RNA FAM TC foi implementada na linguagem de programação Java 8 e processada em um Microcomputador com processador Intel Core i7-2600 3.4 GHz e 8,00 GB de Memória RAM.

5.1 CLASSIFICAÇÃO DE SPAMS

Na sua forma mais popular, um spam consiste numa mensagem de e-mail não solicitada com fins publicitários ou mal intencionada. Geralmente, os Spams têm caráter apelativo e, na grande maioria das vezes, são incômodos e inconvenientes. O termo Spam, no entanto, pode ser aplicado a mensagens enviadas por outros meios eletrônicos e com outras finalidades.

O spam é um problema que acompanha os serviços de e-mail desde o início da popularização da Internet, na década de 90, representando atualmente mais de 50% do total de e-mails trafegados no mundo. De acordo com os dados divulgados pela empresa de segurança virtual AO Kaspersky Lab, entre o quarto trimestre de 2016 e o primeiro trimestre de 2017, a média mensal de spams chegou a 61,66% no mês de novembro de 2016 (GUDKOVA et al., 2017).

Figura 12 – Porcentagem de spams no tráfego global de e-mail no 4º trimestre de 2016 e 1º trimestre de 2017



Fonte: Gudkova et al. (2017)

A consequência direta do spam é o consumo de recursos de máquina, de rede dos provedores de Internet e dos usuários, além do custo do tempo e da atenção humana gastos para selecionar e apagar as mensagens não solicitadas. Indiretamente, há o custo gerado pelas vítimas dos crimes que geralmente acompanham os spams, tais como roubo financeiro, roubo de identidade, roubo de dados e propriedade intelectual, vírus e outras infecções por malwares, pornografia infantil, fraudes e propagandas enganosas (SANTOS JUNIOR, 2013). Spams maliciosos na maioria dos casos estão relacionados com algum tipo de fraude financeira. Segundo o relatório divulgado pelo serviço de segurança digital Kasperky Lab, no primeiro trimestre de 2017, 55.90% do total de spams trafegados representaram algum tipo de ameaça financeira aos usuários (GUDKOVA et al., 2017).

Os filtros de spams são utilizados para impedir que o maior número possível de spams chegue ao usuário. Para isso, o sistema deve identificar e bloquear os e-mails que possuam características inerentes aos spams, geralmente auxiliado por técnicas de inteligência artificial capaz de distinguir com eficiência as diferenças nem sempre claras entre e-mails legítimos e spams. Na literatura encontram-se várias técnicas para filtragem de spams, entre elas destacam-se o uso das redes neurais artificiais, sistema imunológico artificial, SVM (Support Vector Machines), filtros bayesianos, lógica fuzzy, entre outros (UPASANA; CHAKRAVARTY, 2010).

O problema de classificação de spams, apresenta propriedades que o tornam desafiador para as estratégias utilizadas nos filtros de spams, principalmente pela mudança constante do conteúdo dos spams ao longo do tempo, dificultando o trabalho dos filtros em identificar as características específicas dos spams. Tal comportamento se justifica pela intensa busca dos spammers em burlar os filtros de spams, inovando a cada dia suas técnicas de envio de spams.

Assim, a classificação de spams apresenta problemas como, por exemplo (FAWCETT, 2003):

- Distribuição das classes distorcidas, ou seja, a proporção entre e-mails legítimos e spams é desigual e em constante mudança;
- Classe alvo complexa e em constante mudança;
- Dificuldade de medidas de desempenho devido aos erros de classificação falso positivo;
- Concept drift, pois se refere a um problema de aprendizagem não estacionário ao longo do tempo.

Diante disso, é possível afirmar que o problema de classificação de spams apresenta comportamentos que impõem dificuldades consideráveis para o filtro. Assim, para realização de um dos testes da RNA ARTMAP Fuzzy TC, foi utilizado o dataset Spambase do repositório UCI Machine Learning (LICHMAN, 2013).

O dataset Spambase foi gerado no laboratório da Hewlett-Packard e possui 4601 amostras, sendo 1813 spams. As amostras são compostas por 57 atributos que correspondem a palavras, caracteres e comprimento de sequências consecutivas de letras maiúsculas. O valor de cada atributo é definido de acordo com sua frequência no e-mail (LICHMAN, 2013).

