

Desenvolvimento de Metodologia Inteligente para Classificação de Tipos de Isoladores em Redes de Distribuição

Ricardo Menezes Prates, Eduardo F. de Simas Filho, Jês de Jesus Fiais Cerqueira e Rodrigo Pereira Ramos

Resumo—O presente trabalho apresenta uma metodologia para classificação automatizada de imagens de três tipos de isoladores existentes em Redes de Distribuição de média tensão, conhecidos coloquialmente como Isolador de Pino, Isolador Polimérico e Isolador de Saia Baiana. O processo de classificação ocorre através do emprego de técnicas de processamento digital de imagens (PDI) e de inteligência computacional. Esta metodologia pode ser caracterizada pelas etapas de segmentação de imagens, extração de atributos dimensionais e cálculo de parâmetros característicos, além do desenvolvimento e implementação de uma Rede Neural Artificial (RNA). Em suma, as informações obtidas na etapa de PDI foram posteriormente tratadas para o treinamento da RNA escolhida - uma Rede Perceptron Multicamadas. Ao final do artigo, foi realizado um estudo comparativo para identificar um número otimizado de neurônios que devem pertencer à camada oculta da Rede Neural, como também uma avaliação dos parâmetros de desempenho da RNA para o processo de classificação. Como resultado, o sistema mostrou-se satisfatório, obtendo precisão geral de 99% de acerto na identificação do tipo de componente presente na imagem.

Palavras-Chave—Isoladores de Distribuição, Processamento Digital de Imagem, Redes Neurais Artificiais.

Abstract—The present study demonstrates an automated methodology for image classification of three types of insulators in Medium Voltage Distribution Networks. This components are known colloquially as Pin, Polymeric and Saia Baiana Isolators. The classification process occurs through the use of digital image processing techniques (DPI) and computational intelligence. This methodology can be characterized by the following steps: image segmentation, dimensional attributes extraction and characteristic parameters calculation. In addition, it was developed an Artificial Neural Network (ANN) to treat this information. Thus, the data obtained in the DPI stage was used for the training of the chosen ANN - a Multi-layered Perceptron Network. A comparative study was carried out to identify the optimized number of neurons for the Neural Network hidden layer, as well as to evaluate the ANN performance parameters for the classification process. At the end of the evaluation, the system obtained satisfactory results, achieving 99 % of efficiency in identifying the type of component present in the image.

Keywords—Distribution Insulators, Digital Image Processing, Artificial Neural Networks.

Ricardo Menezes Prates, Departamento de Engenharia Elétrica da Universidade Federal do Vale do São Francisco - UNIVASF / Pós-Graduação em Engenharia Elétrica da Universidade Federal da Bahia - UFBA, Brasil. E-mail: ricardo.prates@univasf.edu.br.

Eduardo F. de Simas Filho e Jês de Jesus Fiais Cerqueira, Departamento de Engenharia Elétrica da Universidade Federal da Bahia - UFBA. E-mails: eduardo.simas@ufba.br, jes@ufba.br.

Rodrigo Pereira Ramos, Departamento de Engenharia Elétrica da Universidade Federal do Vale do São Francisco - UNIVASF, Brasil. E-mail: rodrigo.ramos@univasf.edu.br.

I. INTRODUÇÃO

A conformidade no fornecimento de energia elétrica, prestado pelas concessionárias de energia, está intimamente relacionada com a qualidade dos serviços de manutenção preventiva e corretiva, praticados por estas empresas, nas redes de distribuição (RDs) de baixa e média tensão. Como pré-requisito para realização das referidas atividades, a primeira etapa a ser realizada é a inspeção. Ela consiste na procura e identificação de defeitos presentes nos componentes das RDs, como, por exemplo: elementos defeituosos (quebrados, trincados, poluídos), mal posicionados, pontos quentes, fugas de corrente, falhas incipientes (descargas parciais internas e superficiais) dentre outros. A partir da determinação do tipo de componente e respectivo defeito, torna-se possível a atuação de forma preventiva nas redes elétricas.

