



Célula Neural Artificial Paraconsistente utilizada como um Módulo Redutor de Ruídos em Sinais com Amplitudes oscilantes

Arnaldo de Carvalho Junior^{1,2}, Maurício C. Mario¹, Hyghor M. Cortês¹ e João Inácio Da Silva Filho¹

¹UNISANTA – Universidade Santa Cecília – Programa de Pós-Graduação em Engenharia Mecânica - PPGEMec
Rua Oswaldo Cruz, 266 - Santos-SP, Brasil - CEP: 11045-100

²IFSP- Instituto Federal de Educação, Ciência e Tecnologia de São Paulo
Rua Maria Cristina, 50 - Jardim Casqueiro - Cubatão - São Paulo

E-mail: adecarvalhojr@ifsp.edu.br

Received May, 2017

Resumo: A Célula Neural Artificial Paraconsistente (CNAP) é um algoritmo que utiliza a lógica paraconsistente anotada de modo que aplicando os graus de evidência favorável (μ) e desfavorável (λ) em suas duas entradas, apresenta em suas saídas o grau de evidência de análise resultante μ_E (ou evidência de análise resultante real (μ_{ER})) e o intervalo de evidência resultante (φ_E). A Célula Neural Artificial Paraconsistente de Aprendizagem (CNAPap) e suas variações é um tipo de CNAP que usa a saída como uma realimentação para a entrada do grau de evidência desfavorável no tempo, podendo assim ser treinada para responder (aprender) qualquer valor real dentro de um intervalo $[0,1]$ pertencente aos conjunto dos números reais. Esta célula configurada convenientemente pode ser utilizada na análise e tratamento de sinais de dados analógicos. Neste trabalho apresentamos os resultados de simulações de CNAPap e suas variações topológicas como um módulo redutor de ruído de sinal para sistemas de automação.

Palavras chave: Tratamento de Sinais, LPA2v, CNAPap, Filtro LPA2v.

Paraconsistent Artificial Neural Cell used as noise Reducer Module in Signals with Oscillating Amplitudes

Abstract: The Paraconsistent Artificial Neural Cell (PANcel) is an algorithm that utilizes the paraconsistent annotated logic so that applying the degrees of favorable evidence (μ) and unfavorable (λ) on its two inputs, it presents at its outputs the degree of resulting analysis evidence (μ_E) or real analysis evidence (μ_{RE}) and the resulting evidence interval (φ_E). The Paraconsistent Artificial Neural Cell of Learning (LPANcel) and its variations is a type of PANcel that uses the output as a feedback to the input of the unfavorable degree of evidence in time, it can learn (be Training) any real value within a closed range (interval values $[0,1]$) in the set of Real numbers. This cell can be used in analysis and treatment of signal of analogic data types. In the proposed article we present the results of simulations of LPANcel and its topological variations as noise reduction module of signals for automation systems.

Keywords: Signal Treatment, PAL2v, LPANcel, PAL2v Filter

1. Introdução

A Lógica Clássica, ao que tudo indica foi iniciada na Grécia Antiga pelo filósofo Aristóteles e seu grupo e é atualmente a base para os modernos sistemas eletrônicos

digitais e computadores. A Lógica Clássica é estritamente binária e aceita apenas 2 estados possíveis para uma proposição P . A sua aplicação em uma análise obriga que a sua conclusão aponte que a proposição é verdadeira (V) ou é falsa (F), não havendo espaço para meio termos ou contradições que possam gerar incertezas.

No mundo real as contradições, ambiguidades ou inconsistências podem aparecer ao se tentar descrever situações que se deseja analisar, o que torna a Lógica Clássica inoperante [1].

As Lógicas Paraconsistentes (LP) surgiram da necessidade de se desenvolver ferramentas e metodologias para tratar situações contraditórias ou inconsistentes. Estas lógicas apresentam resultados que permitem considerar as ambiguidades e contradições em sua estrutura de maneira não trivial. A LP e suas extensões têm se mostrado adequadas no tratamento de problemas ocasionados por situações em que surgem contradições ao se trabalhar com problemas do mundo real [2].

Este artigo propõe o uso de um tipo particular de LP, a Lógica Paraconsistente Anotada com anotação de 2 valores, para o tratamento de sinais, como redutor de ruído em sinais com amplitudes oscilantes [12].

