

Reconhecimento de Padrões de Falhas Tipo Fenda em Chapa de Alumínio Utilizando Clusterização Fuzzy

Pedro Henrique S. Coutinho,
Thiago P. das Chagas, Fábio da C. Cruz
DCET - UESC
Ilhéus, Bahia, Brasil
Emails: coutinho.p92@gmail.com,
tpchagas@uesc.br, fabiocruz28@yahoo.com.br

Eduardo F. Simas Filho
PPGEE - UFBA
Salvador, Bahia, Brasil
Email: eduardo.simas@ufba.br

Maria C. S. Albuquerque,
Ivan C. Silva, Cláudia T. T. Farias
LEUS - IFBA
Salvador, Bahia, Brasil
Emails: cleaalbuquerque@ifba.edu.br,
ivansilva@ifba.edu.br, cfarias@ifba.edu.br

Resumo—Neste trabalho é aplicado um método *fuzzy* de classificação não-supervisionada para reconhecimento de padrões de descontinuidades do tipo fenda em uma chapa de alumínio. O caráter *fuzzy* provê robustez à análise de dados reais, já que os dados são classificados por graus de pertinência. Os sinais foram coletados através da inspeção não-destrutiva por ultrassom utilizando ondas de Lamb. As características dos sinais nos domínios do tempo e frequência foram selecionadas utilizando análise de componentes principais. Além disso, é proposta uma análise baseada apenas nos valores de pico dos sinais como forma de caracterizá-los. Para a classificação *fuzzy* não-supervisionada utilizou-se um método híbrido, o Fuzzy ckMeans Subtrativo. Os resultados obtidos para os três casos foram eficientes para reconhecimento dos defeitos.

Palavras-chave—Fuzzy, classificação não-supervisionada, reconhecimento de padrões, inspeção por ultrassom.

I. INTRODUÇÃO

Um tipo de ensaio não-destrutivo amplamente utilizado em diversos setores industriais é o ensaio ultrassônico. Este ensaio é utilizado para avaliação de efeitos de corrosão, inspeção de solda e detecção de defeitos laminares em chapas, por exemplo. Desta forma, é uma importante ferramenta para manutenção preditiva de equipamentos industriais [1].

A aplicação das ondas ultrassônicas do tipo de Lamb é uma técnica avançada e promissora de inspeção por ultrassom, pois possui alta sensibilidade a descontinuidades de diferentes geometrias, perda de espessura e alterações microestruturais. Estas vantagens advêm da capacidade de propagação tanto pela estrutura interna como pela região superficial da peça inspecionada, além da capacidade de propagação em longas distâncias.

Trabalhos relacionados à detecção de falhas do tipo fenda em chapas de alumínio por meio da inspeção por ultrassom utilizando ondas de Lamb foram realizados utilizando sinais em frequência e classificados utilizando classificação supervisionada através de redes neurais artificiais, por exemplo [2]. Neste trabalho é analisada a viabilidade

da aplicação de sinais no tempo para a classificação, já que dispensa a necessidade de transformadas. Para isso, é aplicado um método de classificação não-supervisionada.

Os dados são classificados nos domínio espectral e temporal. Além disso, é proposta uma abordagem baseada nos valores de pico dos sinais, já que com o aumento do número de fendas as amplitudes medidas tendem a ser menores, devido à perda de energia da onda ao longo da propagação. Essa abordagem reduz a dimensionalidade do problema de classificação à um, sendo atrativa para implementação em um sistema embarcado.

Para a classificação é utilizado um método não-supervisionado baseado em lógica *fuzzy*, que é capaz de capturar incertezas de dados reais. A abordagem não-supervisionada descarta a necessidade de conhecimento prévio do conjunto de dados. Mesmo que neste caso as classes sejam conhecidas, a sua aplicação é justificada, pois pretende-se avaliar abordagens de menor custo computacional para implementação em sistemas embarcados e a possibilidade de inclusão de novas classes ao problema.

O processo de classificação não-supervisionada pode ser caracterizado por três etapas: a extração de características, medida de similaridade entre os padrões e o agrupamento. Neste trabalho, para seleção de características foram utilizados a transformada rápida de Fourier (FFT - *Fast Fourier Transform*) [3] para análise em frequência e a análise de componentes principais (PCA - *principal component analysis*) [4] para redução da dimensionalidade do vetor de características. A medida de similaridade foi a distância euclidiana e para o agrupamento utilizou-se um método *fuzzy* híbrido, o Fuzzy ckMeans Subtrativo.

