

Rede neural ARTMAP Fuzzy com treinamento continuado para detecção de spams

C. R. Santos Junior, T. Abreu, A. D. P. Lotufo

FEIS – Faculdade de Engenharia de Ilha Solteira

Universidade Estadual Paulista – UNESP

Ilha Solteira-SP, Brasil

carlos9.rsj@gmail.com, thays7abreu@gmail.com, annadiva@ieee.org.

Abstract—O problema de mensagens não solicitadas pelos usuários em meios de comunicação eletrônica, embora tenha surgido antes mesmo da popularização da Internet, ainda é um assunto preocupante. Desperdício de largura de banda, perda de tempo, de produtividade e de dados, ou atraso na leitura de e-mails legítimos, são alguns dos problemas que os spams podem causar. Diversas técnicas de filtragem automática de e-mails são apresentadas na literatura, porém muitas destas necessitam de um novo processo de treinamento para acompanhar a evolução das técnicas de evasão, já que o problema em sistemas reais tem como uma de suas principais características a constante busca por novos métodos. Neste trabalho é proposta uma rede neural ARTMAP Fuzzy com treinamento continuado para detecção de spams. O modelo proposto neste trabalho é testado a fim de validar sua eficiência.

Keywords—E-mail, Spam, Filtro de spams, Rede Neural ARTMAP Fuzzy, Treinamento Continuado.

I. INTRODUÇÃO

A necessidade de uma forma de comunicação rápida e econômica tornou-se imprescindível no mundo globalizado, necessidade essa suprida com o uso dos e-mails que permitem atingir inúmeros destinatários com facilidade e sem aumento de custos. Estas vantagens também foram observadas pelos Spammers que através do envio de e-mails não solicitados levam aos destinatários, quase sempre de forma incômoda e inconveniente, conteúdos publicitários ou códigos maliciosos. O número de spams se tornou absurdamente maior se comparado aos e-mails legítimos, como mostram estatísticas divulgadas por grandes corporações de segurança que indicaram no ano de 2014 o total de 66,76% de spams em relação aos e-mails trafegados no mundo [1]. Esses dados representam grande insatisfação dos usuários, já que os spams causam inúmeros problemas, como inundação nas caixas de e-mails consumindo tempo, dinheiro, largura de banda, além de fraudes, roubos, etc.

Os filtros anti-spam são utilizados para identificar e bloquear o maior número possível de spams de chegarem aos usuários. Na literatura encontram-se várias técnicas para filtragem, entre elas destacam-se o uso das Redes Neurais Artificiais (RNA), Sistema Imunológico Artificial, SVM (Support Vector Machines), filtros Bayesianos, Lógica Fuzzy, entre outros [2].

No trabalho de [3], o princípio da descrição mais simples auxiliado por fator de confiança (MDL-CF) com treinamento por erro (Train On Error), formaram o modelo de filtro anti-spam. As bases de dados TREC05, TREC06 e CEAS08 foram utilizadas nos testes. Em [4] a base de regras disponibilizada em [5] é utilizada para criar uma tabela de palavras válidas para pré-processar os e-mails e alimentar a RNA Perceptron Multicamadas com o algoritmo de treinamento Backpropagation. A base de dados utilizada é a SpamAssasin. No trabalho de [6] é utilizado no pré-processamento o software WEKA [7] e redes Bayesianas combinadas com RNA com treinamento baseado em algoritmo genético para classificação. Uma base de dados formada pelo próprio autor foi utilizada para os testes. Já nos trabalhos de [8] e [9] é utilizado o mesmo modelo de pré-processamento proposto por [8]. As RNAs SOM-WTA e SOM-LVQ foram as escolhidas por [9] e a RNA Perceptron Multicamadas em ambos os trabalhos. Além da base de dados SpamAssasin utilizadas nos trabalhos, [9] também inclui amostras de e-mails originadas no Brasil.

Uma RNA é um processador maciçamente paralelamente distribuído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Ela se assemelha ao cérebro por dois aspectos principais: O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem e, as conexões sinápticas entre neurônios são utilizadas para armazenar o conhecimento adquirido [10].