2. Lógica Paraconsistente Anotada

A Lógica Paraconsistente Anotada – LPA pertence a uma família de Lógicas Paraconsistentes que possui a propriedade de ser representada por um diagrama de Hasse de quatro vértices. Em seus vértices são representados os estados lógicos extremos de uma proposição (P). Uma proposição P é assim acompanhada por anotações pertencentes a um reticulado finito [3] [4]. Cada anotação está relacionada a um estado lógico extremo da proposição P que por sua vez está localizado no vértice do reticulado, tal que: T = Inconsistente, V = Verdadeiro, F = Falso e $\perp$ = Paracompleto ou Indeterminado.

2.1 Lógica Paraconsistente Anotada com anotação de dois valores LPA2v

A Na Lógica Paraconsistente Anotada com Anotação de dois valores (LPA2v) a representação de evidências em um reticulado no plano real é formada por pares que compõem uma anotações (μ, λ) , permitindo assim atingir um maior poder de representação. A proposição P é suportada pelo grau de evidências favoráveis, ou (μ) . O grau das evidências desfavoráveis que negam ou rejeitam a proposição P é representada pelo elemento (λ) .

Um operador “ $\sim$ ” é introduzido e definido como segue [3]: $\sim: \tau \mapsto \neg \tau$, onde $\tau = \{(\mu, \lambda) \mid \mu, \lambda \in [0, 1] \subset \mathfrak{R}\}$

A associação de um par (μ, λ) para uma proposição P significa que o grau de evidência favorável em P é μ , e o grau de evidência desfavorável é λ , conforme as anotações no reticulado [4] [5]:

$(1, 0) \rightarrow$ indica existência de evidência favorável total e evidência desfavorável igual a zero, assinalando uma conotação lógica verdadeira para a proposição P .

$(0, 1) \rightarrow$ indica a existência de evidência favorável igual a zero e evidência desfavorável total, dando uma conotação de falsidade lógica para a proposição P .

$(1, 1) \rightarrow$ indica a existência de ambos, evidência favorável e desfavorável totais, atribuindo uma conotação lógica de inconsistência à proposição P .

$(0, 0) \rightarrow$ indica a existência de ambos, evidência favorável e desfavorável zero, atribuindo uma conotação lógica de indeterminação para a proposição P .

A figura 1 apresenta um reticulado representativo de quatro vértices associado com a LPA2v [6].




Figura 1. Reticulado finito de Hasse associado à LPA2v.

Através de transformações lineares entre um Quadrado Unitário no Plano Cartesiano (QUPC) e o reticulado associado à LPA é possível se chegar às seguintes equações matemáticas relacionadas à LPA2v [2] [3] apresentadas a seguir:

$$\lambda = 1 - \mu_2 \quad (1)$$

$$G_C = \mu_1 - \lambda \quad (2)$$

$$G_{CT} = \mu_1 + \lambda - 1 \quad (3)$$

$$\mu_E = \frac{G_C + 1}{2} \Rightarrow \mu_E = \frac{\mu - \lambda + 1}{2} \quad (4)$$

$$\mu_{CTR} = \frac{\mu + \lambda}{2} \quad (5)$$

Onde μ_1 é o grau de evidência favorável, proveniente da primeira evidência; λ é o grau de evidência desfavorável, como o complemento da segunda evidência; G_C é o grau de certeza; G_{CT} é o grau de contradição.

A análise paraconsistente gera valores de G_C e G_{CT} entre 1 e -1. Para ser consistente com as entradas (μ, λ) , em aplicações práticas eles precisam ser normalizados e seus valores limitados novamente entre 0 e 1 para respeitar os limites da lógica paraconsistente. Portanto, o μ_E é o grau de evidência resultante, sendo a saída normalizada de G_C , enquanto que μ_{CTR} é a saída normalizada de G_{CT} .

Conforme visto em [1] [8] pode-se obter um resultado mais preciso extraindo-se os efeitos da contradição em sucessivas análises de modo a obter o grau de certeza

resultante real (G_{CR}), como indicado na figura 2, e apresentado nas equações matemáticas a seguir:

$$D = \sqrt{(1 - |G_C|)^2 + G_{CT}^2} \quad (6)$$

Se $G_C > 0$

$$G_C > 0 \rightarrow G_{CR} = 1 - D;$$

$$G_C < 0 \rightarrow G_{CR} = D - 1; \quad (7)$$

$$\phi = 1 - |G_{CT}| \quad (8)$$

$$\mu_{ER} = \frac{G_{CR} + 1}{2} \quad (9)$$

$$\phi_E = 1 - |2 * \mu_{CTR} - 1| \quad (10)$$




Figura 2. Reticulado LPAv2 com Grau de certeza (G_C), Grau de Contradição (G_{CT}) e Grau de Certeza real (G_{CR}).