Este trabalho está dividido da seguinte forma: na seção 2 é apresentada a metodologia de coleta dos dados. Na seção 3 é realizada uma breve fundamentação teórica sobre os métodos de extração de padrões e de classificação aplicados, na seção 4 são mostrados os resultados obtidos e, finalmente, na seção 5 são apresentadas as conclusões do trabalho.

II. METODOLOGIA

O corpo de prova utilizado para a inspeção ultrassônica foi uma chapa de alumínio com dimensões 300x300x1 mm. As falhas tipo fenda possuem 1,85 mm de largura e 0,8 mm de profundidade e foram inseridas na peça como apresentado na Figura 1.




Figura 1. Corpo de prova utilizado com dimensões em milímetros. Adaptado de Silva et al. [2].

A inspeção por ultrassom foi realizada empregando ondas de Lamb na configuração transmissão-recepção por imersão. Os sinais foram gerados pelo gerador de pulso Olympus® 5077PR com transdutores Olympus Panametrics® V-303 com diâmetro 12,7 mm e frequência central nominal de 1 MHz. A digitalização foi realizada por um osciloscópio Tektronix® TDS 2024C com a taxa de amostragem de 250 Ms/s e armazenados em um micro-computador [2].

A coleta de dados foi realizada na região entre as alturas 50 e 250 mm, possuindo então duas regiões que não apresentam defeito.

III. FUNDAMENTAÇÃO TEÓRICA

A. Extração de características

Foram utilizadas três abordagens para extração de características dos sinais: numa empregou-se os coeficientes da FFT e nas outras utilizaram-se as diversas amostras e os valores de pico dos sinais no tempo. A análise em frequência é a abordagem padrão utilizada em trabalhos anteriores [2] para classificação de defeitos tipo fenda em chapa de alumínio.

A PCA foi utilizada para redução da dimensão do vetor de características e para evidenciar as diferenças entre os padrões dos sinais.

Análise de componentes principais: A PCA é uma técnica de extração de características baseada na transformação ortogonal de um conjunto de sinais em um espaço onde as características sejam não correlacionadas. As componentes do espaço gerado são denominadas componentes principais e são ordenadas em ordem decrescente de variância.

B. Classificação não-supervisionada

A classificação não-supervisionada foi realizada por um método de agrupamento *fuzzy*, o Fuzzy ckMeans Subtrativo. A abordagem *fuzzy* é capaz de capturar incertezas de dados reais e prover resultados mais robustos do que em abordagens *hard* [5], já que os dados são classificados por graus de pertinência em relação à cada classe.

Fuzzy ckMeans Subtrativo: O Fuzzy ckMeans Subtrativo (FCKMS) é um método híbrido de agrupamento que utiliza o agrupamento subtrativo para inicializar a matriz de centros do Fuzzy ckMeans (FCKM) [5].

O FCKM é uma variação do Fuzzy c-Means (FCM) [6]. No FCKM, uma matriz binária, denominada $UCrisp = [\mu_{ij}]_{i,j=1}^{c,N}$, é obtida a partir da matriz de pertinência $U = [\mu_{ij}]_{i,j=1}^{c,N}$ gerada pelo FCM com a condição apresentada na equação (1).

$$\mu_{ij} = \max \left(\left[\frac{\mu_{ij}}{\max_{l=1}^c \mu_{il}} \right], \left[\frac{\mu_{ij}}{\max_{l=1}^N \mu_{lj}} \right] \right) \quad (1)$$

onde c é o número de grupos, N o número de elementos do conjunto de dados e μ o grau de pertinência de um elemento a um determinado grupo.

O primeiro termo da condição garante que seja atribuído o valor 1 ao grupo a que um elemento possua maior grau de pertinência e o segundo garante que exista pelo menos um elemento contido em cada grupo.

Esta variação permite obter resultados similares ao FCM com menor esforço computacional. Assim como o FCM, o FCKM necessita da informação a priori da quantidade de grupos e da matriz de centros iniciais. Um dos principais problemas em métodos de agrupamento *fuzzy* é a inicialização dos centros. A matriz de centros é geralmente inicializada aleatoriamente, ou escolhida pelo usuário. Yang et al. [7] propuseram o agrupamento subtrativo [8] para essa finalidade no FCM e aqui a mesma proposta foi aplicada ao FCKM.