Diversas técnicas de filtragem automática de e-mails são apresentadas na literatura, porém muitas destas não oferecem a possibilidade de adaptação, já que o problema em sistemas reais tem como principal característica ser dinâmico, ou seja, evadir as técnicas de filtragem. Neste trabalho é proposto um modelo dinâmico utilizando uma técnica de pré-processamento disponível na literatura, no qual os e-mails são submetidos à extração de características; e a Rede Neural Artificial ARTMAP Fuzzy com treinamento continuado, para detecção e classificação de spams. A principal motivação de utilizar o treinamento continuado, é que este possibilita a aprendizagem da RNA de modo on-line, ou seja, o treinamento da rede é realizado de forma contínua, sem que seja necessário reiniciá-lo.

II. MODELO PROPOSTO

O modelo proposto esta dividido em duas fases, a do pré-processamento, proposto por Carpinteiro et al. [8], e fase de classificação.

A metodologia proposta esta ilustrada na Figura 1.

Pré-Processamento

O desempenho na tarefa de classificação das RNAs esta relacionado diretamente à qualidade dos dados utilizados na fase de treinamento. O pré-processamento tem a função de garantir a extração e seleção minuciosa das características da base de dados, de forma que os dados sem informações irrelevantes, mais simples e uniformes possibilitam a RNA aperfeiçoar o processo de classificação. O pré-processamento pode ser dividido em quatro etapas: Processamento HTML, Tokenização, Detecção de Padrões e Seleção de Características [8].

A. Processamento HTML

O formato HTML permite adicionar ao corpo do e-mail, formatação de texto, tabelas, hiperlinks, imagens, etc. Essas personalizações são possíveis por uso das chamadas tags. Seguem o seguinte padrão: < nome-tag parâmetro > Texto da tag < nome-tag >.

B. Tokenização

Emails no formato de texto original, ou e-mails no formato HTML depois de processados, são enviados ao processo de tokenização. O processo simplesmente separa o texto em tokens, ou seja, simples palavras. São utilizados como delimitadores os seguintes caracteres: espaço, nova linha, tabulação, exclamação, interrogação, vírgula e ponto e vírgula. Também neste processo todos os caracteres são passados a forma minúscula e é removida toda acentuação.

C. Detecção de Padrões

Identifica padrões de textos conhecidos e utilizados por spammers como técnicas para evadir filtros de spams, e unifica padrões de texto para se obter uma única saída.

D. Seleção de Características

A maior dificuldade na classificação de textos é a alta dimensionalidade do espaço característico, já que cada palavra é considerada um espaço característico. Para contornar essa dificuldade é necessário o uso de métodos estatísticos a fim de selecionar as palavras mais relevantes para representar as classes spam ou ham.

Neste trabalho a seleção dessas palavras foi auxiliada pelo método Frequency Distribution (FD) que tem como objetivo medir o grau de ocorrência de um termo t em um conjunto C . O FD do termo t é calculado conforme equação (1):