Sendo que D é a distância entre o estado lógico paraconsistente - $\epsilon\tau(G_C, G_{CT})$ e o vértice V (se $G_C > 0$) ou F (se $G_C < 0$); então G_{CR} é o grau de certeza real; ϕ é o intervalo de certeza; μ_{ER} é o grau de evidência resultante real (G_{CR} normalizado com valores entre (0,1)); μ_{CTR} é o grau de contradição normalizado e ϕ_E é o intervalo de evidência resultante [8] [9].

Na equação (7), G_{CR} é obtido após os efeitos da contradição serem removidos, sendo o resultado considerado o de valor puro.

O sinal de saída de um sistema paraconsistente de tratamento de incertezas fornecerá o resultado de Grau de Certeza Resultante Real (G_{CR}) sendo representado pelos valores (G_{CR} , $\phi(\pm)$) [8].

O grau de evidência resultante real (μ_{ER}) é um valor mais consistente do que o grau de evidência resultante

(μ_E), conforme os efeitos da contradição são extraídos da análise.

Se o G_{CT} tende a inconsistente, ϕ é marcado como “+”; e se G_{CT} tende a indeterminado, ϕ é marcado como “-”.

2.2. A Célula Neural Artificial Paraconsistente Padrão

Conforme apresentado em [1], pode-se escrever o conjunto de equações matemáticas da Lógica Paraconsistente Anotada e suas interpretações para formar um algoritmo denominado de Nó de Análise Paraconsistente (NAP) [6], sendo este o bloco básico de uma Célula Neural Artificial Paraconsistente (CNAP). A figura 3 mostra a representação do algoritmo de análise paraconsistente – LPA2v. A figura 4 apresenta o símbolo de uma CNAP padrão.




Figura 3. Representação do algoritmo de Análise Paraconsistente LPA2v.




Figura 4. Símbolo da CNAP padrão.

As entradas (F_{tCT} – Fator de Tolerância à Contradição, F_{tC} – Fator de Tolerância à Certeza, F_{tD} – Fator de Tolerância à Decisão, F_A – Fator de Aprendizagem) são valores externos de ajuste entre (0,1), permitindo atribuir outros valores de limites superior e inferior para G_C , G_{CT} , ϕ e taxa de aprendizagem.

Estes fatores podem ou não serem utilizados, dependendo de como se aplica a CNAP e estão bem detalhados em [6]. O valor “1” é máximo e “0” é mínimo quando aplicado a cada fator. As CNAPs podem ser combinadas

para formar uma rede neural artificial paraconsistente - RNAP. As saídas de uma CNAP ou de uma RNAP podem ser aplicadas a um sistema de tratamento de sinais ou de tomada de decisão, conforme proposto em [10].

A partir da CNAP básica várias células neurais paraconsistentes foram propostas em [6] e podem ser utilizadas em arranjos de interconexão para formar Redes Neurais Artificiais Paraconsistentes - RNAPs como elemento chave de sistemas especialistas.

2.3. Célula Neural Artificial Paraconsistente Analítica - CNAPa

A CNAPa faz a análise paraconsistente e apresenta em sua saída o valor do grau de evidência resultante - μ_E , cuja saída poderá variar entre os limites superior e inferior estabelecidos pelo fator de tolerância à certeza, F_{tC} . Uma variante desta CNAP é a Célula Neural Artificial Paraconsistente Analítica Real CNAPar que apresenta μ_{ER} , ao invés de μ_E . A forma como o grau de evidência resultante e grau de evidência resultante real são calculados é exatamente conforme descrito nas equações (1) a (10). A figura 5a apresenta o símbolo da CNAPa enquanto o símbolo da CNAPar é apresentado na figura 5b.

2.4. Célula Neural Artificial Paraconsistente de Aprendizagem

A célula Neural Artificial Paraconsistente de Aprendizagem - CNAPap, consiste basicamente de uma CNAPa cuja saída μ_E é aplicada à entrada do grau de evidência desfavorável - λ [5][9]. Da mesma forma, a Célula Neural Artificial Paraconsistente de Aprendizagem Real - CNAPapr consiste basicamente de uma CNAPar. A figura 6a apresenta a CNAPap enquanto a CNAPapr é apresentada na figura 6b.