Com o método subtrativo, a inicialização passa a ser automática e em pontos representativos do conjunto de dados, localizados próximos aos centros obtidos ao final do processo do FCKM. Essa metodologia aumenta a probabilidade de convergência e reduz o custo computacional do método *fuzzy*.

IV. RESULTADOS

O conjunto de dados utilizado é composto por 400 sinais, sendo 100 da classe sem defeito (50 de cada região da peça) e 100 de cada classe com defeito: três, duas e uma fenda. Todos os sinais foram utilizados para a realização dos testes.

A eficiência da classificação obtida foi calculada pelo produto de eficiência (PE), que é a média geométrica dos percentuais (Ef_i) de sinais classificados corretamente em cada classe. Matematicamente, é expresso pela equação (2).

$$PE = [(Ef_1) \times (Ef_2) \times \dots \times (Ef_c)]^{\frac{1}{c}} \quad (2)$$

A. Análise em frequência

Nesta análise, a principal característica que pode ser utilizada para distinguir os sinais das diferentes classes, após a aplicação da FFT, são suas amplitudes, como pode ser observado na Figura 2.

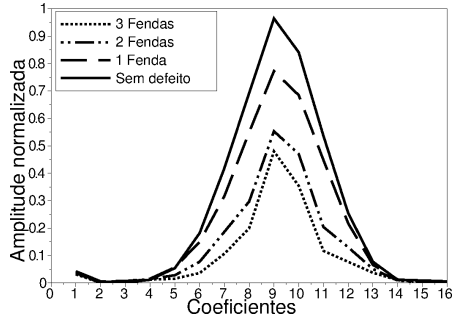


Figura 2. Sinais típicos em frequência.

O FCKMS foi aplicado aos componentes principais obtidos dos coeficientes 1 a 18 da FFT, pois possuem a maior parte da informação relevante dos sinais em frequência.

A representação das duas primeiras componentes principais após aplicação da PCA aos 16 coeficientes da FFT pode ser vista na Figura 3.

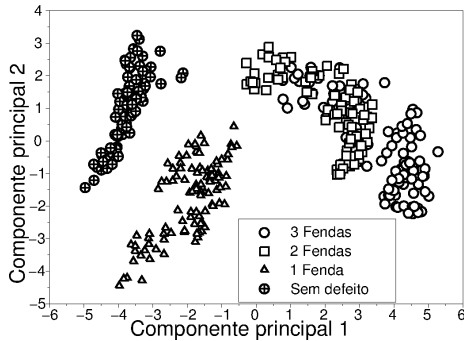


Figura 3. Sinais em frequência no espaço da PCA.

Com objetivo de determinar automaticamente a quantidade de grupos, foram aplicados quatro índices de validade de agrupamento [6], [9]: distância média entre grupos (AWCD - *average within-cluster distance*), hipervolume fuzzy (FH - *fuzzy hypervolume*), densidade média da separação (APD - *average partition density*) e achatamento médio dos grupos (ACF - *average cluster flatness*).

O número de grupos é indicado pelo FH e ACF por valores de mínimo e pelo APD por valores de máximo. Como AWCD decai monotonamente com o aumento de c , uma alta variação na taxa de decaimento indica o número de grupos. O resultado para o método FH está apresentado na Figura 4.

O FH, APD e AWCD indicaram 4 grupos, enquanto o ACF indicou 6 grupos. Desta forma, utilizando métodos




Figura 4. Valores normalizados do FH em função do número de grupos.

automáticos é possível reconhecer os 4 padrões presentes na chapa.

Buscou-se separar os dados em 4 grupos. Os produtos de eficiência em função do número de coeficientes da FFT e das 5 primeiras componentes principais da PCA estão apresentados na Tabela I. O maior PE para cada coeficiente está em negrito.

Tabela I
PRODUTOS DE EFICIÊNCIA (%) OBTIDOS EM FUNÇÃO DOS COEFICIENTES DA FFT E DAS COMPONENTES PRINCIPAIS

Coef.	Comp. Principais	Prod. de Eficiência (%)				
		1	2	3	4	5
1		41,44	-	-	-	-
2		54,53	51,21	-	-	-
3		38,73	33,99	62,49	-	-
4		42,97	47,45	48,01	52,49	-
5		55,54	54,93	54,18	54,65	58,80
6		65,69	59,27	55,18	59,28	59,09
7		62,66	62,76	59,72	62,51	62,09
8		60,22	64,10	62,21	63,06	62,73
9		78,75	71,27	64,45	68,36	71,02
10		78,62	72,55	70,61	71,90	72,11
11		79,78	72,43	71,27	72,81	73,01
12		79,73	74,26	71,97	73,20	73,78
13		79,73	74,72	72,53	74,16	74,16
14		79,47	75,12	77,07	74,87	75,12
15		80,22	75,69	76,53	31,77	76,53
16		79,70	76,82	77,56	88,29	80,28
17		78,01	74,37	31,46	74,62	74,43
18		72,72	75,66	74,89	74,11	72,42

O maior PE foi obtido utilizando 16 coeficientes e 4 componentes principais.