$$FD(t) = \frac{n[t \in C]}{T} \quad (1)$$

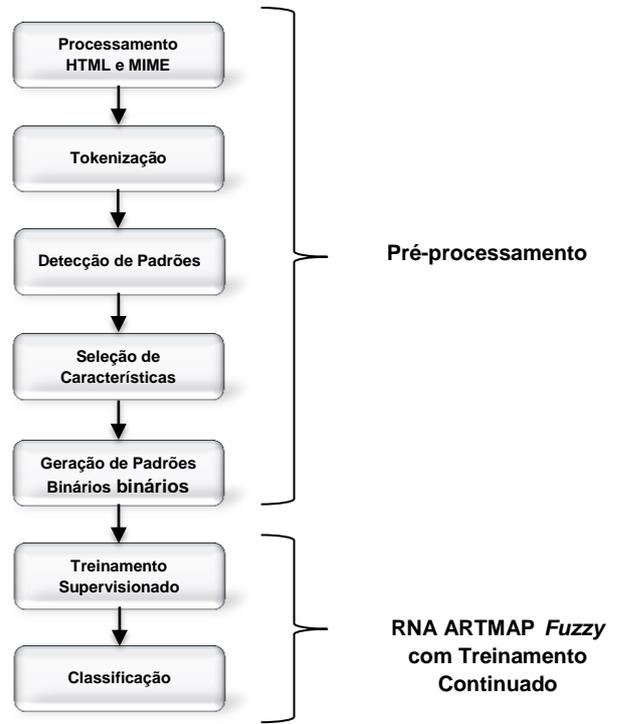


Fig. 1. Diagrama de blocos da metodologia proposta

RNA ARTMAP Fuzzy

A RNA ARTMAP *Fuzzy* é caracterizada por um conjunto de equações que implementam as propriedades da Teoria da Ressonância Adaptativa (ART), objetivando a aprendizagem incremental e supervisionada [12].

É orientada a categorizar de forma estável padrões de entrada e saída com valores difusos, quer dizer, no intervalo [0, 1], e que, portanto, se pode interpretar como graus de pertinência aos conjuntos difusos. Nas operações são utilizados operadores difusos $MIN(\wedge)$ e $MAX(\vee)$, respectivamente, da teoria de lógica fuzzy [13].

A ARTMAP *Fuzzy* constrói correspondências entre as múltiplas entradas e saídas, convertendo-se num associador de padrões. No caso particular em que um dos padrões seja a predição de saída desejada para o padrão de entrada, a rede permite o tratamento de problemas de classificação supervisionada de padrões. Por isso, baseiam-se em duas RNAs ART *Fuzzy* (ART_a e ART_b) e em um módulo F_{ab} (módulo MapField) entre as camadas F_2 de ambas as redes [13]. Na figura 2 esta ilustrada a arquitetura da rede neural ARTMAP *Fuzzy* [11].

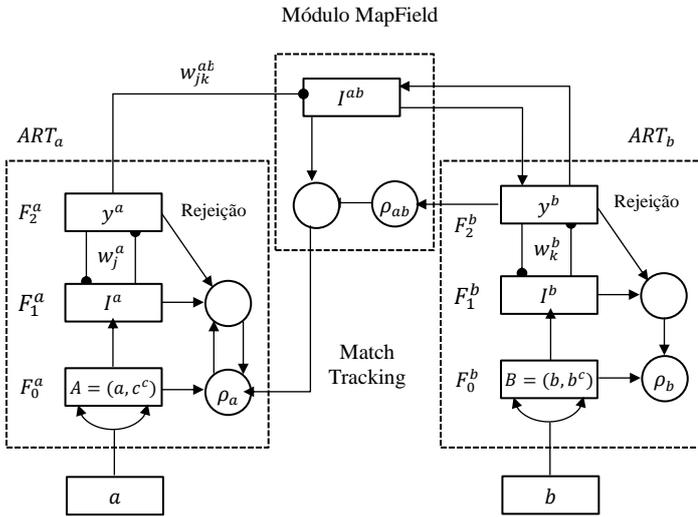


Fig. 2. Estrutura da RNA ARTMAP Fuzzy

Os parâmetros fundamentais da rede neural ARTMAP-Fuzzy são definidos a seguir [11]:

- Parâmetro de escolha α ($\alpha > 0$): Atua na seleção de categorias;
- Taxa de treinamento β ($\beta \in [0, 1]$): Controla a velocidade da adaptação da rede;
- Parâmetro de vigilância (ρ_a , ρ_b e ρ_{ab}): Controla a ressonância da rede, isto é, o parâmetro responsável pelo número de categorias criadas.

Cada módulo ART é composto por três camadas: sendo F_0 a camada de entrada, F_1 a camada de comparação, e F_2 a camada de reconhecimento, que realiza o armazenamento em categorias. Os dados (I) fornecidos para a camada F_0 estão na forma de codificação de complemento. As camadas F_1 e F_2 são conectadas pelos pesos (w_j^a no ARTa e w_k^b no ARTb). Estes pesos são utilizados no processo de escolha da categoria, sendo que para cada vetor de entrada (I) em F_1 e o índice J em F_2 é possível definir a função de escolha T_j de acordo com equação (2), onde (\wedge) é o operador *fuzzy* AND. A escolha da categoria é realizada conforme (3), sendo J o índice ativo de F_2 [11].

$$T_j(I) = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (2)$$

$$J = \operatorname{argmax} T_j \quad (3)$$

A ressonância ocorre caso o teste de vigilância (4) seja satisfeito para o índice ativo J [11].

$$\frac{|I \wedge w_j|}{|I|} \geq \rho \quad (4)$$

Caso o teste de vigilância descrito na equação (4) não seja satisfeito, ocorre o reset, e a função de escolha continua até que uma nova categoria J satisfaça (4). Após o processo de ressonância nos módulos ARTa e ARTb deve-se verificar o casamento das categorias em ambos os módulos, esta etapa é realizada pelo módulo MapField.