Dado que a célula está sempre realizando a análise entre o grau de evidência favorável (μ) atual com o grau de evidência resultante (μ_E) (ou grau de evidência resultante real (μ_{ER})) anterior, há um sentido de relógio e a célula levará um tempo para apresentar o resultado final, que dependerá da precisão (casas decimais) desejada.

A CNAPapr recebe o nome de célula de aprendizagem porque a saída tende a responder, ou aprender, qualquer valor real no intervalo fechado $[0,1]$ aplicado à entrada μ . O fator de aprendizagem F_A funciona como um ajuste (ou ganho) do sinal realimentado, permitindo que a célula tenha uma aprendizagem mais rápida ou mais lenta, conforme equações (11) a (14).




Figura 5 - CNAPa (a) e CNAPar (b).




Figura 6 - CNAPap (a) e CNAPapr (b).

$$\mu_{Ek} = \frac{\{\mu_{(\kappa)} - (\lambda_{(\kappa)}) * F_A\} + 1}{2} \Rightarrow$$

$$\mu_{Ek} = \frac{\{\mu_{(\kappa)} - (1 - \mu_{E(k-1)}) * F_A\} + 1}{2} \quad (11)$$

$$\lambda_{(\kappa)} = 1 - \mu_{E(k-1)} \quad (12)$$

$$\mu_{ERk} = \frac{\{\mu_{(\kappa)} - (\lambda_{(\kappa)}) * F_A\} + 1}{2} \Rightarrow$$

$$\mu_{ERk} = \frac{\{\mu_{(\kappa)} - (1 - \mu_{ER(\kappa-1)}) * F_A\} + 1}{2} \quad (13)$$

$$\lambda_{(\kappa)} = 1 - \mu_{ER(k-1)} \quad (14)$$

Onde k refere-se ao valor atual e $k-1$ a amostra imediatamente anterior.

As figuras 7 e 8 apresentam um exemplo de comportamento de uma CNAPap e CNAPapr para um sinal quadrado aplicado à sua entrada, com F_A igual a 1.

Nota-se que a CNAPap leva uma quantidade de amostras menor que a CNAPapr para “aprender o valor de entrada. Nota-se ainda que as saídas μ_E e μ_{ER} apresentam características de integral enquanto que a saída μ_{CTR} apresenta características de diferencial normalizado [0,1]. Pode-se verificar que a CNAPap necessita de 20 amostras ou iterações para “aprender” reproduzindo assim o valor exato do sinal de entrada na saída.

A CNAPapr necessita de 21 iterações para obter estas condições de repetir o valor da entrada na saída.




Figura 7. Saídas μ_E da CNAPap e μ_{ER} da CNAPapr à um sinal de onda quadrada aplicado à entrada de grau de evidência favorável - μ .




Figura 8. Saída μ_{CTR} da CNAPapr à um sinal de onda quadrada aplicado à entrada μ .

2.5. CNAP por Extração do Efeito da Contradição

A CNAPap funciona de modo esperado quando o Fator de aprendizagem - F_A tem valor unitário, ou quando apenas o F_A é variável e o valor de μ aplicado na entrada é constante. Entretanto, conforme apresentado em [11], quando se varia simultaneamente o valor do grau de evidência favorável - μ e o fator de aprendizagem - F_A , a saída converge para um valor diferente do esperado a ser obtido na entrada. Para corrigir esta deficiência em [11] foi proposta uma alteração na equação da CNAPap, sendo chamada de célula Neural Artificial Paraconsistente por Extração do Efeito da Contradição - CNAPapxct, cujo valor do grau de evidência resultante atual, é obtido pela equação apresentada a seguir:

$$\mu_{Ek} = \mu_{E(k-1)} + G_{CT} * F_A \quad (15)$$

Onde F_A = Fator de aprendizagem segue com valores entre 0 e 1.

A figura 9 apresenta a resposta a um sinal de onda quadrada aplicada na entrada de uma CNAPapxct para diferentes valores de F_A .




Figura 9. Saída μ_E da CNAPapxct para um sinal de onda quadrada aplicado à entrada μ .

Nota-se que com F_A nulo não há aprendizagem, enquanto que com F_A de valor unitário a saída reflete diretamente o valor apresentado na entrada. A CNAPapxct utilizando F_A com valor de 0,5 apresenta comportamento idêntico à CNAPap com F_A de valor unitário.

3. Materiais e Métodos

Foram utilizadas funções do *software* MATLAB® R2008a com SIMULINK para configuração das células e suas estruturas para demonstrar, através de simulações, as diferentes formas de suas aplicações no tratamento de sinais de dados analógicos. As figuras 10, 11 e 12 apresentam respectivamente modelos de CNAPap, CNAPapr e CNAPapxct, propostos e criados no SIMULINK para as simulações utilizadas.