O resultado *defuzzificado* e os graus de pertinência da melhor classificação obtida estão apresentados nas Figuras 5 e 6, respectivamente. A *defuzzificação* dos dados foi realizada pelo método dos máximos, em que um ponto é classificado ao grupo que apresenta maior grau de pertinência. Os grupos obtidos estão apresentados por símbolos e seus centros por “×”. Os graus de pertinência estão apresentados na ordem das regiões em que os dados foram coletados (1 a 100 - 1 fenda (1F), 101 a 150 e 251 a 300 - sem defeito (SD), 151 a 250 - 2 fendas (2F) e 301 a 400 - 3 fendas (3F)).

B. Análise no tempo

Sinais típicos no domínio do tempo, de cada região da peça, são apresentados na Figura 7.




Figura 5. Resultado *defuzzificado* da classificação dos dados em frequência.




Figura 6. Graus de pertinência aos grupos obtidos dos dados em frequência para (a) grupo 1, (b) grupo 2, (c) grupo 3 e (d) grupo 4.




Figura 7. Sinais típicos no domínio do tempo.

Pode-se perceber que sinais da classe sem defeito de diferentes regiões possuem amplitudes semelhantes, mas apresentam defasagem de $0,3 \mu s$, aproximadamente, como pode ser visto no detalhe na Figura 8. Em caso de interesse em aplicar a análise temporal, a metodologia do experimento deve ser analisada para verificar se a diferença de fase é causada pelo processo de coleta dos dados ou características da chapa, uma vez que os defeitos também alteram a fase da onda.

A diferença de fase entre os sinais das duas regiões sem defeito faz com que sejam formados dois grupos após a transformação da PCA, apresentada na Figura 9.

Neste caso, o FH, APD e AWCD indicaram 3 grupos,




Figura 8. Detalhe dos sinais típicos das duas regiões da classe sem defeito.

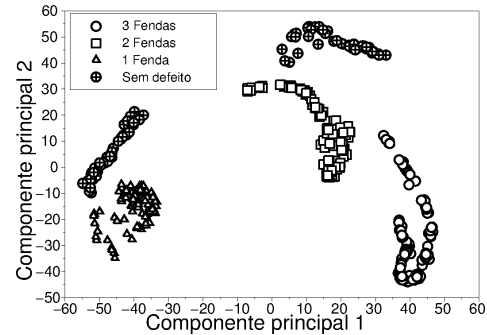


Figura 9. Sinais no tempo no espaço da PCA.

enquanto o ACF indicou 5 grupos. Em qualquer um dos casos os dados das regiões sem defeito não seriam agrupados.

Com o deslocamento de $0,3 \mu s$ dos sinais sem defeito coletados na região entre duas e três fendas, os dados das regiões sem defeito aproximam-se na PCA, como pode ser visto na Figura 10.




Figura 10. Sinais no tempo espaço da PCA após o deslocamento de fase dos sinais da região sem defeito.

Com a correção de fase, o AWCD e o ACF indicaram 4 grupos e o APD indicou 3. O FH apresentou mínimo global em 3 grupos, mas um valor próximo para 4. Neste caso, os 2 valores deveriam ser testados.

O FCKMS foi aplicado aos dados originais e com a correção de fase dos sinais de uma região sem defeito para classificação em 4 grupos. A classificação foi realizada para

as 5 primeiras componentes principais, pois apresentaram variância maior que 1%.

Os produtos de eficiência obtidos com a variação do número de componentes principais para os dados originais e com os sinais da região sem defeito em fase estão apresentados nas Tabelas II e III, respectivamente.

Tabela II
PRODUTOS DE EFICIÊNCIA EM FUNÇÃO DO NÚMERO DE COMPONENTES PRINCIPAIS PARA OS DADOS NO TEMPO.