Atualmente, as atividades de inspeção em campo nas redes de distribuição são, em parte, realizadas por profissionais treinados pela concessionária na modalidade de inspeção visual. Essas atividades são baseadas em métodos empíricos de avaliação, onde o profissional define o tipo de componente e a classe de defeito de forma visual e intuitiva. Estas ações estão sujeitas a subjetividades e interpretações heurísticas, que podem levar a identificação/diagnósticos imprecisos ou incorretos da inspeção.

Dessa forma, verifica-se que ainda é latente a necessidade de melhoria das técnicas de identificação de componentes e análise de defeitos nas redes de distribuição de energia elétrica. Para isso, uma abordagem se mostra promissora: desenvolvimento e implementação de técnicas automatizadas/inteligentes de aquisição dados e análise das informações.

As técnicas de visão computacional para inspeção automática podem ser exploradas para redução de subjetividades inerentes aos atuais métodos de inspeção de RDs. Essas técnicas vêm sendo estudadas há mais de 30 anos, mas a sua popularização e utilização em larga escala iniciaram-se recentemente, com a redução nos custos para aquisição de sistemas digitais de captura de imagens, como filmadoras e webcams [1]. Diversos métodos têm sido testados com sucesso para solução de problemas de detecção de defeitos em tecido, papel e cerâmica, dentre outros [2].

O uso de processamento digital de imagem e inteligência computacional para identificação de componentes e/ou detecção de falhas é uma abordagem característica de reconhecimento de padrões e algumas aplicações podem ser encontradas na literatura [3].

O emprego de técnicas de visão computacional e sistemas inteligentes para inspeção de sistemas de potência é um tema atual e, até onde sabemos, pouco explorado. Uma revisão recente da literatura a respeito deste tema pode ser encontrada na referência [4].

Nesta pesquisa, objetiva-se dar início ao desenvolvimento de uma metodologia para classificação de imagens de isoladores existentes em RDs de média tensão, através do emprego de técnicas de PDI e do uso de inteligência computacional. Com este propósito, foi realizada uma sequência de atividades, a saber: segmentação de áreas de interesse nas imagens, cálculo de atributos dimensionais e geração de vetores característicos que possuem a “assinatura” dos componentes avaliados. Os referidos vetores foram posteriormente implementados para o treinamento de uma RNA que servirá para a classificação do tipo de isolador. Isto posto, esta pesquisa é uma etapa inicial que visa abrir caminho para o desenvolvimento de técnicas automatizadas para inspeção de Redes de Distribuição através da implementação de visão computacional.

II. DESENVOLVIMENTO DA METODOLOGIA PARA CLASSIFICAÇÃO DOS ISOLADORES

As principais etapas de um sistema de reconhecimento de padrões são a aquisição de dados, o pré-processamento, a segmentação, a extração de atributos e a classificação dos padrões [5], [6]. Serão descritas as diferentes abordagens experimentais empregadas nas etapas do processo de classificação. A Figura 1 apresenta, de forma esquemática, o fluxograma de procedimentos realizados para o desenvolvimento deste estudo.