Figura 10. Unidade de CNAPap criada no MATLAB® SIMULINK (a) e em bloco (b).




Figura 11. Unidade de CNAPap criada no SIMULINK.




Figura 12. CNAPapxct criada no SIMULINK.

Para verificar o comportamento das células neurais paraconsistentes configuradas no *software* de simulação, foram aplicados:

- a) sinais senoidais e adicionados ruídos;
- b) sinais de intensidade variável com oscilação em amplitude com outros sinais interferentes;
- c) sinais de onda quadrada adicionado com outros sinais interferentes;

A seguir são apresentadas as formas das aplicações e os resultados obtidos com as simulações realizadas.

4. Resultados e Comentários

4.1. Módulo Redutor de Ruído

A figura 13 apresenta um sinal senoidal variando entre 0,2 e 0,8 (nos limites da LPA2v), frequência de 1 rad/seg, com adição de ruído branco, aplicado à entrada. A janela de observação é de 10 segundos, aplicado à entrada de uma CNAPap, sendo que os valores medidos nas saídas da célula são apresentados nas figuras 14 e 15.




Figura 13. Topologia de simulação da CNAPapr, com sinal senoidal mais ruído branco aplicado à entrada μ .

Nota-se na figura 14 uma grande semelhança entre o ruído branco considerado e o sinal G_{CT} obtido na saída da CNAPapr. A saída do grau de evidência resultante real - μ_{ER} , consiste em uma análise já com os efeitos da contradição sendo extraídos, nesse caso, o ruído. Percebe-se pela figura 15 que o sinal μ_{ER} apresenta menos variações de ruído que o sinal aplicado à entrada μ .




Figura 14. Comparação entre o ruído branco e o resultado do G_{CT} na saída da cNAPapr.




Figura 15. Gráfico mostrando o Sinal senoidal com ruído e saída com ruído reduzido (μ_{ER}).

Foi mantida a mesma topologia da figura 13, porém aplicando-se à entrada um sinal senoidal de baixa frequência somado a um sinal de menor amplitude e frequência mais alta. Neste caso é simulada uma interferência em oscilação em amplitude. Os resultados da simulação com sinais interferentes em oscilação em amplitude são apresentados nas figuras 16 e 17, a seguir.




Figura 16. Comparação entre sinal interferente de 6 rad/seg e o grau de contradição (G_{CT}) da CNAPapr.

Novamente percebe-se na figura 16 uma grande semelhança entre o sinal interferente considerado e o sinal G_{CT} obtido na saída da CNAPapr.




Figura 17. Sinal de entrada com oscilação em amplitude e o Grau de Evidência Resultante Real (μ_{ER}) da CNAPapr.

Pode-se perceber pela figura 17 que o sinal μ_{ER} apresenta menos variações de oscilação em amplitude que o sinal aplicado à entrada μ .

A seguir o comportamento na saída da CNAPapr para uma onda quadrada com ruído branco sobreposto aplicado à entrada μ , pode ser verificado pelas figuras 18 e 19.

Nota-se pela figura 18 que o sinal G_{CT} apresenta picos muito diferentes do ruído, devido ao efeito diferencial já mencionado na figura 8, justamente nos pontos onde há transição da onda quadrada aplicada à entrada da CNAPapr.

É possível ainda observar na figura 19 que um atraso é introduzido na forma de onda de saída, devido ao tempo (ou número de amostras) que a CNAPapr necessita para “aprender” o sinal de entrada. Ainda assim, nos períodos de estabilidade (nível alto e baixo) do sinal de entrada a CNAPapr apresenta uma redução do nível de ruído em relação à entrada. Desta forma pode-se perceber que quando o sinal de informação varia abruptamente (como um degrau ou onda quadrada), ha uma distorção na saída. Esta distorção é causada pelo número de amostras necessários para a aprendizagem da célula.




Figura 18. Comparação entre ruído branco a ser adicionado à onda quadrada na entrada e o resultado do Grau de Contradição – G_{CT} .




Figura 19. Onda quadrada com ruído branco na entrada da CNAPapr comparado com o Grau de Evidência Real (μ_{ER}) na saída, após a análise das contradições.

Pelas simulações apresentadas, percebe-se que uma CNAPapr pode funcionar como um Módulo Redutor de Ruído e Interferência simplificado, ainda que haja uma alta relação entre a taxa de amostragem do sinal, a frequência de ruído e número de amostras que a célula necessita para aprender o valor da entrada. Verifica-se que estes fatores influenciarão na eficácia da CNAPapr para este tipo de aplicação.

