



Treinamento de uma Célula Neural Artificial Paraconsistente de Aprendizagem (CNAPap) utilizando Microsoft Excel

Rodney Gomes da Silva^{1,2}, João Inácio da Silva Filho¹, Dorotéia Vilanova Garcia¹

¹ UNISANTA- Universidade Santa Cecília – Programa de Pós-Graduação em Engenharia Mecânica – PPGEMec - Rua Oswaldo Cruz, 288 - Boqueirão, CEP- 11045-000, Santos-SP, Brasil

² ETEC ARISTÓTELES FERREIRA - Escolas Técnicas Estaduais - Av. Dr. Epitácio Pessoa, 466 - Aparecida, CEP 11030-600, Santos - SP, Brasil

Email: engprofrodney@gmail.com

Resumo

As pesquisas e os estudos da Lógica Paraconsistente (LP) têm despertado grandes interesses em especialistas na área de automação industrial e em outras áreas, principalmente na saúde, e, neste caso, os modos de aplicações desta lógica se mostram bastante promissores. Este trabalho apresenta uma forma de aplicação do algoritmo da Célula Neural Artificial Paraconsistente de Aprendizagem (CNAPap), que é originado da Lógica Paraconsistente Anotada com Anotação de dois Valores (LPA2v). O algoritmo CNAPap foi configurado para atuar em um *software* aplicativo onde foi feito um treinamento para estudar como uma célula neural aprende de maneira mais rápida através de suas iterações. Os resultados deste estudo demonstraram que controles diversos aplicados em Inteligência Artificial com as Redes de Análises Paraconsistentes compostas de CNAPap podem ser simulados e testados com os recursos de um *software* aplicativo antes de uma aplicação real.

Palavras-Chave: Inteligência Artificial; Célula Neural; Redes de Análises Paraconsistentes.

Training of a Paraconsistent Artificial Neural Cell Learning (CNAPap) using Microsoft Excel

Abstract

The research and studies of Paraconsistent Logic (PL) have aroused great interest in specialists in the field of industrial automation and in other areas, especially in health, and in this case, the modes of application of this logic are very promising. This work presents a form of application of the algorithm of the Paraconsistent Artificial Neural Cell of Learning (CNAPap) originated from the Paraconsistent Annotated Logic with two Values Annotation (LPA2v) and configured to act in an application software. Based on this algorithm training was done to see how a neural cell learns faster through its iterations. The results of this study demonstrated that several controls applied in Artificial Intelligence with the Paraconsistent Analysis Networks can be simulated and tested with the resources of an application software before a real application.

Keywords: Artificial Intelligence; Neural Cell; Paraconsistent Analysis Networks.

Introdução

Uma Célula Neural Artificial Paraconsistente de Aprendizagem (CNAPap) pode ser treinada para aprender um padrão pelo método de análise paraconsistente aplicado através de

um algoritmo e, serem utilizados em sistemas de sensores primários que recebem as primeiras informações e transformam em sinais elétricos que serão tratados pela rede. Com isso, esse treinamento é feito para que as células reconheçam apenas valores 0 ou 1 [1]. A Figura 1 mostra uma representação de uma CNAPap.




Figura 1– Símbolo da CNAPap.

Fonte: Da Silva Filho; ABE; Lambert-Torres. 2008

Com isso, a Lógica Paraconsistente Anotada LPA pertence à classe das lógicas não-clássicas e, de acordo com os vários trabalhos na área de Inteligência Artificial, trata-se de uma excelente solução para fazer tratamento destas situações incertas de modo não-trivial [2].

Sendo assim, o método de interpretação da Lógica Paraconsistente baseada nos conceitos de uma Lógica Paraconsistente Anotada com anotação de dois valores LPA2v, permite a criação de uma família de Células Neurais Artificiais Paraconsistentes (CNAPs) que no qual traz inovação nas aplicações de Redes Neurais. Essas CNAPs tem um comportamento no qual modela um neurônio biológico oferecendo uma simples implementação em *hardware* ou em *software*, compondo assim, Redes Neurais Paraconsistentes. Foram construídas a partir de uma Célula Paraconsistente básica representada pelo Algoritmo que descreve o reticulado associado à Lógica Paraconsistente Anotada denominado de "Para-Analisador" e pertence à família de células que são projetadas para funções específicas em uma rede paraconsistente de reconhecimento de padrões [3].

Portanto, neste artigo será apresentado a CNAPap funcionando em um *software* de planilha eletrônica no Excel, de forma a proporcionar que os usuários possam simular o comportamento de uma célula no processo de aprendizagem.