O bom desempenho na tarefa de classificação tem forte dependência da qualidade da base de dados utilizada na fase de treinamento. A relação entre as características das amostras utilizadas no treinamento e as amostras utilizadas na fase de teste definem a qualidade da base de dados e sua complexidade, sendo que características semelhantes entre as bases de treinamento e teste facilitam a tarefa do classificador. Porém, quando se trata de problemas reais, nem sempre é possível prever as próximas amostras a serem classificadas, o que torna a classificação complexa.

Com o objetivo de melhor avaliar a RNA FAM TC e compará-la à FAM na tarefa de classificação, foram realizados três testes utilizando diferentes amostras do conjunto de dados de treinamento da RNA FAM. No teste 1, a amostra considerada é formada por 30% do conjunto de spams e 30% do conjunto de e-mails legítimos, portanto, a mesma porcentagem para ambas as classes. Já no teste 2, foram utilizados 10% do conjunto de spams e 50% do conjunto de e-mails legítimos, e no teste 3, 50% do conjunto de spams e 10% do conjunto de e-mails legítimos.

A variação do número de spams e e-mails legítimos no conjunto de treinamento tende a influenciar a taxa de acertos na classificação das amostras de acordo com as características mais presentes no treinamento.

A sequência das amostras no conjunto de treinamento foi composta alternando entre e-mails legítimos e spams, já o conjunto de teste, a primeira parte é formada pelos e-mails legítimos e em seguida por spams.

A tabela 1 apresenta os dados utilizados no conjunto de dados do treinamento da RNA FAM nos três testes realizados.

Tabela 1 - Conjunto de dados para Treinamento da ARTMAP Fuzzy

	Test 1	Test 2	Test 3
<i>Spams</i>	544 (30%)	181 (10%)	906 (50%)
<i>Legítimos</i>	836 (30%)	1394 (50%)	279 (10%)
TOTAL	1380	1575	1185

Fonte: Próprio autor

Os parâmetros utilizados nas RNAs FAM TC e FAM são apresentados na tabela 2:

Tabela 2 - Parâmetros RNAs FAM TC e FAM

	Teste 1		Teste 2		Teste 3	
	FAM TC	FAM	FAM TC	FAM	FAM TC	FAM
$\bar{p}_a$	0,82	0,88	0,80	0,91	0,76	0,72
N_{min}	3	-	6	-	3	-
N_{max}	600	-	200	-	1100	-

Fonte: Próprio autor

A figura (13) compara a evolução da acurácia a cada amostra classificada pelas RNAs FAM TC e FAM nos três testes realizados. A FAM TC inicia a classificação a partir das primeiras amostras e a FAM após a fase de treinamento finalizado. No teste 1, a FAM TC mantém seu desempenho estável durante todo o teste e apresenta uma melhora da taxa de acertos no decorrer das amostras uma vez que permanece ativa sua aprendizagem. Já a RNA FAM inicia a classificação a partir da 1381ª amostra e, apesar de superar a FAM TC no início da classificação, seu desempenho tende a diminuir no decorrer do teste à medida que o conhecimento adquirido na fase de treinamento se torna defasado. Neste teste a RNA FAM TC obteve acurácia de 91,4, enquanto que a RNA FAM atingiu 89,26.


No teste 2, apenas 10% dos spams integraram o conjunto de treinamento, sendo o restante formado por 50% dos e-mails legítimos. Esse conjunto levou a FAM a ter dificuldade na classificação dos spams, além da dificuldade natural de manter o desempenho diante de novas informações. A classificação da FAM teve início a partir da 1576ª amostra e, apesar de contar com um conjunto de treinamento com mais amostras que no teste 1, não consegue melhorar o desempenho. Já a RNA FAM TC mostrou sofrer pouca influência na classificação

dos spams em decorrência do baixo número de amostras de spams no início da classificação. Sua taxa de acertos manteve-se evoluindo e mostrou uma queda sutil a partir da 3000ª amostra. Neste teste a RNA FAM TC obteve acurácia de 93,65, enquanto que a RNA FAM atingiu 86,95.