5. Conclusões

As células neurais artificiais paraconsistentes CNAPs apresentam resultados promissores e podem, dentro de certos limites, serem aplicadas no tratamento de sinais de sistemas de automação. O presente estudo apresentou algumas aplicações potenciais de CNAP, principalmente as variantes de células neurais artificiais paraconsistentes de aprendizagem, no tratamento de sinais. Pelas simulações efetuadas, percebe-se que uma CNAPapr pode funcionar como um módulo Redutor de Ruído e Interferência simplificado, ainda que haja uma alta relação entre a taxa de amostragem do sinal, a frequência de ruído e número de amostras suficiente para que célula aprenda o valor aplicado na entrada. Como estes fatores influenciarão na eficácia da CNAPapr para este tipo de aplicação, as topografias das CNAPs apresentadas neste trabalho abrem um novo campo de pesquisa nas aplicações onde trabalhos futuros serão levados a efeitos focando no estudo do comportamento das Células frente as variações destes e de outros fatores.

Referências

- [1] Da Silva Filho, J. I.. Métodos de Aplicações da Lógica Paraconsistente Anotada de anotação com dois valores-LPA2v. Revista Seleção Documental, ISSN 1809-0648, Santos, São Paulo – Brasil, Número 1, Ano 1, p. 18 – 25, Março 2006.
- [2] Da Silva Filho, J. I.. Análises de Sinais de Informações em Lógica Paraconsistente Anotada. Revista Seleção Documental, ISSN 1809-0648, Santos, São Paulo – Brasil, Número 14, Ano 4, p. 22 – 26, Junho 2009.
- [3] Da Costa, N. C. A.; Abe, J. M.; Subrahmanian, V.S. “Remarks on annotated logic, Zeitschrift f. math. Logik und Grundlagen d. Math”. 37, Vol.37, pp 561-570, 1991.
- [4] Subrahmanian, V. S. “On the semantics of quantitative logic programs. Proc. 4th. IEEE Symposium on Logic Programming”, Computer Society Press, Washington D.C., 1987.
- [5] Da Cruz, C. M.. “Application of Paraconsistent Artificial Neural network in Statistical Process Control acting on voltage level monitoring in Electrical Power Systems - Intelligent System Application to Power Systems (ISAP)”, pp.(1-6), Porto-PT, DOI 10.1109/ISAP.2015.7325579, September, 2015.

- [6] Da Silva Filho, J. I.. “Introdução às Células Neurais Artificiais Paraconsistentes”, Revista Seleção Documental, No 8, Dezembro, 2007.
- [7] Da Silva Filho, J. I.. Da Cruz, C. M.. Rocco, A.. Garcia, D. V.. Ferrara, L.F. P. Onuki, A. S.. Mario, . C.. Abe, J. M.. M. A. “Paraconsistent Artificial Neural Network for structuring Statistical Process Control in Electrical Engineering”. Towards Paraconsistent Engineering Book, pp 77-102, Springer International Publishing, ISBN 978-3-319-40418-9, 2016.
- [8] Da Silva Filho, J. .I. “Treatment of Uncertainties with Algorithms of the Paraconsistent Annotated Logic”, Journal of Intelligent Learning Systems and Applications, 2012, 4, 144-15. Published Online May 2012 at <http://dx.doi.org/10.4236/jilsa.2012.42014>.
- [9] Mario, M. C.; Ferrara, L. F. P.; Da Silva Filho, J. I. “Treinamento de uma Célula Neural Artificial Paraconsistente de Aprendizagem”. Seleção Documental Magazine, No 6, pp 11 – 16, 2007, SP. Brazil. ISBN 18090648.
- [10] Da Silva Filho, J. I.; Torres, C. R.; Abe, J. M.. “Robô Móvel Autônomo Emmy: Uma Aplicação eficiente da Lógica Paraconsistente Anotada”, Revista Seleção Documental, No 3, Setembro, 2006, SP. Brasil. ISBN 18090648.
- [11] Minicz, M. de F.; Matuck, G. R.; Tasinaffo, P. M.; Da Silva Filho, J. I.. “Célula Neural Artificial Paraconsistente de Aprendizagem por Extração do Efeito da Contradição”. Seleção Documental Magazine, No 33, pp 3 – 9, Março, 2014, SP. Brasil. ISBN 18090648.