

ALGORITMOS BIOINSPIRADOS OTIMIZAM CONTROLADOR COM MAPEAMENTO COGNITIVO FUZZY DE MIXER INDUSTRIAL

Data de aceite: 01/12/2023

Márcio Mendonça

Universidade Tecnológica Federal do
Paraná
PPGEM-CP - Programa de Pós-
Graduação em Engenharia Mecânica PP/
CP
Cornélio Procópio - PR
<http://lattes.cnpq.br/5415046018018708>

Fabio Rodrigo Milanez

Faculdade da Industria Senai
Departamento Acadêmico de Engenharia
Elétrica-
Londrina -PR
<http://lattes.cnpq.br/3808981195212391>

Michelle Eliza Casagrande Rocha

Engenheira Telecomunicações -
Universidade Norte do Paraná – Unopar
– Kroton –
Londrina-PR
<http://lattes.cnpq.br/4411484670091641>

Marcio Jacometti

Universidade Tecnológica Federal do
Paraná
Departamento acadêmico das ciências
humanas e sociais aplicadas (DACHS)
Cornélio Procópio – PR
<http://lattes.cnpq.br/8509336134084374>

Vicente de Lime Gongora

Faculdade da Indústria SENAI Londrina
Departamento Acadêmico de Engenharia
Elétrica-
Londrina -PR
<http://lattes.cnpq.br/3808981195212391>

Marcos Antônio de Matos Laia

Departamento De Ciência Da Computação
– UFSJ
Minas Gerais - MG
<http://lattes.cnpq.br/7114274011978868>

Emerson Ravazzi Pires da Silva

Universidade Tecnológica Federal do
Paraná
Departamento Acadêmico de Engenharia
Elétrica (DAELE)
Cornélio Procópio – PR
<http://lattes.cnpq.br/3845751794448092>

Kazuyochi Ota Junior

Mestre - PPGEM-CP - Programa de Pós-
Graduação Multicampi em Engenharia
Mecânica
Cornélio Procópio - PR
<http://lattes.cnpq.br/3845751794448092>

Augusto Alberto Foggiano

Departamento de Odontologia – UENP
Jacarezinho - PR
<http://lattes.cnpq.br/0580089660443472>

Fabio Nogueira de Queiroz

Centro Paula Souza
Departamento Computação-FATEC Ourinhos
Ourinhos – SP
<http://lattes.cnpq.br/4466493001956276>

Luiz Francisco Sanches Buzachero

Universidade Tecnológica Federal do Paraná
Departamento de Engenharia Elétrica – Daele
Cornélio Procópio - PR
<http://lattes.cnpq.br/1747856636744006>

Andre Luis Shiguemoto

Universidade Tecnológica Federal do Paraná
Departamento de Engenharia Elétrica – Daele
Cornélio Procópio - Pr
<http://lattes.cnpq.br/9243656534211182>

Guilherme Cyrino Geromel

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo – IFSP
Piracicaba-SP
<http://lattes.cnpq.br/7535398878830738>

Bruno Oliveira Rosa

Universidade Tecnológica Federal do Paraná
Acadêmico - Departamento de Engenharia Elétrica – Daele
Cornélio Procópio - Pr
<http://lattes.cnpq.br/5010826876808074>

João Roberto Sartori Moreno

Universidade Tecnológica Federal do Paraná
PPGEM-CP - Programa de Pós-Graduação em Engenharia Mecânica PP/CP
Cornélio Procópio - PR
<http://lattes.cnpq.br/2121271692037520>

Gustavo Henrique Bazan

Instituto Federal do Paraná
Campus Jacarezinho
Jacarezinho - PR
<http://lattes.cnpq.br/7076940949764767>

Luiz Antonio Costa

Uninter
Acadêmico – Engenharia Produção
Ourinhos-SP
<https://lattes.cnpq.br/1864248410546085>

Henrique Cavalieri Agonilha

Universidade Filadélfia (Unifil)