O módulo MapField verifica o casamento das informações entre os módulos ART. Este processo é realizado pelo teste denominado Match Tracking descrito em (5), em que y_b representa o vetor de atividade do módulo ARTb [11].

$$\frac{|y^b \wedge w_{jk}^{ab}|}{|y^b|} \geq \rho_{ab} \quad (5)$$

Caso o teste Match Tracking (5) não seja satisfeito, uma nova categoria do módulo ARTa deve ser escolhida e introduzida no processo de treinamento até que este critério seja satisfeito.

Após realizar os processos de ressonância para os módulos ARTa e ARTb e o teste de Match Tracking para o módulo MapField é realizada a adaptação dos pesos sinápticos w_j^a , w_k^b e w_{jk}^{ab} conforme (6), [11].

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

$$w_k^{novo} = \beta(I \wedge w_k^b) + (1 - \beta) w_k^b \quad (6)$$

$$w_{jk}^{novo} = 1$$

RNA ARTMAP FUZZY COM TREINAMENTO CONTINUADO

Apesar de a rede neural ARTMAP Fuzzy ser caracterizada com inúmeras vantagens[11], ainda limita-se na fase de aprendizagem. A limitação está em problemas em que os dados são alterados constantemente, pois as informações utilizadas na aprendizagem não mais correspondem ao problema atual, sendo necessário um novo processo de treinamento. Nessas condições é incorporado na rede neural ARTMAP Fuzzy o treinamento continuado, que possibilita a aprendizagem de modo on-line. Trata-se do desenvolvimento de um sistema que contempla o treinamento de forma contínua, e.g., havendo a disponibilidade de novos padrões, assim o treinamento não necessita ser reinicializado [16]. Na rede ARTMAP Fuzzy, bem como em outras redes da família ART, a incorporação do módulo de treinamento continuado é possível justamente por suas características de estabilidade e plasticidade, constituindo um sistema neural aperfeiçoado quando comparado à rede ARTMAP com treinamento incremental [17, 18]. O treinamento continuado permite a inclusão de novos padrões à memória da rede de forma permanente. Deste modo, o treinamento e a análise (diagnóstico) se tornam procedimentos mais rápidos e eficientes. Para que este mecanismo funcione de

forma correta, foram adicionados alguns elementos no algoritmo de treinamento da rede neural ARTMAP *Fuzzy* [16].

Na primeira modificação é feita a inclusão de pesos temporários além dos definitivos nos módulos *ARTa* e *MapField*. Isto se faz necessário para evitar a presença de categorias semelhantes na memória da rede. Sendo assim, no processo de escolha das categorias do módulo *ARTa*, existem categorias temporárias e categorias definitivas [17]. Logo, definem-se duas funções de escolha, uma para as categorias temporárias e outra para as categorias definitivas, através das equações 7 e 8, respectivamente:

$$T_j^t(I) = \frac{|I \wedge w_j^t|}{\alpha + |w_j^t|} \quad (7)$$

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

A categoria escolhida é a com o maior valor de escolha entre as categorias temporárias e definitivas por (9).

$$T_j = \max\{T_j^t, T_j^d\} \quad (9)$$

A segunda modificação é a inclusão de dois novos parâmetros: *NMIN* e η . O parâmetro *NMIN* ($NMIN \in \mathbb{N}$, com $NMIN > 1$), chamado parâmetro de permanência, refere-se ao número de vezes que uma categoria temporária deve atualizar seus pesos, caso atinja o valor *NMIN* (equação 10) essa categoria torne-se definitiva [17].

$$ContT = NMIN \quad (10)$$

sendo:

NMIN: Parâmetro de Permanência;

ContT: Contador de atualização de pesos de uma categoria temporária.