No teste 3, apenas 10% dos e-mails legítimos integraram o conjunto de treinamento, sendo o restante formado por 50% dos spams. Mais uma vez, o baixo número de amostras de uma das classes no conjunto de treinamento leva a dificultar a classificação pela RNA FAM. A classificação teve início a partir da 1185ª amostra e no decorrer de toda classificação há o aumento de erros cometidos pela RNA, apesar de contar com um conjunto de treinamento com mais amostras que no teste 1, não consegue melhorar o desempenho. Já a RNA FAM TC apresenta estabilidade e melhora sua taxa de acertos a cada amostra apresentada. Neste teste a RNA FAM TC obteve acurácia de 89,7, enquanto que a RNA FAM atingiu 85,48.


Para garantir o aprendizado continuado, a arquitetura da RNA deve evoluir de acordo com o conhecimento adquirido ao longo das amostras. A figura (14) apresenta as categorias criadas pelas RNAs no decorrer dos três testes. Nota-se a criação de categorias da FAM apenas na fase de treinamento, limitando-se seu desempenho a depender da qualidade e quantidade de dados do conjunto de treinamento, enquanto que a FAM TC mantém ativa sua aprendizagem, realizando a seleção das informações relevantes através das variáveis N_{min} e N_{max} .

Figura 13 - Evolução da acurácia para cada amostra das RNAs FAM TC (azul) e FAM (vermelho)



Fonte: Próprio autor

Figura 14 - Números de neurônios criados no módulo ART_a das RNAs FAM TC e (azul) e FAM (vermelho)



Fonte: Próprio autor

A tabela 3 apresenta os resultados obtidos pelas RNAs FAM TC e FAM na classificação de spams.

Tabela 3 - Classificação de Spams

	<i>Modelo</i>	<i>Categorias ARTa</i>		<i>Acurácia</i>	
		<i>Definitiva</i>	<i>Temporária</i>	<i>Treino</i>	<i>Teste</i>
Teste 1	FAM TC	39	2	88,84	91,40
	FAM	36	-	-	89,26
Teste 2	FAM TC	37	0	94,73	93,65
	FAM	85	-	-	86,95
Teste 3	FAM TC	25	1	88,10	89,70
	FAM	12	-	-	85,48

Fonte: Próprio autor

5.2 PREVISÃO DA SÉRIE TEMPORAL MACKEY-GLASS

Uma série temporal é qualquer conjunto de dados ordenados no tempo e dispostos num determinado intervalo (SCHOPF, 2007). Para previsão de uma série, são necessárias duas condições básicas: Dados referentes ao comportamento passado da série temporal e assumir que esse comportamento pode se repetir no futuro (LOPES, 2005).

Visando determinar o comportamento de uma série, é possível definir duas categorias, estacionária e não-estacionária. Uma série temporal é considerada estacionária se os dados tiverem flutuações em torno de uma média constante no tempo. Caso os dados variem com o tempo, ou seja, se o padrão básico da série histórica dos dados apresentam padrões tendenciosos, cíclicos, sazonais ou aleatórios, a série temporal é dita não-estacionária (O'DONOVAN, 1983; LOPES, 2005).

Assim, com o objetivo de avaliar o desempenho da RNA FAM TC, a série temporal não-estacionária benchmark MACKEY e GLASS (1977) é utilizada neste trabalho para avaliar o desempenho do modelo na previsão de séries temporais à longo prazo. Os valores da série são obtidos através da equação diferencial variante no tempo (19) (KASABOV; SONG, 2002):

$$\frac{dx(t)}{dt} = \frac{0,2x(t - \tau)}{1 + x^{10}(t - \tau)} - 0,1x(t) \quad (19)$$

Para encontrar a solução numérica da equação, foi utilizado o método Runge-Kutta de quarta ordem. Assumindo-se o tamanho do passo $h = 0,1$, $x(0) = 1,2$, $\tau = 17$ e $x(t) = 0$

para $t < 0$. O objetivo é prever o valor de x_{t+85} para qualquer valor de t , considerando as entradas x_{t-18} , x_{t-12} , x_{t-6} , e x_t (KASABOV; SONG, 2002).

O conjunto de dados é formado por 3500 amostras, sendo que 3000 amostras foram obtidas no intervalo [201,3200] e 500 amostras foram obtidas no [5001,5500] (KASABOV; SONG, 2002).