Londrina - PR

<http://lattes.cnpq.br/9845468923141329>

Carlos Alberto Paschoalino

Universidade Tecnológica Federal do Paraná

Departamento de Engenharia Elétrica – Daele

Cornélio Procópio - Pr

<http://lattes.cnpq.br/0419549172660666>

RESUMO: Em instalações industriais, é comum a existência de processos multivariáveis com fortes interações entre suas variáveis. Além disso, existem não linearidades e, em alguns casos, com objetivos de controle conflitantes. Neste contexto, este trabalho foca-se na aplicação de algoritmos bioinspirados para a otimização off-line de um mapa cognitivo fuzzy dinâmico (DFCM) no controle inteligente de um misturador industrial. O controlador DFCM é baseado no aprendizado de Hebb. Algoritmos bioinspirados são inspirados em processos biológicos ou naturais. Eles são frequentemente usados em problemas de otimização, pois são capazes de encontrar soluções de alta qualidade em problemas complexos. Alguns exemplos de algoritmos bioinspirados incluem algoritmos genéticos, algoritmos de colônia de formigas e algoritmos de enxame de abelhas. Mapas cognitivos fuzzy são modelos de aprendizado automático que podem ser usados para representar o conhecimento de um sistema. Eles são compostos por um conjunto de nós que representam variáveis do sistema e um conjunto de conexões que representam as relações entre essas variáveis. Os pesos das conexões são usados para representar a força das relações. Controle inteligente é um campo da engenharia que se concentra no uso de métodos inteligentes para controlar sistemas. Ele pode ser usado para melhorar o desempenho, a confiabilidade e a eficiência dos sistemas. O objetivo deste trabalho é avaliar o desempenho de algoritmos bioinspirados para a otimização *off-line* de um mapa cognitivo fuzzy dinâmico (DFCM) no controle inteligente de um misturador industrial. O DFCM foi treinado usando um conjunto de dados de simulação de um misturador industrial. O conjunto de dados incluiu informações sobre as entradas e saídas do misturador. Os algoritmos bioinspirados foram usados para otimizar os pesos do DFCM. Os resultados mostraram que os algoritmos bioinspirados foram capazes de melhorar o desempenho do DFCM. O DFCM otimizado foi capaz de alcançar uma mistura mais uniforme do que o DFCM não otimizado. Este trabalho mostrou que os algoritmos bioinspirados podem ser usados para melhorar o desempenho de mapas cognitivos fuzzy dinâmicos (DFCM) no controle inteligente de misturadores industriais. Este trabalho se encerra com uma conclusão e endereça futuros trabalhos.

PALAVRAS-CHAVE: Mapas Cognitivos Fuzzy Dinâmicos; Misturador Industrial; Algoritmos Bioinspirados; Controle Inteligente.

BIO-INSPIRED EVOLUTIONARY ALGORITHMS APPLIED TO OFF-LINE OPTIMIZATION OF A FUZZY COGNITIVE MAP OF AN INDUSTRIAL MIXER

ABSTRACT: In industrial facilities, it is common to find multivariable processes with strong interactions between their variables. Additionally, there are nonlinearities and, in some cases, conflicting control objectives. In this context, this work focuses on the application of bio-inspired algorithms for the off-line optimization of a dynamic fuzzy cognitive map (DFCM) in the intelligent control of an industrial mixer. The DFCM controller is based on Hebbian learning. Bio-inspired algorithms are inspired by biological or natural processes. They are often used in optimization problems, as they can find high-quality solutions to complex problems. Some examples of bio-inspired algorithms include genetic algorithms, ant colony algorithms, and bee swarm algorithms. Fuzzy cognitive maps are machine learning models that can be used to represent the knowledge of a system. They are composed of a set of nodes that represent system variables and a set of connections that represent the relationships between those variables. The weights of the connections are used to represent the strength of the relationships. Intelligent control is a field of engineering that focuses on the use of intelligent methods to control systems. It can be used to improve the performance, reliability, and efficiency of systems. The objective of this work is to evaluate the performance of bio-inspired algorithms for the off-line optimization of a dynamic fuzzy cognitive map (DFCM) in the intelligent control of an industrial mixer. The DFCM was trained using a simulation dataset of an industrial mixer. The dataset included information about the inputs and outputs of the mixer. Bio-inspired algorithms were used to optimize the weights of the DFCM. The results showed that bio-inspired algorithms were able to improve the performance of the DFCM. The optimized DFCM was able to achieve a more uniform mixture than the non-optimized DFCM. This work showed that bio-inspired algorithms can be used to improve the performance of dynamic fuzzy cognitive maps (DFCMs) in the intelligent control of industrial mixers. This paper ends with a conclusion and addresses future work.

KEYWORDS: Dynamic Fuzzy Cognitive Maps; Industrial Mixer; bio-inspired evolutionary algorithms. Intelligent Control.

1 | INTRODUÇÃO

Na natureza, a sobrevivência de indivíduos está fortemente relacionada com a adaptabilidade dos seres à competição por recursos. Em outras palavras, os indivíduos mais bem adaptados à competição por recursos, sobrevivem. Deste modo, adaptar-se às variações do ambiente é imprescindível para garantir a sobrevivência dos indivíduos.

A natureza é uma fonte rica de inspiração para a engenharia e a ciência. Sistemas naturais como a evolução, o crescimento de plantas e a locomoção de animais foram estudados e replicados em sistemas artificiais. Esses sistemas bioninspirados têm o potencial de resolver problemas de maneiras inovadoras e eficientes.