O parâmetro η ($\eta > 0$), chamado de índice de novidade, é responsável em verificar se há ou não a necessidade de atualização dos pesos da categoria definitiva vencedora, i.e., informações redundantes apresentadas à rede neural são descartadas [17]. Desta forma, evita-se que classes de padrões semelhantes sejam alocadas em categorias distintas, evitando, assim, o desnecessário sobre-carregamento da memória da rede. Isto é feito através da equação (11).

$$T_j > \eta \quad (11)$$

Caso a equação (11) seja satisfeita não haverá a necessidade da atualização de pesos. A fase aprendizagem de uma RNA com treinamento continuado incorporado pode ser realizado de dois modos: on-line/off-line e on-line.

A. Modelo de Aprendizagem off-line

O modo de aprendizagem off-line é caracterizado pela divisão dos processos de aprendizagem e diagnóstico, sendo necessário que a RNA incorpore as informações na fase de aprendizagem de maneira estática, e só após o término se inicia a fase de diagnóstico. Este modelo apresenta limitações quando aplicado a problemas que possuem constante mutação dos dados, pois ao longo do tempo as informações dadas a RNA na fase de aprendizagem não mais condizem com a atual condição do problema. Já o modo de aprendizagem on-line permite a RNA estar em constante fase de aprendizagem e diagnóstico em paralelo. Essa característica torna a RNA capaz de permanecer atualizada mesmo com a constante mutação dos dados de determinados problemas. A inicialização dos pesos caracteriza o modo de aprendizagem on-line/off-line. Inicialmente a RNA é submetida à fase de aprendizagem no modo convencional off-line a fim de se obter os pesos dos módulos *ARTa*, *ARTb* e *MapField*. O próximo passo é ativar o modo de aprendizagem on-line atribuindo os pesos adquiridos anteriormente aos pesos definitivos da RNA, como mostra as equações (12), (13) e (14).

$$w^{ad} = w^a \quad (12)$$

$$w^{bd} = w^b \quad (13)$$

$$w_{jk}^{abd} = w_{jk}^{ab} \quad (14)$$

Na inicialização da rede a categoria temporária é iniciada com apenas um neurônio ativo, i.e., o primeiro padrão apresentado à rede é dado pela equação (15), e os pesos do módulo *MapField* temporário, são fixados em 1, conforme a equação (16).

$$w_1^{at} = a_1 \quad (15)$$

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

B. Modelo de Aprendizagem on-line

No modo de aprendizagem on-line a RNA permanece em constante fase de aprendizagem e diagnóstico. Inicialmente o primeiro padrão de entrada da RNA é atribuído aos pesos definitivos dos módulos *ARTa* e *ARTb*, de acordo com (17) e (18).

$$w^{ad} = a_1 \quad (17)$$

$$w^{bd} = b_1 \quad (18)$$

Os pesos definitivos pelo módulo *MapField* são com valor 1, conforme a equação (19).

$$w_{jk}^{abd} = 1 \quad (19)$$

Já os pesos temporários dos módulos ART_a inicializados com o segundo padrão de entrada, e os pesos temporários do módulo MapField com o valor 1, de acordo com as equações (20) e (21) respectivamente.

$$w_1^{at} = a_2 \quad (20)$$

$$w_{jk}^{abt} = 1 \quad (21)$$

III. RESULTADOS

A. Forma de análise dos resultados

Para analisar o desempenho do modelo proposto, a avaliação dos resultados é feita através da medida da taxa de erro, dada pela equação (22).

$$Ter = \frac{E}{N} \quad (22)$$

sendo: E o total de erros e N o total de amostras submetidas à fase de classificação.

A base de dados utilizada para realização dos testes foi a Spam Assassin [5], formado por 6.047 e-mails divididos em três subconjuntos: Spam – Contém 1.897 Spams; EasyHam – 3.900 e-mails legítimos facilmente diferenciáveis dos spams por não conterem assinaturas de spams como por exemplo tags HTML; Hard Ham – 250 e-mails legítimos, porém mais difíceis de diferenciar dos spams por conterem assinaturas de spams. Portanto, o total de e-mails possui aproximadamente 31% de spams.