Os parâmetros utilizados na RNA FAM TC foram os seguintes:

- Parâmetro de vigilância inicial do módulo ART_a ($\bar{\rho}_a$) = 0,97;
- Parâmetro de vigilância do módulo ART_b (ρ_b) = 0,99;
- Parâmetro de vigilância do módulo Inter-ART (ρ_{ab}) = 1;
- Taxa de treinamento $\beta = 1$;
- Parâmetro de escolha $\alpha = 0,001$;
- Parâmetro $N_{min} = 2$;
- Parâmetro $N_{max} = 1500$.

As análises de desempenho foram baseadas no valor da raiz do erro quadrático médio (RMSE- root mean square error), equação (20).

$$RMSE = \frac{1}{N} \left(\sum_{t=1}^N (y_t - \hat{y}_t) \right)^{\frac{1}{2}} \quad (20)$$

sendo:

N = número total de amostras do conjunto;

$\hat{y}_t$ = saída desejada;

y_t = saída estimada;

Os resultados obtidos foram comparados com a RNA FAM, para isso, as amostras no intervalo de $t = 1$ à $t = 875$ foram reservados para o treinamento desta RNA.


A figura (15) compara o valor real e o valor previsto pelas RNAs FAM TC e FAM dos primeiros 1000 pontos de previsão. Na figura (15a), apresenta a previsão realizada pela FAM TC e na figura (15b) a previsão realizada pela RNA FAM.

Na figura (15), o erro na previsão de cada ponto é apresentado. A figura (16a) mostra a capacidade da RNA FAM TC de manter o bom desempenho no decorrer da previsão, uma vez que o erro tende a diminuir à medida que realiza a manutenção do conhecimento através da aprendizagem online. No entanto, na figura (16b), nota-se o aumento do erro de forma gradual a partir do início da previsão da RNA FAM. Tal comportamento pode ser justificado pela defasagem do conhecimento adquirido na fase de treinamento, já que as previsões de pontos

distantes das amostras utilizadas para aprendizagem tendem a apresentar cada vez mais características diferentes.


A aprendizagem online requer uma arquitetura flexível da RNA, as figuras (17) e (18) apresentam a evolução da estrutura do modelo para cada entrada. É importante notar que o treinamento continuado possibilita a criação de categorias sempre que necessário, assim como a exclusão de neurônios temporários. No módulo ART_b , a RNA FAM TC se estabilizou por volta da 85ª categoria, enquanto que a FAM precisou de 161 categorias. Já o módulo ART_a da RNA FAM TC estabilizou por volta de 190 categorias definitivas e 1000 categorias temporárias, enquanto que a RNA FAM criou 789 categorias.

Figura 15 - (a) Previsão da série temporal Mackey Glass através das RNA FAM TC. (b) Previsão da série temporal Mackey Glass através da RNA FAM. O gráfico compara a saída real do conjunto de dados (azul) com a saída prevista.




Fonte: Próprio autor

Figura 16 - Erro na previsão da série temporal Mackey Glass. (a) RNA FAM TC e (b) RNA FAM




Fonte: Próprio autor

Figura 17 Números de neurônios criados no módulo ART_b das RNAs FAM TC (azul) e FAM (vermelho)



Fonte: Próprio autor

Figura 18 - Números de neurônios criados no módulo ART_a das RNAs FAM TC e (azul) e FAM (vermelho).



Fonte: Próprio autor

A tabela 4 apresenta os resultados obtidos pelas RNAs FAM TC e FAM na previsão de série temporal.

Tabela 4 - Previsão da série temporal de Mackey-Glass

Modelo	<i>Categorias ART_a</i>		<i>Categorias ART_b</i>	<i>RMSE</i>	
	<i>Definitivo</i>	<i>Temporária</i>		<i>Treino</i>	<i>Teste</i>
FAM TC	171	1099	89	0,0437	0,0279
FAM	789	-	161	-	0,1826

Fonte: Próprio autor

6 CONCLUSÕES

Neste trabalho, foi apresentada uma nova abordagem de aprendizagem online para a RNA FAM. O modelo introduziu o conceito de treinamento continuado que capacita a RNA a adquirir conhecimento ao longo do diagnóstico a partir das primeiras amostras. Para isto, modificações foram realizadas na arquitetura e no algoritmo da RNA FAM, como a inclusão de uma nova camada no módulo ART_a , uma nova estratégia de ajuste do parâmetro ρ_a em função do padrão de entrada, seleção das categorias relevantes através dos parâmetros N_{min} e N_{max} , e ativação automática de aprendizagem supervisionada em virtude da disponibilidade de dados no módulo ART_b .