Célula Neural Artificial Paraconsistente de Aprendizagem – CNAPAP

A célula de aprendizagem é uma CNAPap apresenta na sua saída um valor que varia assintoticamente cujo comportamento é similar ao processo de um neurônio biológico.

Considera-se inicialmente que um valor 1, significa padrão (V) Verdadeiro e o valor zero, significa Padrão Falso (F) [1]. Dessa forma, a partir da saída ajustada em meio (0,5) (célula virgem), inicia-se um processo de aprendizagem através de iterações seguindo um algoritmo e fluxograma definidos [1]. Uma aplicação recorrente de um valor padrão 1 provoca uma saída convergente em 1. Neste caso, ao final de iterações, quando a saída alcança 1 significa que a CNAPap aprendeu, ou foi treinada. Da mesma forma, um padrão 0 provoca uma saída convergente em 0 após seu treinamento.

O fator de aprendizagem (Fa)

O Fator de Aprendizagem (Fa) é um valor que irá ajustar os cálculos para que uma célula possa aprender mais rapidamente ou não. Se o valor de Fa for igual a um, a CNAPap irá aprender bem mais rápido. Por outro lado, se o valor for igual a zero, a CNAPap irá ter o seu aprendizado bem mais lento do que o tempo previsto [1].

Fluxograma do algoritmo de aprendizagem do padrão de verdade

A aprendizagem de uma CNAPap é feita através de um treinamento que consiste em aplicar um padrão na entrada do sinal de Grau de Evidência favorável sucessivamente até que as contradições diminuam e seja obtido na saída um Grau de Evidência resultante igual a 1.

A Figura 2 apresenta o fluxograma para aprendizagem do padrão de verdade por uma CNAP de aprendizagem [1].

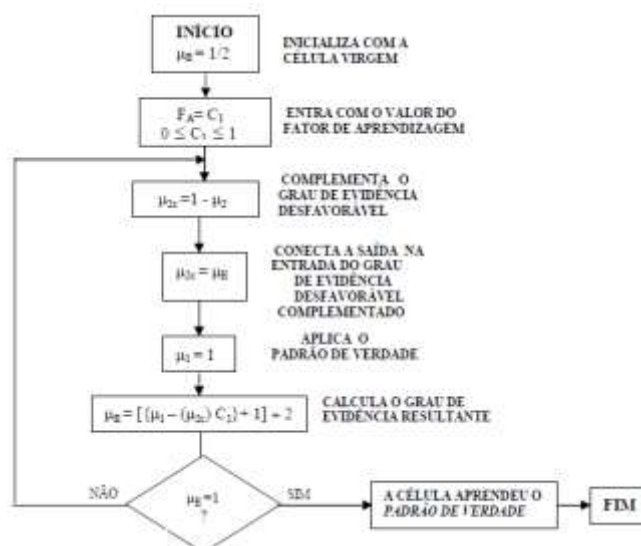


Figura 2 – Fluxograma para aprendizagem do padrão de Verdade da CNAPap.

Fonte: Da Silva Filho; ABE; Lambert-Torres. 2008

Objetivos

O presente trabalho tem como objetivo principal fornecer informações relevantes quanto ao uso do *software* Microsoft Excel na simulação de uma CNAPap e apresentar em

sua *interface* gráfica através de uma planilha eletrônica os valores calculados por fórmulas atribuindo o seu fator de aprendizagem (Fa) e mostrar graficamente, os resultados do aprendizado através das suas iterações (passos).

Materiais e Métodos

Neste trabalho foi utilizado uma planilha eletrônica no Excel versão 2016 da fabricante Microsoft para fazer simulações de aprendizagem em uma CNAPap. Neste *software* aplicativo utilizado foram feitas até dez iterações (passos) para que essa CNAPap tivesse precisão em sua aprendizagem. Para criação da planilha, foi inserido as colunas necessárias para demonstração do aprendizado da CNAPap que foi implementada da seguinte forma:

- Considerando que nas células:

B5 = Grau de Evidência favorável (μ_1) - valor inicial 0,5 e depois 1;

C5 = Grau de Evidência desfavorável (μ_2) - valor inicial 0,5 e depois,
o valor da célula E5 em diante;

D5 = Complemento do Grau de Evidência Desfavorável - valor inicial 0,5 e depois
um – C6 em diante;

K4 = Fator de aprendizagem (Fa) (valores 0 até 1).

Calcula-se na célula E5 = Grau de Evidência resultante (μ_E) pela fórmula:

$$\mu_E = ((B5 - (D5) * \$K\$4) + 1) / 2$$

Com os passos apresentados foram realizadas até dez iterações (passos) e obteve resultados sucessivos até que o mesmo ficasse bem próximo de 1, mostrando assim, que essa CNAPap aprendeu o seu padrão de verdade. Os testes foram realizados no *software* aplicativo, conforme apresentado na Figura 3.