Alguns parâmetros da RNA ARTMAP *Fuzzy* se mantiveram os mesmos em todos os testes, como apresenta a Tabela I:

TABELA I. PARÂMETROS RNA ARTMAP FUZZY

Parâmetro	Valor
ρ_{ab}	1
ρ_b	1
β	1
α	0.01

Os valores dos parâmetros de vigilância ρ_{ab} e ρ_b foram mantidos com o valor 1, já que o problema possui apenas duas opções de classes, Spam ou Ham, logo a vigilância deve exigir alto grau de semelhança. O parâmetro de escolha α apresentou melhores resultados para o problema com valores menores, como o escolhido 0.01, assim como a taxa de treinamento β com o valor 1. Neste trabalho a seleção dos valores foi através da busca exaustiva de acordo com os melhores resultados.

O parâmetro de vigilância ρ_a , a porcentagem de e-mails destinados ao treinamento, e o tamanho do vetor de entradas M do módulo ART_a da RNA ARTMAP *Fuzzy* são cruciais para um bom desempenho do modelo proposto. O parâmetro ρ_a determina o grau de semelhança entre as classes existentes e os

novos padrões apresentados a RNA; a porcentagem de e-mails utilizados no treinamento determina a quantidade de informações adquiridas pela RNA durante o processo de aprendizagem, essencial na fase de classificação; e o tamanho do vetor de entrada M representa o número de características extraídas na fase de pré-processamento que compõem o vetor característico.

A escolha de tamanhos menores do vetor M influencia na maior ocorrência dos chamados ruídos nos padrões destinados ao treinamento da RNA. Ruídos podem ser definidos como padrões iguais, mas de classes diferentes, ou seja, um padrão gerado a partir de um Ham é exatamente igual ao padrão gerado a partir de um Spam. Na fase de aprendizagem os padrões identificados como ruídos foram excluídos, pois é incoerente apresentar a RNA dois padrões iguais indicando saídas distintas, principalmente por se tratar de uma RNA com aprendizagem supervisionada. A escolha de valores maiores para M indica um maior número de características para formar um padrão, o que possibilita maior diversificação dos padrões e diminuição na ocorrência de ruídos. Porém essas características podem não possuir um bom valor de DF_{s-h} e contribuir para o aumento da taxa de erros (Ter).

B. Resultados

A seguir são apresentados os resultados para $M = 20$ e treinamento de 10% da base de dados. A taxa de “ruído %” é de 8.020, o qual representa a porcentagem de padrões excluídos em relação a base de dados. Na tabela II estão descritos os resultados, sendo realizada uma variação no parâmetro ρ_a , sendo este o parâmetro que determina o grau de semelhança entre um padrão de entrada e um padrão já conhecido pela rede neural.

TABELA II. RESULTADOS

ρ_a	Taxa de Erro
0.81	4.01
0.86	3.77
0.91	2.19
0.96	0.00
0.99	0.00

CONCLUSÃO

O uso de RNAs com arquitetura baseada na teoria da ressonância adaptativa para problemas de classificação de padrões é destaque na literatura, com resultados bastante satisfatórios. Este trabalho teve como objetivo o desenvolvimento de uma metodologia para detecção de e-mails indesejados, sendo utilizado o modelo de pré-processamento proposto em [8] e a RNA ARTMAP *Fuzzy* com treinamento continuado no processo de classificação.

No modelo proposto, o pré-processamento foi responsável por extrair as características mais relevantes dos e-mails pertencentes às classes dos Spams e dos e-mails legítimos, a fim de se gerar o vetor característico. Os padrões binários referentes a cada e-mail foram formados a partir do vetor

característico e a RNA ARTMAP *Fuzzy* com treinamento continuado responsável por classificar os padrões de entrada entre Spam e e-mail legítimo.

Foram realizados testes variando o parâmetro ρ_a da RNA, no qual a dimensão utilizada do vetor de entrada M do módulo ART_a é igual a 20, e a porcentagem de treinamento em relação à base de dados é de 10%.