O modelo foi avaliado utilizando-se a classificação do dataset Spambase e a previsão da série temporal Mackey e Glass (1977). Em ambas as aplicações, a RNA FAM TC teve seu desempenho comparado com a RNA FAM para validar as contribuições do trabalho proposto.

Na tarefa de classificação de spams foram realizados três testes, sendo que para cada teste foram selecionadas quantidades diferentes de amostras entre spams e e-mails legítimos para formar o conjunto de treinamento. O objetivo dos diferentes testes foi variar as características mais presentes no conjunto de treinamento entre spams e e-mails legítimos. Para todos os testes, a RNA FAM TC apresentou melhora na taxa de acertos ao longo da classificação, uma vez que mantém sua aprendizagem ativada para manutenção eficiente do conhecimento. Já a RNA FAM, mostrou no decorrer da classificação uma redução gradual do desempenho à medida que o conhecimento adquirido na fase de treinamento se torna obsoleto em relação às amostras atuais. Ainda pode-se notar através da figura 13 que a RNA FAM TC realiza a seleção de informações relevantes de forma eficiente, contribuindo no controle de proliferação de categorias e no número reduzido de categorias definitivas.

A previsão da série temporal caótica de Mackey e Glass (1977) mostrou a boa capacidade da RNA FAM TC em realizar a manutenção do conhecimento de forma eficiente. Esta característica garante o bom desempenho no decorrer da previsão, uma vez que o erro tende a diminuir à medida que novas informações são assimiladas através do treinamento continuado. Por outro lado, a RNA FAM tem o comportamento oposto, sendo que o erro na previsão tende a aumentar à medida que os pontos previstos se distanciam dos pontos utilizados no treinamento. Assim, para a RNA FAM, as categorias criadas na fase de treinamento são mantidas durante todo o processo, já a RNA FAM TC, evolui sua estrutura através da inclusão de neurônios temporários e definitivos e exclusão de neurônios temporários.

Os resultados apresentados confirmam a capacidade da RNA FAM TC de adquirir conhecimento ao longo das amostras apresentadas de forma estável e eficiente, garantindo a qualidade do diagnóstico através da seleção de informações relevantes para seu bom desempenho a longo prazo.

Diante disso e da necessidade crescente de modelos que suportem a aprendizagem online, a RNA FAM TC demonstra ser uma boa alternativa para aplicações e estudos que exijam a capacidade de manutenção eficiente do conhecimento. Além disso, contribui para a evolução da RNA ARTMAP Fuzzy.

6.1 SUGESTÕES PARA TRABALHOS FUTUROS

Para dar sequência a esta pesquisa, sugerem-se os seguintes tópicos:

- Explorar novas abordagens para o controle de proliferação de categorias;
- Investigar possibilidade de melhorias no processo de decremento no valor do parâmetro de vigilância com foco na redução do tempo de processamento;
- Avaliar a influência dos parâmetros no desempenho da metodologia após longo período sem ajustes.