Componentes Principais	Variância (%)	PE (%)
1	48,10	70,46
2	27,46	71,43
3	11,90	78,51
4	5,52	78,51
5	1,10	78,51

Tabela III
PRODUTOS DE EFICIÊNCIA EM FUNÇÃO DO NÚMERO DE COMPONENTES PRINCIPAIS PARA OS DADOS NO TEMPO COM A CORREÇÃO DE FASE DOS SINAIS DE UMA REGIÃO SEM DEFEITO.

Componentes Principais	Variância (%)	PE (%)
1	55,46	92,73
2	21,99	93,95
3	9,00	95,16
4	5,30	94,86
5	1,68	95,73

O resultado *defuzzificado* da melhor classificação obtida dos dados originais está apresentado na Figura 11 e os graus de pertinência são mostrados na Figura 12.

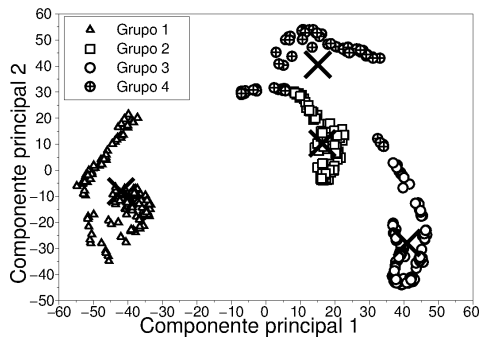


Figura 11. Resultado *defuzzificado* da classificação dos dados no tempo originais.

O resultado *defuzzificado* da melhor classificação dos dados com a correção de fase de uma região sem defeito está apresentado na Figura 13 e os graus de pertinência na Figura 14.

C. Análise pelos valores de pico

Como os sinais possuem mesma frequência, propõe-se a utilização dos valores de pico extraídos dos sinais no domínio do tempo para a classificação. Essa abordagem dispensa o uso de transformadas e da PCA.




Figura 12. Graus de pertinência aos grupos obtidos dos dados no tempo originais para (a) grupo 1, (b) grupo 2, (c) grupo 3 e (d) grupo 4.




Figura 13. Resultado *defuzzificado* da classificação dos dados no tempo após correção de fase.




Figura 14. Graus de pertinência aos grupos obtidos dos dados no tempo após correção de fase para (a) grupo 1, (b) grupo 2, (c) grupo 3 e (d) grupo 4.

As amplitudes normalizadas dos sinais em relação aos pontos em que estão no conjunto de dados podem ser vistas na Figura 15.

Neste caso, os índices FH e APD indicaram 3 grupos, mas com valores para 4 próximos. O AWCD e o ACF indicaram 4 grupos.

O resultado *defuzzificado* da classificação para 4 grupos é apresentado na Figura 16 e os graus de pertinência na Figura 17. O PE obtido nesta abordagem foi 82,96%.

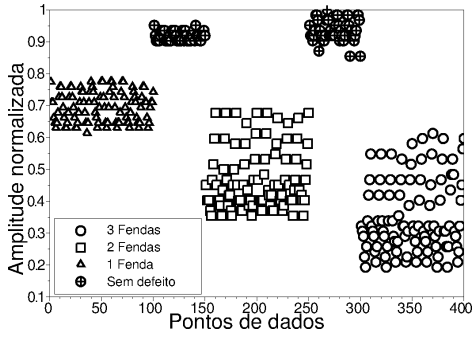


Figura 15. Amplitudes normalizadas dos sinais.

Esta abordagem foi capaz de agrupar os dados das regiões sem defeito. Os erros de classificação ocorreram entre dados das regiões com defeito.

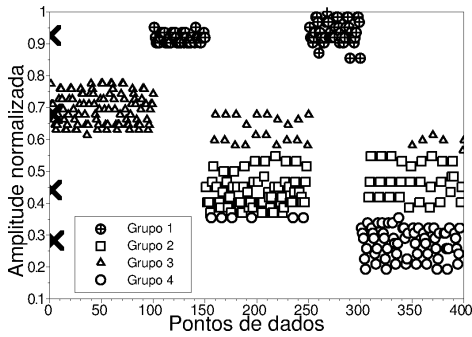


Figura 16. Resultado *defuzzificado* da classificação dos dados de pico dos sinais.