Resultados

Para essa planilha, foi inserido os mesmos valores de entrada μ_1 e μ_2 como pode ser observado no passo 0, que depois de compilados pelo algoritmo da CNAPap, geraram os resultados para o grau de evidência desfavorável (μ_2), Complemento do Grau de Evidência Desfavorável e o grau de evidência resultante (μ_E).

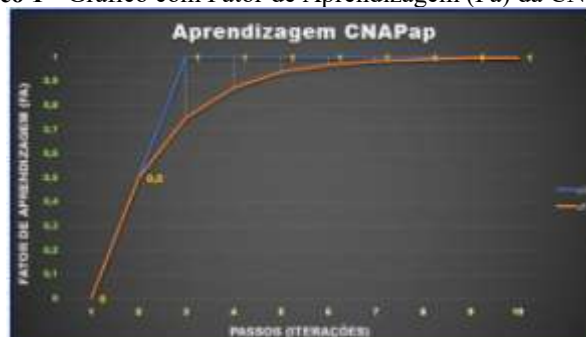
Passos	μ_1	μ_2	Graude Evidência Detectável	μ_E
1	0.5	0.5	0.5	0.5
2	0.5	0.5	0.5	0.75
3	0.5	0.5	0.5	0.875
4	0.5	0.5	0.5	0.9375
5	0.5	0.5	0.5	0.96875
6	0.5	0.5	0.5	0.984375
7	0.5	0.5	0.5	0.9921875
8	0.5	0.5	0.5	0.99609375
9	0.5	0.5	0.5	0.998046875
10	0.5	0.5	0.5	0.9990234375
11	0.5	0.5	0.5	0.99951171875
12	0.5	0.5	0.5	0.999755859375
13	0.5	0.5	0.5	0.9998779296875
14	0.5	0.5	0.5	0.99993896484375
15	0.5	0.5	0.5	0.999969482421875
16	0.5	0.5	0.5	0.9999847412109375
17	0.5	0.5	0.5	0.9999923706046875
18	0.5	0.5	0.5	0.99999618530234375
19	0.5	0.5	0.5	0.999998092651171875

Figura 3 - Fator de Aprendizagem (Fa) da CNAPap igual a 1.

De acordo com o valor do Fator de Aprendizagem (Fa) da CNAPap ajustado entre os valores 0 até 1, o grau de evidência resultante (μ_E) tende a ficar mais próximo de 1, mostrando assim, o aprendizado da CNAPa através dos seus passos.

Também foi possível a implementação de um gráfico para mostrar a curva da CNAPa de aprendizagem quando a mesma estiver com o seu Fator de Aprendizagem (Fa) igual a 1, mostrando assim a variância dos valores de entrada μ_1 e μ_2 da planilha, conforme demonstrado no Gráfico 1.

Gráfico 1 - Gráfico com Fator de Aprendizagem (Fa) da CNAPap igual a 1.



Discussão

Todos os resultados mostraram a fidelidade e o funcionamento que o fluxograma e o algoritmo CNAPap construído no *software* aplicativo possui em relação, a outros sistemas que funcionam através da mesma lógica.

Conclusão

Este trabalho apresentou o algoritmo de uma CNAPap funcionando através de *software* aplicativo baseado em uma planilha eletrônica, a fim de possibilitar o monitoramento e a interação com o aprendizado dessa CNAPa. Verificou-se que o algoritmo aplicado neste treinamento possui a vantagem de permitir que eventuais necessidades de



ajustes de controle sejam feitas antes da real aplicação. Este estudo contribui para que outras pesquisas que utilizam como base o algoritmo da CNAPap possa vir a serem feitas em aplicações distintas.

Referências bibliográficas

- [1] Da Silva Filho, J. I.; ABE, J.M.; Lambert-Torres, G. (2008). **Inteligência Artificial com as Redes de Análises Paraconsistentes – Teoria e Aplicações**, Rio de Janeiro: LTC, p. 229-233. Vol.1.
- [2] Mário, C. M.; Pompeo Ferrara, L. F.; Da Silva Filho, J. I. (2007). **Treinamento de uma Célula Neural Artificial Paraconsistente de Aprendizagem**. Revista Seleção Documental. ISSN 1809-0648, nº. 6, 2007, 11-16p.
- [3] Da Silva Filho, J. I. (2007). **Introdução às células neurais artificiais paraconsistentes**. Revista Seleção Documental. ISSN 1809-0648, nº. 8, 2007, 5-14p.