REFERÊNCIAS

- AMORIM, D. G. **Redes ART com categorias internas de geometria irregular**. 2006. 246 f. Tese (Doutorado em Física) – Departamento de Eletrônica e Computação, Universidade de Santiago de Compostela, Santiago de Compostela, 2006.
- ANITHA, K.; CHILAMBUHEL VAN, A. NPFAM: Non-Proliferation Fuzzy ARTMAP for Image Classification in Content Based Image Retrieval. **KSII Transactions on Internet and Information Systems**, Seoul, v. 9, n. 7, p. 2683-2702, 2015.
- BENITES, F.; SAPOZHNIKOVA, E. Improving scalability of ART neural networks. **Neurocomputing**, Libertyville, v. 230, p. 219-229, 2017.
- CARPENTER, G. A.; GROSSBERG, S. A massively parallel architecture for a self-organization neural pattern recognition machine. **Computer Vision, Graphics, and Image Processing**, Maryland Heights, v. 37, p. 54-115, 1987a.
- CARPENTER, G. A.; GROSSBERG, S. ART2: Self-organization of stable category recognition codes for analog input patterns. **Applied Optics: Special Issue on Neural Networks**, New York, v. 26, p. 4919–4930, 1987b.
- CARPENTER, G. A.; GROSSBERG, S. **Pattern Recognition by Self-Organizing Neural Networks**. Cambridge. The MIT, 1991.
- 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.
- CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. Fuzzy ART: Fast Stable Learning and Categorization of Analog Patterns by an Adaptive Resonance System. **Neural Networks**, Kidlington, v. 4, n. 6, p. 759-771, 1991.
- CARPENTER, G. A. et al. Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Networks**, Piscataway, v. 3, n. 5, p. 698-713, 1992.
- DAGHER, I. et al. An ordering algorithm for pattern presentation in fuzzy ARTMAP that tends to improve generalization performance. **IEEE Transactions on Neural Networks**, Piscataway, v. 10, n. 4, p. 768-778, 1999.
- FARIMAN, H. J. et al. Hand movements classification for myoelectric control system using adaptive resonance theory. **Australasian Physical and Engineering Science in Medicine**, Dordrecht, v. 39, n. 1, p. 85-102, 2016.
- FAWCETT, T. “In vivo” spam filtering: A challenge problem for KDD. **ACM SIGKDD Explorations Newsletter**, New York, v. 5, n. 2, p. 140-148, 2003.
- GHARAVIAN, D.; BEJANI, M.; SHEIKHAN, M. Audio-visual emotion recognition using FCBF feature selection method and particle swarm optimization for fuzzy ARTMAP neural networks. **Multimedia Tools and Applications**, New York, v. 76, n. 2, p. 2331-2352, 2015.

GÓMEZ-SÁNCHEZ, E. et al. μ ARTMAP: Use of Mutual Information for Category Reduction in Fuzzy ARTMAP. **IEEE Transactions on Neural Networks**, Piscataway, v. 13, n. 1, p. 58-69, 2002.

GROSSBERG, S. **A Theory of human memory: Self-organization and performance of sensor-motor codes, maps, and plans**. Studies of mind and brain. Boston: Reidel, 1982a. p. 498-639.

GROSSBERG, S. **Behavioral contrast in short-term memory: Serial binary memory models or parallel continuous memory models**. Studies of mind and brain. Boston: Reidel, 1982b. p. 425-447.

GROSSBERG, S. Adaptive pattern classification and universal recoding, I: Parallel development and coding of neural feature detectors. **Biological Cybernetics**, Heidelberg, v. 23, p. 121-134, 1976a.

GROSSBERG, S. Adaptive pattern recognition and universal recoding, II: Feedback, expectation, olfaction, and illusions. **Biological Cybernetics**, Heidelberg, v. 23, p. 187-202, 1976b.

GUDKOVA, D. et al. **Spam and phishing in Q1 2017. Spam: quarterly highlights**. SECURELIST, 2017. Disponível em: <<https://securelist.com/spam-and-phishing-in-q1-2017/78221/>> Acesso em: 01 ago. 2017.

HAYKIN, S. **Neural networks: a comprehensive foundation**. 2. ed. New Jersey: Prentice Hall, 1999. 842 p.

JIN, M. et al. Fuzzy ARTMAP ensemble based decision making and application. **Mathematical Problems in Eng.**, New York, v. 2013, p. 1-7, 2013.

JIN, M. et al. Reliable fault diagnosis method using ensemble fuzzy ARTMAP based on improved Bayesian belief method. **Neurocomputing**, Libertyville, v. 133, p. 309-316, 2014.

KASABOV, N.; SONG, Q. Denfis: Dynamic evolving neural-fuzzy inference system and its application for time-series prediction, **IEEE Transactions on Fuzzy Systems**, Piscataway, v. 10, n. 2, p. 144-154, 2002.

KEF, M.; CHERGUI, L.; CHIKHI, S. A novel fuzzy approach for handwritten Arabic character recognition. **Pattern Analysis and Applications: Theoretical Advances**, London, v. 19, p. 1041-1056, 2016.

LI, D. W.; YANG, F. B.; WANG, X. X. Crop region extraction of remote sensing images based on fuzzy ARTMAP and adaptive boost. **Journal of Intelligent & Fuzzy Systems**, Amsterdam, v. 29, p. 2787-2794, 2015.

