

## Aprendizado por Demonstração aplicado à um Braço Robótico utilizando Célula Neural Artificial Paraconsistente

Paulino Machado Gomes<sup>1,2</sup>, Mauricio Conceição Mario<sup>1</sup>, João Inácio da Silva Filho<sup>1</sup>,  
Leonardo do Espirito Santo<sup>2,3</sup>, Rodrigo Silvério da Silveira<sup>2,3</sup>,  
Cláudio Luís Magalhães Fernandes<sup>1,2,3</sup>

<sup>1</sup>Universidade Santa Cecília – Unisanta, PPGEMec- Programa de Pós Graduação em Engenharia Mecânica, Santos-SP, Brasil

<sup>2</sup>Faculdade de Tecnologia de São Vicente - FATEF  
Av. Presidente Wilson, 1013, Itararé, São Vicente-SP, Brasil

<sup>3</sup>Faculdade SENAI de Tecnologia Mecatrônica  
R. Santo André, 680, Boa Vista, São Caetano - SP, Brasil

E-mail: paulino.machado.g@gmail.com

**Resumo:** Neste trabalho é utilizado um algoritmo denominado de Célula Neural Artificial Paraconsistente de aprendizagem (CNAPap), que foi criado a partir das equações baseadas em Lógica Paraconsistente Anotada – LPA. A LPA é uma lógica não clássica, que é baseada em conceitos que permitem, sob certas condições, aceitar a contradição em seus fundamentos, sem invalidar as conclusões. Com sinais padronizados, repetidamente aplicados à entrada da CNAPap, é possível armazenar gradativamente esta informação, aumentando ou diminuindo seu nível de resposta, na saída com variação assintótica, e controlado por um Fator de Aprendizagem ( $F_A$ ). Foi implementado em um microcontrolador ATmega 328p, um conjunto de cinco CNAPaps, formando uma Rede Neural Artificial Paraconsistente de aprendizagem (RNAPap), e vários ensaios foram realizados, para validar o seu funcionamento, atuando no aprendizado por demonstração (LfD), em um Robô Manipulador. Os resultados de estudos comparativos, mostraram que a RNAPap possui propriedades dinâmicas, com capacidade de atuar, tanto no processo de aprendizagem por demonstração, como no processo de imitação.

**Palavras-chave:** lógica paraconsistente, controlador programável, algoritmo paraconsistente, controle de razão

### Learning by Demonstration applied to a Robotic Arm using Paraconsistent Artificial Neural Cell

**Abstract:** The Annotated Paraconsistent Logic - LPA is a non-classical logic that is based on concepts that allow, under certain conditions, to accept the contradiction in its foundations, without invalidating the conclusions. In this work, an algorithm called Paraconsistent Artificial Neural Cell of Learning (PAN Cell), which was created from equations based on LPA Logic, is used. With standardized signals repeatedly applied to the PAN Cell input, it is possible to gradually store this information, increasing or decreasing its response level at the output with asymptotic variation and controlled by a Learning Factor ( $l_F$ ). A set of five PAN Cells was implemented in an ATmega 328p microcontroller, forming a learning Paraconsistent Artificial Neural Network (PANNet) and several tests were carried out to validate its operation acting in learning by demonstration (LfD) in a Robot Manipulator. The results of comparative studies showed that PAN Cell has dynamic properties capable of acting, both in the learning process by demonstration and in the imitation process.

**Keywords:** Paraconsistent Annotated Logic; Robotics; Learning from demonstration; Artificial Intelligence; Paraconsistent Artificial Neural Network.

## Introdução

Diversas pesquisas estão sendo desenvolvidas visando tornar as máquinas mais independentes dos processos de programação por meio de sistemas especialistas, robótica autônoma e aprendizado de máquina.

Para certos modelos de controle utilizados em robótica industrial, a reprogramação para mudar tarefas de um robô pode ser custosa para a produção. Muitas vezes as novas tarefas exigem adaptações e modificações profundas no código fonte da programação. A eficiência da reprogramação deve ser confirmada por meio de diversos testes aplicados ao robô, o que resulta em paradas não programadas, trazendo prejuízos a produção [1].

### 1.1 Aprendizado por Demonstração e Lógica Paraconsistente

O Aprendizado por Demonstração, do inglês *Learning from Demonstration* (LfD), consiste em fazer com que uma máquina execute novas tarefas imitando procedimentos que lhe são apresentados, sem a necessidade de reconfiguração ou reprogramação de seu *software*. Seguindo este princípio, a pesquisa relacionada à aplicação dessa técnica visa encontrar formas eficientes de substituir o trabalho de programação manual das atividades da máquina por um processo de programação automática, conduzido exclusivamente para repetir a tarefa demonstrada por um especialista [2]. No entanto em um processo de LfD, as comparações dos dados de informação entre o Tutor (ser humano) e o Aprendiz (Robô) são contaminadas por contradições, gerando incertezas nas conclusões [3][4].