Com base na evolução biológica, John Holland publicou o livro «*Adaptation in Natural, and Artificial Systems*» (HOLLAND, 1992), considerado atualmente a referência básica sobre Algoritmos Genéticos (AGs).

Os AGs são inspirados no processo evolutivo natural, no qual as mutações e a

seleção natural atuam sobre os indivíduos de uma população para gerar indivíduos mais adaptados ao ambiente. Os AGs simulam esse processo em um computador, utilizando uma população de soluções candidatas a um problema.

Desde então, esses algoritmos vêm sendo aplicados com sucesso em problemas do mundo real relacionados a busca e otimização (STACH et al., 2005).

De um modo geral, AGs são um tipo de sistema bionspirado que é inspirado na evolução natural. Na evolução natural, os organismos passam por um processo de seleção natural, onde os organismos melhor adaptados ao seu ambiente têm mais chances de sobreviver e se reproduzir. Os AGs simulam esse processo usando uma população de indivíduos, cada um dos quais representa uma possível solução para um problema.

A cada geração, os indivíduos da população são avaliados de acordo com sua qualidade. Os indivíduos mais bem avaliados são selecionados para se reproduzir, e seus genes são combinados para criar uma geração de indivíduos. Uma pequena quantidade de mutação também é introduzida na população para garantir que a diversidade seja mantida.

Os AGs trabalham com uma busca estocástica, onde o espaço de busca é percorrido baseando-se em transições probabilísticas (GOLDBERG, 1989).

De modo geral, os AGs possuem quatro características que difere seu método de busca e otimização dos métodos tradicionais, sendo elas (GOLDBERG, 1989):

- Fazem uso de uma codificação do conjunto de parâmetro e não os próprios parâmetros;
- Operam em uma população e não em um único ponto;
- Usam informações do valor da função custo e não informações sobre derivadas da função de otimização;
- Utilizam regras de transição probabilísticas ao invés de determinísticas.

Os AGs são formados por uma população de indivíduos e um conjunto de operadores sobre a população. Segundo as teorias evolucionárias, as quais foram base para o desenvolvimento dos AGs, os elementos mais bem adaptados ao seu meio têm maior probabilidade de sobreviver e de se reproduzir, transmitindo seu material genético para as próximas gerações. Um AG é composto basicamente por quatro etapas:

1. Geração da população inicial;
2. Avaliação de cada elemento da população;
3. Seleção dos melhores elementos da população;
4. Manipulação genética, através dos operadores de cruzamento e mutação, de forma a criar uma nova população.

Após a realização de todas as etapas citadas, um laço retorna ao passo 2 enquanto um determinado critério de parada não for atingido. Destaca-se que a aplicação de AGs requer conhecimento prévio do problema abordado (STACH et al., 2005) simple,

and powerful tool for simulation and analysis of dynamic systems. They were originally developed in 1980 by Kosko, and since then successfully applied to numerous domains, such as engineering, medicine, control, and political affairs. Their popularity stems from simplicity and transparency of the underlying model. At the same time FCMs are hindered by necessity of involving domain experts to develop the model. Since human experts are subjective and can handle only relatively simple networks (maps, e, que, determine os parâmetros iniciais como função de avaliação, número de indivíduos na população inicial, porcentagens de operadores, nem sempre é trivial.

Desta forma, ajustes empíricos, técnicas de refinamento, experiência no uso da ferramenta, agregados ao conhecimento do problema conduzem a resultados satisfatórios. Outro fator relevante está na criação de diferentes tipos de indivíduos, e na utilização de operadores que garantam que as sucessivas gerações sempre contenham soluções factíveis dentro do espaço de busca do problema (COPPIN, 2004).

AGs são frequentemente usados para resolver problemas de otimização. Em um problema de otimização, o objetivo é encontrar a solução que melhor atende a um determinado conjunto de critérios. Os AGs são capazes de resolver problemas de otimização que são difíceis ou impossíveis de resolver usando métodos tradicionais.

Algumas aplicações de AGs incluem:

- Otimização de processos industriais
- Planejamento de recursos
- Alocação de ativos
- Design de produtos
- Detecção de anomalias

Exemplos de aplicações de AGs

- Otimização de processos industriais: Os AGs podem ser usados para otimizar processos industriais, como a produção de bens e serviços. Por exemplo, os AGs podem ser usados para encontrar a configuração ideal de uma máquina ou para otimizar o fluxo de materiais em uma fábrica Bäck, T., Fogel, D. B., & Michalewicz, Z. (1997), como é empregado nesse trabalho otimizando um controlador D-FCM.

Entretanto, o maior problema do uso de métodos que empregam heurísticas de busca, como é o caso dos AGs e da *Particle Swarm Optimization* (PSO) é que não existe nenhuma garantia da obtenção de um ponto de mínimo (ou máximo) global (KENNEDY; EBERHART, 1995). Dessa forma, um algoritmo busca, seja ele um AG ou outra metaheurística, pode convergir para um ponto de ótimo local da função de avaliação, que não necessariamente corresponde à solução ótima do problema.