LICHMAN, M. **UCI Machine learning repository**. California: University of California, School of Information and Computer Science, 2013. Disponível em: <<https://archive.ics.uci.edu/ml/datasets/spambase>>. Acesso em: 04 maio 2017.

LIM, C. P.; HARRISON, R. F. Online pattern classification with multiple neural network systems: an experimental study. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, Piscataway, v. 33, n. 2, p. 235-247, 2003.

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, p. 235–244, 2005.

LOPES, M. L. **Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica**. 2005. 169 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2005.

MACKEY, M. C.; GLASS, L. Oscillation and chaos in physiological control systems. **Science**, Washington, v. 197, n. 4300, p. 287–289, 1977.

MARCHIORI, S. C. et al. 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.

MOKHTAR, M.; HOWE, J. Comparing the online learning capabilities of Gaussian ARTMAP and Fuzzy ARTMAP for building energy management systems. **Expert Systems with Applications**, Kidlington, v. 40, p. 6007–6018, 2013.

O'DONOVAN, T. M. **Short term forecasting: an introduction to the box-jenkins approach**. New York: John Wiley & Sons, 1983.

OLIVEIRA, M. A. de; INMAN, D. J. Performance analysis of simplified Fuzzy ARTMAP and Probabilistic Neural Networks for identifying structural damage growth. **Applied Soft Computing**, Amsterdam, v. 52, p. 53-63, 2017.

PARRADO-HERNÁNDEZ, E.; GÓMEZ-SÁNCHEZ, E.; DIMITRIADIS, Y. A. Study of distributed learning as a solution to category proliferation in Fuzzy ARTMAP based neural systems. **Neural Networks**, Kidlington, v.16, p. 1039–1057, 2003.

POURPANAH, F.; LIM, C.P.; SALEH, J.M. A hybrid model of fuzzy ARTMAP and genetic algorithm for data classification and rule extraction. **Expert Systems with Applications**, Kidlington, v. 49, p. 74–85, 2016.

POURPANAH, F. et al. A Q-learning-based multi-agent system for data classification. **Applied Soft Computing**, Amsterdam, v. 52, p. 519-531, 2017.

SANTOS, F. L. et al. Performance of a Fuzzy ARTMAP Artificial Neural Network in Characterizing the Wave Regime at the Port of Sines (Portugal). **Journal of Coastal Research**, Coconut Creek, v. 32, n. 6, p. 1362-1373, 2016.

SANTOS JUNIOR, C. R. **Teoria da ressonância adaptativa através da linguagem Java para detecção e classificação de e-mails indesejados**. 2013. 77 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica, Universidade Estadual Paulista, Ilha Solteira, 2013.

SCHOPF, E. C. **Método neuro-estatístico para predição de séries temporais ruidosas**. 2007. 105 f. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2007.

SHARKEY, N. E.; SHARKEY, A. J. C. An analysis of catastrophic interference. **Connection Science**, Abingdon, v. 7, p. 301–329, 1995.

UPASANA, S. C.; CHAKRAVARTY, S. A Survey of Text Classification Techniques for E-mail Filtering. INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND COMPUTING, 2., 2010, Washington. **Proceedings...** Washington: [s. n.], 2010. p. 32-36.

VIGDOR, B.; LERNER, B. Accurate and Fast Off and Online Fuzzy ARTMAP-Based Image Classification With Application to Genetic Abnormality Diagnosis. **IEEE Transactions on Neural Networks**, Piscataway, v. 17, n. 5, p. 1288-1300, 2006.

WANG, G.; GUO, Z.; QIAN, L. Online incremental learning for tool condition classification using modified Fuzzy ARTMAP network. **Journal of Intelligent Manufacturing**, New York, v. 25, n. 6, p. 1403–1411, 2014.

WONG, S. Y. et al. A Truly Online Learning Algorithm using Hybrid Fuzzy ARTMAP and Online Extreme Learning Machine for Pattern Classification. **Neural Processing Letters**, New York, v. 42, p. 585-602, 2015.

XU, Z. et al. A selective fuzzy ARTMAP ensemble and its application to the fault diagnosis of rolling element bearing. **Neurocomputing**, Libertyville, v. 182, p. 25-35, 2016.

ZHANG, Y., JI, H., ZHANG, W. TPPFAM: Use of threshold and posterior probability for category. **Neurocomputing**, Libertyville, v. 124, p. 63-71, 2014.