Na área da Inteligência Artificial, o método de aprendizado de máquinas é geralmente feito com algoritmos baseados em Lógica Clássica. Sabe-se que a Lógica clássica fundamenta-se em princípios estritamente binários, no entanto, em algumas situações em que a informação é incompleta, contraditória ou redundante, as incertezas contidas nos dados podem inviabilizar a sua aplicação [5][6]. Devido a sua natureza binária, a utilização de sistema desenvolvido com lógicas não clássicas pode ser um caminho promissor na área da aprendizagem de máquinas que inclui o LfD[6][7].

A Lógica Paraconsistente (PL) está classificada entre as lógicas denominadas não clássicas, que se baseia na oposição ao princípio da não contradição - um dos princípios básicos da lógica clássica. Recentemente a LP, na sua versão especial denominada Lógica Paraconsistente Anotada com anotação de dois valores - LPA2v, tem se destacado nas aplicações de seus algoritmos em diversas áreas do conhecimento [5][6][7]. Portanto, neste artigo são apresentadas novas alternativas em controle de automação que requerem aprendizado de máquina para agregar um maior nível de eficiência em LfD por meio da

implementação de estruturas algorítmicas baseadas em Lógica Paraconsistente – LPA. 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 [6] [7] 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  $\mu_1$  é o grau de evidência favorável, proveniente da primeira evidência;  $\lambda$  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.

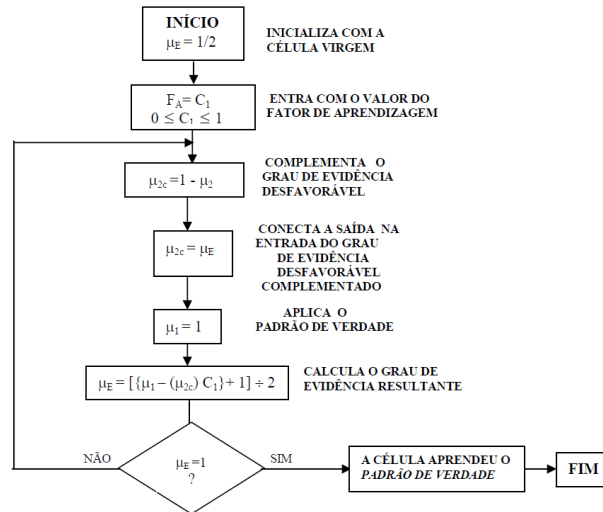
No processo de aprendizagem considera-se uma equação para cálculos de valores de Graus de Evidencia resultantes sucessivos  $\mu_{E(K)}$  até chegar ao valor 1. Portanto, para um valor de Grau de Evidencia  $\mu_{E(K)}$  inicial, são obtidos valores  $\mu_{E(K+1)}$  até que  $\mu_{E(K+1)} = 1$ . Considerando um processo de aprendizagem do *padrão de verdade* a equação de aprendizagem e obtida através da equação do cálculo do Grau de Evidencia resultante ficando[5][6][7]:

$$\frac{\mu_{E(K+1)} = \{\mu_1 - (\mu_{E(K)} C) F_A\} + 1}{2} \quad (11)$$

onde:  $\mu_{E(K)} C = 1 - \mu_{E(K)}$  sendo:  $0 \leq F_A \leq 1$  (12)

Considera-se a Célula completamente treinada quando  $\mu_{E(K+1)} = 1$ .

O fator de aprendizagem  $F_A$  é um valor real, dentro do intervalo fechado [0,1] atribuído arbitrariamente por ajustes externos. Conforme e visto pela equação do cálculo do Grau de Evidencia resultante  $\mu_{E(K+1)}$ , quanto maior e o seu valor, maior e a rapidez de aprendizado da Célula. O fluxograma e algoritmo de aprendizagem e apresentado na Figura 1.



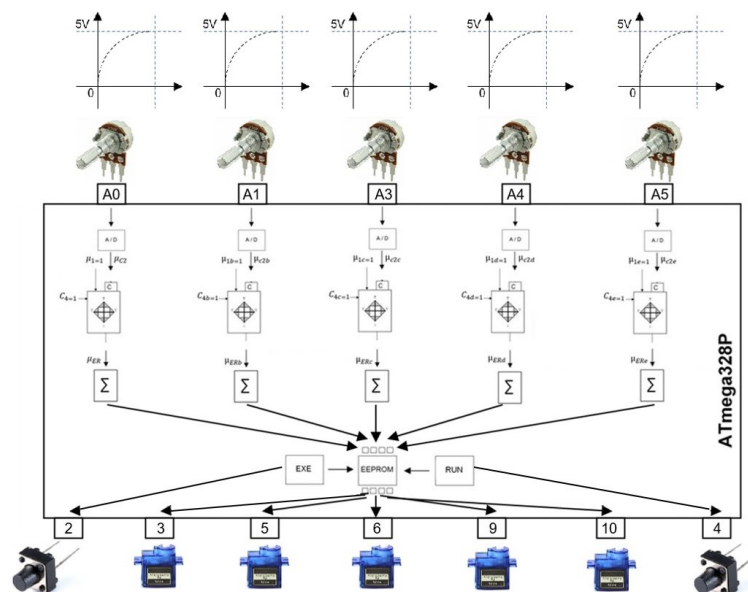
**Figura 1.** Fluxograma para aprendizagem do *padrão de Verdade* da CNAPap.