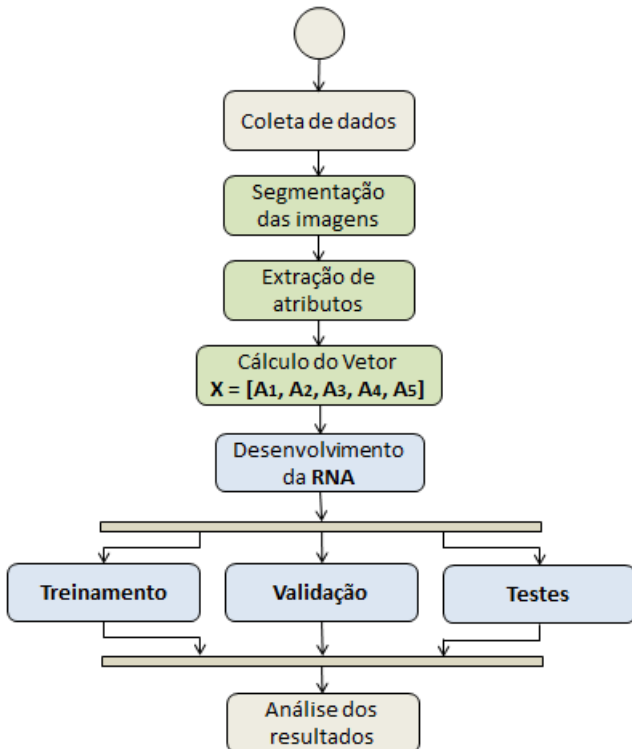


Fig. 1. Diagrama da metodologia desenvolvida para classificação dos isoladores.

Na etapa de coleta de dados, foram obtidos três tipos de isoladores de distribuição da empresa COELBA (Companhia de Eletricidade do Estado da Bahia), conhecidos como Isolador de Pino (IPN), Isolador Polimérico (IPL) e Isolador de Saia Baiana (ISB), usados em RDs de 13,8kV (ver Figura 2).

Num segundo momento, foram coletados um conjunto de fotos dos referidos componentes em diversos ângulos e posições diferentes - 300 fotos no total (100 de cada componente). O modelo de câmera empregado nesta pesquisa foi o Lenovo K6 PLUS, com dimensões das imagens de 4.632 x 2.608 pixels e resolução de 72 dpi. Esta etapa foi realizada em um laboratório de pesquisa da UFBA, com iluminação e cor da superfície de trabalho controladas.



Fig. 2. Fotografias do IPN (a esquerda), do ISB (centro) e do IPL (a direita).

A partir do conjunto de imagens coloridas obtidas, elas foram transformadas em imagens de níveis de cinza e foi realizado um processo de filtragem das mesmas, para minimização do ruído. Um algoritmo adaptativo de filtro de Wiener foi aplicado. Este algoritmo implementa uma abordagem pixel-a-pixel baseada em estatísticas estimadas em vizinhanças de pixels. O filtro local é, na verdade, um filtro passa-baixas variante no espaço, cuja transformada de Fourier é dada por [7]:

$$H(u, v) = \frac{S_f(u, v)}{S_f(u, v) + S_\eta(u, v)} \quad (1)$$

onde $S_f(u, v)$ e $S_\eta(u, v)$ são a densidade espectral de potência do ruído e da imagem degradada, respectivamente. Dentro da região local (vizinhança), a imagem degradada é assumida ser estacionária, com média m_f e variância σ_f^2 . O algoritmo adaptativo então estima a média e variância locais, definindo uma vizinhança Δ de dimensões $N \times M$ ao redor de cada pixel na imagem degradada, chamada de $F(n_1, n_2)$, dadas por:

$$m_f = \frac{1}{NM} \sum_{n_1, n_2 \in \Delta} F(n_1, n_2) \quad (2)$$

$$\sigma_f^2 = \frac{1}{NM} \sum_{n_1, n_2 \in \Delta} F^2(n_1, n_2) - m_f \quad (3)$$

A imagem restaurada \hat{F} é obtida das regiões restauradas localmente e dada por:

$$\hat{F}(n_1, n_2) = m_f + \frac{\sigma_f^2}{\sigma_f^2 + \sigma_\eta^2} (F(n_1, n_2) - m_f) \quad (4)$$

A variância do ruído é estimada a partir da média de todas as variâncias σ_f^2 . Usamos neste trabalho uma vizinhança de tamanho 5×5 .