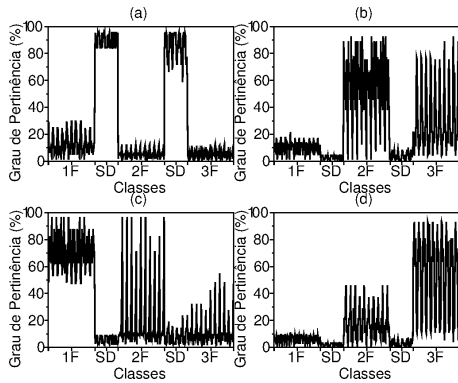


Figura 17. Graus de pertinência aos grupos obtidos dos dados de pico dos sinais.

O melhor resultado obtido na abordagem no tempo foi satisfatório quando comparado ao resultado encontrado em [2] na etapa de treino da rede neural (PE=98,14%), pois apresentaram diferença de apenas 2,4%.

V. CONCLUSÕES

A inspeção ultrassônica utilizando ondas de Lamb é uma técnica promissora para realização de ensaios não-destrutivos em ambientes industriais. Neste trabalho foram comparadas diferentes análises de sinais obtidos com

a aplicação da técnica em uma chapa de alumínio com defeitos tipo fenda. Os dados foram classificados a partir de uma abordagem não-supervisionada.

A análise temporal gerou grupos compactos após a aplicação da PCA. No entanto, sinais pertencentes à classe sem defeito, coletados em regiões diferentes da chapa, apresentaram diferença de fase. Caso a análise temporal se mostre uma alternativa favorável pelo menor custo computacional em relação à espectral, deve ser verificado se essa defasagem é resultado do método de inspeção utilizado, ou por características internas da chapa. Quando os dados da classe sem defeito foram deslocados para mesma fase, classificou-se mais de 92% dos dados corretamente.

Pela análise espectral pôde-se perceber a influência dos valores de pico dos sinais na classificação. Utilizando 16 coeficientes da FFT e 5 componentes principais foram classificados corretamente cerca de 87% dos sinais.

A classificação baseada apenas nos valores de pico, que possui o menor custo computacional das três, também se mostrou eficiente para distinção das quatro classes, classificando 83% dos dados corretamente, sendo que os erros ocorreram entre os dados com defeito. Mesmo que a eficiência obtida nessa abordagem seja inferior às abordagens anteriores, sua aplicação pode ser realizada em sistemas que não demandem elevada precisão.

AGRADECIMENTOS

Ao Laboratório de Ensaios Ultrassônicos do IFBA, ao projeto FAPESB/UESC: “Identificação automática de espécies de morcegos através do sinal de ecolocalização utilizando sistemas Fuzzy”, à Universidade Estadual de Santa Cruz pelo apoio financeiro e ao doutor Rogério Vargas por nos apresentar o método FCKM.

REFERÊNCIAS

- [1] M.J.S.F. Santos, *Ondas ultra-sonoras guiadas na caracterização e controlo não destrutivo de materiais*. Tese de doutorado. Universidade de Coimbra, 2004.
- [2] E. J. Silva, F. C. Cruz, D. H. S. Zanini, G. S. Pereira, C. T. T. Farias, I. C. Silva, e E. F. S. Filho, “Detecção e classificação de descontinuidades tipo fenda em chapas de alumínio utilizando ondas ultrassônicas guiadas de Lamb, transformada de Fourier e redes neurais artificiais”. *CONAEND&IEV 2014*, 2014.
- [3] A. V. Oppenheim, R. W. Shafer, J. R. Buck, *Discrete-Time Signal Processing*. New Jersey: Prentice Hall, 1999.
- [4] I. T. Jolliffe, *Principal Component Analysis*. Springer, 2002.
- [5] R. Vargas e B. Bedregal, “Uma nova forma de calcular o centro dos clusters no algoritmo Fuzzy c-Means”. *Proceedings of CNMAC 2010*, v. 3, p.486-492., 2010.
- [6] J.C. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms*. New York: Plenum Press, 1981.
- [7] Q. Yang, D. Zhang, e F. Tian, “An initialization method for Fuzzy C-means algorithm using Subtractive Clustering”. *3rd International Conference on Intelligent Networks and Intelligent Systems*, p. 393-396, Nov 2010.
- [8] S. L. Chiu, “Fuzzy Model Identification Based on Cluster Estimation”. *Journal of Intelligent and Fuzzy Systems*, v. 2, p. 267-278, 1994.
- [9] R. Babuška, *Fuzzy modeling for control*. New York: Springer, 1998.