O *aprendizado da demonstração*, também conhecido como "*programação por demonstração*", tem como objetivo substituir a programação manual demorada de um robô por um processo de programação automática que é feito exclusivamente em um especialista (tutor) mostrar ao robô (aprendiz) a tarefa que este deve imitar [5][6][7].

**Objetivos:** O objetivo deste trabalho é apresentar o método de aprendizagem por demonstração aplicado em um Robô Manipulador onde o algoritmo de aprendizagem é a CNAPap.

**Material e Métodos**

Inicialmente foi implementada uma Rede Neural Artificial Paraconsistente de aprendizagem - RNAPap composta de 5 CNAPs, conforme mostrada na figura 2.



**Figura 2.** Rede Neural Artificial Paraconsistente de aprendizagem – RNAPap.

## Resultados e Discussão

Através da técnica de tele operação, com o acionamento do potenciômetro, se estabeleceu o estado de  $LfD$ , onde foi aplicado  $n$  vezes o padrão  $\mu 2$  na entrada da CNAPap, até o aprendizado ser completado. Após este processo, o Braço Robótico foi colocado no estado de “Imitação”, onde os dispositivos acionaram, os servos motores das juntas, movimentando-as até completar a tarefa.

## Conclusões

A implementação do sistema de aprendizado por demonstração ( $LfD$ ) por meio de uma Rede Neural Artificial Paraconsistente de aprendizagem RNAPap composta de 5 CNAPs, **conforme** mostrada neste trabalho, apresentou um novo método fundamentado em uma lógica não clássica. A técnica mostra inovação na área de robótica e apresenta bons resultados o que a coloca como boa alternativa para utilização em robôs industriais. Verificou-se que, o RNAPap demonstrou capacidade de aprender e guardar padrões, fazendo o braço robótico reproduzir tarefas que foram anteriormente demonstradas, trazendo certas características similares as do cérebro humano.

## Referências

1. Rosário, J. M. (2009) Automação Industrial. São Paulo: Editora: Baraúna. 2009. 517 págs. ISBN-13: 978-8579230004
2. Mohseni-Kabir, A.; Rich, C.; Chernova, S.; Sidner, C. L.; Miller, D. (2015). Interactive hierarchical task learning from a single demonstration. In *Proceedings of the Tenth Annual - ACM/IEEE International Conference on Human-Robot Interaction, HRI '15*, 2015, 205–212. New York, NY, USA: ACM

3. Ijspeert, A.J.; Nakanishi, J.; Schaal, S. (2002). Learning rhythmic movements by demonstration using nonlinear oscillators. In Proceedings of the IEEE/RSJ Int. Conference on Intelligent Robots and Systems (IROS2002), 2002, pages 958-963.
4. Pastor, P.; Kalakrishnan, M.; Meier, F.; Stulp, F.; Buchli, J.; Theodorou, E.; Schaal, S. (2013). From dynamic movement primitives to associative skill memories. *Robotics and Autonomous Systems*, 2013, vol. 61, no. 4, pp. 351–361.
5. Abe, J. M., Akama, S., Nakamatsu, K., Da Silva Filho, J.I. (2018). Some Aspects on Complementarity and Heterodoxy in Non-Classical Logics. *Procedia Computer Science*, 126, pp. 1253–1260. <https://doi.org/10.1016/j.procs.2018.08.068>
6. Da Silva Filho, J.I.; Abe, J.M.; Marreiro, A.d.L.; Martinez, A.A.G.; Torres, C.R.; Rocco, A.; Côrtes, H.M.; Mario, M.C.; Pacheco, M.T.T.; Garcia, D.V.; Blos, M.F. (2021) Paraconsistent annotated logic algorithms applied in management and control of communication network routes *Sensors*, 21(12), 4219 <https://doi.org/10.3390/s21124219>
7. Mario, M. C., Garcia, D. V., Da Silva Filho, J. I., Silveira Júnior, L., Barbuy, H. S. (2021). Characterization and classification of numerical data patterns using Annotated Paraconsistent Logic and the effect of contradiction. *Research, Society and Development, [S. l.]*, v. 10, n. 13, p. e283101320830, DOI: 10.33448/rsd-v10i13.20830.