Após a filtragem de Wiener, aplicou-se um algoritmo de segmentação baseado no processo de limiarização múltipla de Otsu [8]. Neste método, foram obtidos dois limiares para segmentação das imagens, uma vez que elas apresentam contraste relativamente alto, mas com cores muito próximas. A partir dos dois limiares, usou-se o de menor valor, tendo em vista que isoladores apresentam níveis de cinza menores que os *backgrounds* considerados. No caso dos isoladores IPN e IPL, os componentes foram completamente segmentados do fundo da imagem. Para o caso do ISB, somente a parte superior do componente foi segmentada - estudos empíricos realizados previamente indicaram que essa região já fornece dados suficientes para classificação (ver Figura 3).




Fig. 3. Imagens segmentadas do IPN (a esquerda), do ISB (centro) e do IPL (a direita).

Após a etapa de segmentação, foram extraídos alguns atributos geométricos dos objetos, listados a seguir: Área (A), Perímetro (P), Excentricidade (E), Diâmetro Equivalente (D_e), Raio Menor (R_{menor}), Raio Maior (R_{maior}) e Extensão (E_x). Logo em seguida, foram calculados 5 parâmetros para compor um vetor de atributos, $\mathbf{X} = [A_1, A_2, A_3, A_4, A_5]$. As equações adotadas para o cálculo deste vetor podem ser visualizadas a seguir. É importante salientar que os parâmetros geométricos utilizados são suficientes para a diferenciação dos isoladores, uma vez que estes apresentam diferenças geométricas significativas.

$$A_1 = (P)^2 / (100.A) \quad (5)$$

$$A_2 = E \quad (6)$$

$$A_3 = D_e / P \quad (7)$$

$$A_4 = R_{menor} / R_{maior} \quad (8)$$

$$A_5 = E_x \quad (9)$$

Por fim, a etapa de classificação dos isoladores pode ser realizada através do treinamento de uma Rede Neural Artificial, quando alimentada com parâmetros devidamente tratados [9], [10], [11].

De posse dos dados dos vetores de parâmetros, foi utilizado o *software* MATLAB para o treinamento de uma rede Perceptron Multicamadas, com uma camada oculta e três saídas (3 neurônios), que representam as três classes (tipos)

de isoladores avaliados:

- Classe 1 - Isolador de Pino,
- Classe 2 - Isolador de Saia Baiana,
- Classe 3 - Isolador Polimérico.

O número de neurônios da camada oculta (escondida) pode ser manipulado pelo usuário, possibilitando a verificação e escolha de um valor otimizado de neurônios para aplicação. A Figura 4 ilustra a topologia da RNA implementada.

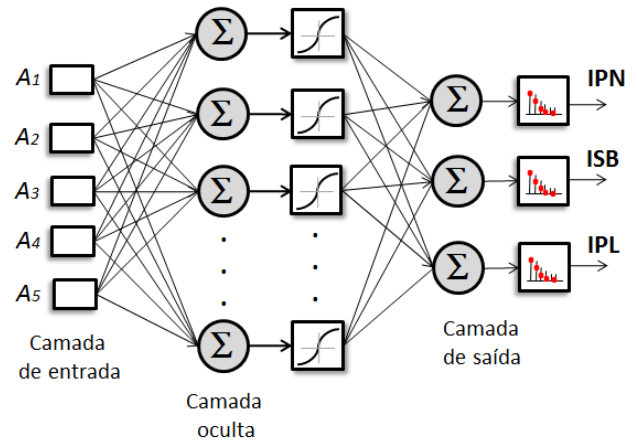


Fig. 4. Rede Neural Implementada

As funções de ativação aplicadas para camada oculta e para camada de saída foram, respectivamente, a função Tansig e a função Softmax. Elas podem ser entendidas da seguinte forma:

- 1) Função de ativação Tansig: possui forma sigmoial, é uma das funções mais utilizadas na construção de uma RNA. Ela pode assumir valores na faixa de $[-1,1]$ e é definida pela equação [12]:

$$F(Net_k) = \frac{2}{1 + e^{-a \cdot Net_k}} - 1 \quad (10)$$

O parâmetro a determina a inclinação da função.