É importante enfatizar que no treinamento da RNA ARTMAP *Fuzzy* com treinamento continuado foram utilizados somente 10% dos dados disponíveis, o que através dos resultados apresentados, nos dá segurança de que a RNA tenha uma forte capacidade de generalização de dados e adaptabilidade aos novos padrões apresentados a ela, característica essa presente no problema de detecção de spams.

REFERÊNCIAS

- [1] M. Vergelis, T. Shcherbakova, N. Demidova, "Kaspersky Security Bulletin. Spam in 2014", Acesso em: 30 de Agosto de 2015, disponível em: <https://securelist.com/analysis/kaspersky-security-bulletin/69225/kaspersky-security-bulletin-spam-in-2014/>, 2015.
- [2] Upasana e S. Chakravarty, "A Survey of Text Classification Techniques for E-mail Filtering," Second International Conference on Machine Learning and Computing, IEEE Computer Society, 2010.
- [3] T.A. Almeida, "SPAM: do Surgimento à Extinção", Tese (Doutorado) Faculdade de Engenharia, Universidade Estadual de Campinas, 2010, pp. 114.
- [4] Q. Ma, Z. Qin, F. Zhang, e Q. Liu, "Text Spam Neural Network Classification Algorithm," IEEE, pp. 466-469, 2010.
- [5] SpamAssassin, Acesso em: Julho de 2012, disponível em: <http://spamassassin.apache.org/>.
- [6] K. Manjusha e R. Kumar, "Spam Mail Classification Using Combined Approach of Bayesian and Neural", IEEE Computer Society, 2010, pp.145-149.
- [7] Weka, disponível em: <http://www.cs.waikato.ac.nz/ml/weka>.
- [8] O.A. Carpinteiro, I. Lima e J. M. Assis, "A Neural Model in Anti-spam Systems," Springer-Verlag Berlin Heidelberg, 2006, pp. 847-855.
- [9] A. M. Silva, "Utilização de Redes Neurais Artificiais para Classificação de Spams". *Dissertação (Mestrado)* - Centro Federal de Educação Tecnológica de Minas Gerais, 2009, pp. 126.
- [10] S. Haykin, "Redes Neurais Princípios e Práticas", 2ª ed., Bookman Companhia Editora, 2008, pp. 908.
- [11] G. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds e D. Rosen, "Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps," IEEE Transactions on Neural Networks, vol. 3(5), 1992, pp. 698 – 713.
- [12] J.A. Freeman e D. M. Skapura, "Neural Networks: Algorithms, applications, and programming techniques," Addison-Wesley, 1991.
- [13] D.G. Amorim, "Redes Art com Categorias Internas de Geometria Irregular," Tese (Doutorado) – Universidade de Santiago de Compostela – Departamento de Eletrônica e Computação, Santiago de Compostela, 2006, pp. 246.
- [14] E.A. Capuano, "O poder cognitivo das redes neurais artificiais modelo ART1 na recuperação de informação," Ci. Inf, Brasília, 2009, pp. 9-30.
- [15] M. C. G. Silveira, A.D. P. Lotufo e C. R. Minussi, "Transient Stability Analysis of Electrical Power Systems Using a Neural Network Based on Fuzzy ARTMAP," IEEE Bologna Tech Conference, Bologna, Italy, 2003.
- [16] A. C. Barros, M. S Tonelli-Neto; J. G. M. S. DECANINI; C. R. Minussi. "Diagnóstico de Distúrbios de Tensão em Sistemas de Distribuição de Energia Elétrica Usando uma Rede Neural ARTMAP Euclidiana Modificada com Treinamento Continuado". CBA, Campina Grande, 2012, pp. 1-8.
- [17] S. C., Marchiori, C. R. Minussi, A. D. P. Lotufo. "Rede Neural ARTMAP Nebulosa Para Análise de Estabilidade Transitória de Sistemas de Energia Elétrica". Learning and Nonlinear Models, v.1, 2002, pp. 59-76.
- [18] A. L. Moreno, C. R. Minussi, "Análise da Estabilidade Transitória de Sistemas de Energia Elétrica usando uma Rede Neural ART Euclidiana & ARTMAP com Treinamento Continuado". Intertech, Ilhéus, 2010, v. 1., pp. 622-627.