- 2) Função de Ativação Softmax: é utilizada em problemas de classificação do tipo *um-vs-todos* [13]. Essa função força a saída de uma Rede Neural a representar a probabilidade dos dados serem de uma das classes definidas. Sem ela as saídas dos neurônios são simplesmente valores numéricos, onde o maior indica a classe vencedora. A equação pode ser visualizada abaixo:

$$\phi_i = \frac{e^{z_i}}{\sum_{j \in group} e^{z_j}} \quad (11)$$

Nessa equação, i representa o índice do neurônio de saída e j representa os índices de todos os neurônios de um nível. A variável z designa o vetor de neurônios de saída.

III. SIMULAÇÃO E ANÁLISE DOS RESULTADOS

Para a etapa de simulação da Rede Neural, foi criada uma base de dados com as características descritas na Tabela I. As cinco primeiras colunas são usadas para compor o vetor de entrada **X** e as três últimas são empregadas para criação do vetor de alvo **T**. Os percentuais da base de dados destinados ao Treinamento, Validação e Teste da RNA, foram arbitrados da seguinte forma:

- Treinamento - 70% (210 amostras);
- Validação - 15% (45 amostras);
- Teste - 15% (45 amostras).

De posse dos vetores supracitados, foram avaliadas 4 RNAs contendo números diferentes de neurônios na camada oculta (5, 10, 15 e 20). A finalidade desta etapa foi identificar qual é a configuração de Rede Neural que apresenta o melhor desempenho no processo de classificação.

TABELA I

ESTRUTURA DE DADOS EMPREGADA NO TREINAMENTO DA RNA.

A1	A2	A3	A4	A5	IPN	ISB	IPL
0,203	0,708	0,250	0,705	0,819	1	0	0
0,133	0,533	0,308	0,845	0,754	1	0	0
0,244	0,827	0,228	0,561	0,727	0	1	0
0,146	0,497	0,295	0,812	0,791	0	1	0
0,257	0,541	0,222	0,840	0,684	0	0	1
0,166	0,513	0,276	0,858	0,741	0	0	1

Para facilitar a análise dos resultados, foram geradas Matrizes de Confusão para todas as RNAs trabalhadas (ver Tabelas de II a V). A Matriz de Confusão (MC) pode ser entendida como um tipo de tabela que permite a visualização do desempenho de um algoritmo de aprendizado. As colunas da matriz representam as instâncias de uma classe prevista, enquanto as linhas representam os casos de uma classe real. As principais equações usadas para se trabalhar com uma MC foram apresentadas por Fawcett [14] e são listadas a seguir:

- Taxa de Verdadeiro Positivo (TVP):

$$TVP \approx \frac{\text{Positivos Corretamente Classificados}}{\text{Total de Positivos}} \quad (12)$$

- Taxa de Falso Positivo (TFP):

$$TFP \approx \frac{\text{Negativos Incorretamente Classificados}}{\text{Total de Negativos}} \quad (13)$$

- Sensibilidade (S):

$$S = TVP \quad (14)$$

- Especificidade (Es):

$$Es = 1 - TFP \quad (15)$$

- Acurácia (Ac):

$$Ac = \frac{\text{Total de Acertos}}{\text{Total de Dados no Conjunto}} \quad (16)$$

A partir das das MCs apresentadas, é possível verificar que a Rede Neural contendo 15 neurônios na camada escondida foi a que apresentou os melhores resultados de saída. O valor da acurácia da classificação foi de 99%.

TABELA II

MC DA RNA COM 5 NEURÔNIOS NA CAMADA ESCONDIDA.

		Classe Prevista			Total
		IPN	ISB	IPL	
Classe Real	IPN	84	16	0	84,0%
	ISB	4	86	10	86,0%
	IPL	0	7	93	93,0%
Total		95,5%	78,9%	90,3%	87,7%

TABELA III

MC DA RNA COM 10 NEURÔNIOS NA CAMADA ESCONDIDA.

		Classe Prevista			Total
		IPN	ISB	IPL	
Classe Real	IPN	80	20	0	80,0%
	ISB	14	74	12	74,0%
	IPL	0	9	91	91,0%
Total		85,1%	71,8%	88,3%	81,7%

TABELA IV

MC DA RNA COM 15 NEURÔNIOS NA CAMADA ESCONDIDA.

		Classe Prevista			Total
		IPN	ISB	IPL	
Classe Real	IPN	100	0	0	100%
	ISB	0	98	2	98,0%
	IPL	0	1	99	99,0%
Total		100%	99,0%	98,0%	99,0%

TABELA V

MC DA RNA COM 20 NEURÔNIOS NA CAMADA ESCONDIDA.

		Classe Prevista			Total
		IPN	ISB	IPL	
Classe Real	IPN	100	0	0	100%
	ISB	0	95	5	95,0%
	IPL	0	4	96	96,0%
Total		100%	96,0%	95,0%	97,0%

A Figura 5 demonstra a variação para os valores da curva ROC (Curva Característica de Operação do Receptor) da RNA com 15 neurônios na camada oculta, para as classes 1, 2 e 3.

A curva ROC é um gráfico bidimensional em que *TVP* é plotada no eixo Y e *TFP* é plotada no eixo X. O gráfico de ROC descreve a relação relativa entre os benefícios (verdadeiros positivos) e os custos (falsos positivos). Os desempenhos são melhores quando as áreas abaixo da curva ROC estão próximas do valor 1 ou a referida curva é achatada na parte de cima do gráfico, correspondendo a 100% de sensibilidade e 100% de especificidade.

De acordo com a explicação acima, a RNA demonstrou resultados satisfatórios, contendo curvas ROC achatadas e próximas do valor 1.

A curva de entropia cruzada, presente na Figura 6, representa o erro entre os resultados obtidos pelo teste de validação

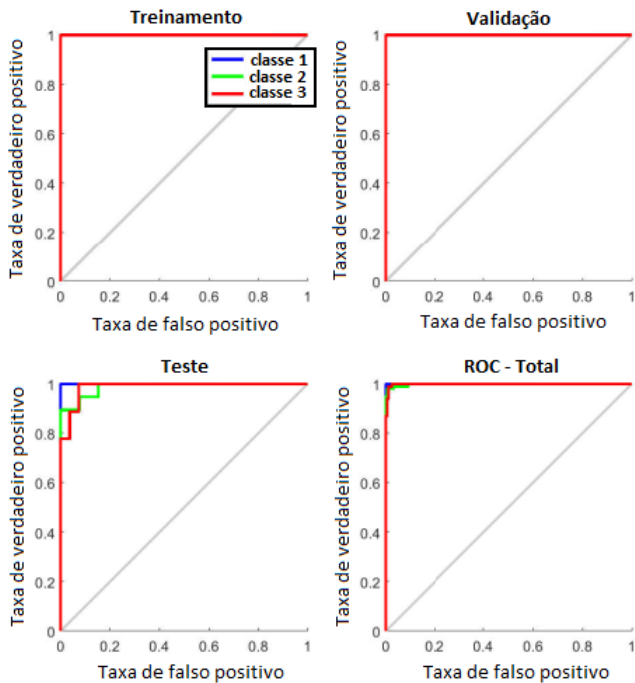


Fig. 5. Curva ROC para RNA com 15 neurônios na camada escondida.

e pelos resultados esperados. O objetivo é ajustar iterativamente os pesos da RNA para que se obtenha uma função de transferência otimizada. Pode-se observar na figura que o mínimo local ocorre na iteração 83, com erro de entropia cruzada de 0,0019562.




Fig. 6. Erro de entropia cruzada para RNA com 15 neurônios na camada escondida.

IV. CONCLUSÕES

Esta pesquisa apresentou uma metodologia destinada à classificação automatizada de isoladores IPN, ISB e IPL através do emprego de uma Rede Neural Artificial do tipo

Perceptron Multicamada, contendo 15 neurônios na camada escondida. O referido número de neurônios demonstrou o melhor desempenho para as RNAs usadas, obtendo precisão geral de 99% de acerto na identificação.

Outro ponto de interesse neste trabalho, relacionado à etapa de PDI, foi a extração de atributos dimensionais das imagens e o cálculo dos vetores de parâmetros. A partir das informações de desempenho obtidas nas simulações das RNAs (só ocorreram 3 erros em 300), é possível constatar que os valores dos vetores de \mathbf{X} conseguiram representar diferenças dimensionais significativas entre os componentes.

Em futuras pesquisas, objetiva-se a ampliação dos tipos de isoladores avaliados de forma simultânea, inserindo, por exemplo, os isoladores do tipo Pilar e do tipo suspensão. Ainda, pretende-se buscar algoritmos mais robustos de segmentação dos componentes, especialmente para quando estes se encontram em campo (localizados em RDs). Outro ponto que deve ser trabalhado nesta pesquisa é a avaliação da performance do atual classificador para fotografias de isoladores que possuem defeitos visíveis.

AGRADECIMENTOS

Os autores gostariam de agradecer à concessionária COELBA pela disponibilização dos componentes avaliados neste artigo.

REFERÊNCIAS

- [1] X. Xie, "A review of recent advances in surface defect detection using texture analysis techniques," *Electronic Letters on Computer Vision and Image Analysis*, v. 7, n. 3, pp.- 1-22, 2008.
- [2] Z. Hocenski, Z. Keser "Failure detection and isolation in ceramic tile edges based on contour descriptor analysis. In: Mediterranean Conference on Control and Automation, 2007.
- [3] Z. Zhao, G. Xu, Y. Qi, N. Liu, T. Zhan, "Multi-patch Deep Features for Power Line Insulator Status Classification from Aerial Images," In: International Joint Conference on Neural Networks (IJCNN), pp.- 3187-3194, 2016.
- [4] P. S. Prasad, B. P. Rao "Review on Machine Vision based Insulator Inspection Systems for Power Distribution System" *Journal of Engineering Science and Technology Review*, v. 9, n. 5, pp.- 135-141, 2016.
- [5] C. Solomon, T. Breckon *Fundamentals of Digital Image Processing: a Practical Approach with Examples in Matlab 3 ed.*, UK, Wiley Blackwell, 2011.
- [6] R. C. Gonzales, R. E. Woods *Processamento Digital de Imagens 3 ed.*, São Paulo, Pearson Prentice Hall, 2010.
- [7] J. Lim, *Two-dimensional signal and image processing*, Prentice Hall, New Jersey, EUA, 1990.
- [8] N. Otsu "A Threshold Selection Method from Gray-Level Histograms" *IEEE Transactions on Systems, Man, and Cybernetics*, v. 9, n. 1, pp.- 62-66, 1979.
- [9] S. Haykin *Redes Neurais: Princípios e Práticas 2 ed.*, Porto Alegre, Bookman, 2001.
- [10] J. Schmidhuber "Deep learning in neural networks: An overview" *Neural Networks*, n. 61, pp.- 85-117, 2015.
- [11] D. Perakovic, M. Perisa, I. Cvitic, S. Husnjak "Artificial Neuron Network Implementation in Detection and Classification of DDoS Traffic," In: 24th Telecommunications Forum (TELFOR), 2016.
- [12] A. Choudhary, R. Rishi, S. Ahlawat, V. S. Dhaka "Optimal Feed Forward MLP Architecture for Off-Line Cursive Numeral Recognition" *International Journal on Computer Science and Engineering*, v. 2, n. 1, pp.- 1-7, 2010.
- [13] Y. Zhang, E. Zhang, W. Chen "Deep neural network for half tone image classification based on sparse auto-encoder" *Engineering Applications of Artificial Intelligence*, v. 50, pp.- 245-255, 2016.
- [14] T. Fawcett "An introduction to ROC analysis" *Pattern Recognition Letters*, v. 27, pp.- 861-874, 2006.