No desenvolvimento do trabalho será apresentado o uso de AGs para ajustar as

relações causais de um controlador por meio de uma proposta de evolução do Mapas Cognitivos *Fuzzy* (FCM) clássico, denominado Mapas Cognitivos *Fuzzy* Dinâmicos (DFCM), para o controle de um tanque misturador industrial).

2 | FUZZY COGNITIVE MAPS

Os mapas cognitivos difusos (FCMs) são uma ferramenta de modelagem baseada em conhecimento que pode ser usada para representar e analisar sistemas complexos. FCMs são compostos de um conjunto de conceitos, que representam variáveis ou entidades no sistema, e um conjunto de relações, que representam as interações entre os conceitos (ZHOU, X., LIU, B. 2011).

A origem dos FCM é apresentada por Kosko (1986) como uma base de conhecimentos metodológicas para modelagem e simulação de sistemas dinâmicos. Eles surgiram a partir de mapas cognitivos que foram inicialmente propostos por Axelrod (1976) para representar palavras, ideias, tarefas ou outros itens ligados a um conceito central e dispostos radialmente em volta deste conceito.

Aplicações

Os FCMs possuem aplicações em diferentes áreas de conhecimento, como:

- Engenharia: controle de processos, planejamento de produção, design de produtos e serviços
- Medicina: diagnóstico, prognóstico, tratamento
- Ciências sociais: economia, política, psicologia
- Ciências naturais: meteorologia, oceanografia, climatologia

Estruturalmente, um FCM pode ser representado por dígrafos diretos Fuzzy com realimentação, vistos como uma coleção de unidades processadoras neurais e relacionadas por pesos. Desse modo, um sistema pode ser modelado convenientemente em termos de conceitos e as relações de casualidade entre eles (SMITH, MENCZER, 2007).

como por exemplo, médica, controle de processos em engenharia, entre outras.

Estruturalmente, um FCM pode ser representado por dígrafos diretos Fuzzy com realimentação, vistos como uma coleção de unidades processadoras neurais e relacionadas por pesos. Desse modo, um sistema pode ser modelado convenientemente em termos de conceitos e as relações de casualidade entre eles (NAPOLES *et al.*, 2017).

Para o trabalho abordado neste capítulo, duas populações (soluções) iniciais para o AG foram comparadas, de acordo a faixa de valores aceita para as relações causais do DFCM e outra baseando-se no conhecimento parcial da solução desejada.

O objetivo principal do trabalho é verificar que o conhecimento prévio da faixa de valores das relações causais ocasiona em convergência mais rápida para os AGs em comparação com uma população inicial totalmente aleatória.

Para o AG, o critério de parada desejado para a evolução de uma nova população é definido pela adequabilidade da solução de acordo com uma função definida pelo operador, chamada fitness (GOLDBERG, 1989). Neste trabalho, a função fitness é dada pelo erro quadrático da abertura desejada para as duas válvulas controladas, sabendo-se que os valores ideais são 44% para V1 e 42% pra V2.

Um conhecimento prévio do problema pode ser necessário para a utilização de AGs (STACH *et al.*, 2005) simple, and powerful tool for simulation and analysis of dynamic systems. They were originally developed in 1980 by Kosko, and since then successfully applied to numerous domains, such as engineering, medicine, control, and political affairs. Their popularity stems from simplicity and transparency of the underlying model. At the same time FCMs are hindered by necessity of involving domain experts to develop the model. Since human experts are subjective and can handle only relatively simple networks (maps, demonstrado nesse caso para a escolha da população (solução) inicial do problema em estudo.

A população inicial pode ser definida de duas maneiras diferentes, comparadas nesse trabalho: na primeira, a população inicial é gerada aleatoriamente. A outra forma utiliza métodos heurísticos relacionados a características específicas do problema (STACH *et al.*, 2005) simple, and powerful tool for simulation and analysis of dynamic systems. They were originally developed in 1980 by Kosko, and since then successfully applied to numerous domains, such as engineering, medicine, control, and political affairs. Their popularity stems from simplicity and transparency of the underlying model. At the same time FCMs are hindered by necessity of involving domain experts to develop the model. Since human experts are subjective and can handle only relatively simple networks (maps. As vantagens da segunda opção são a melhora da resposta e vantagens da segunda opção são melhora da resposta e do tempo para alcançá-la. Entretanto, nesse método há probabilidade de retenção da solução em um máximo ou mínimo local, prejudicando a qualidade da solução (REEVES; ROWE, 2002).

3 | METODOLOGIA

Para demonstrar a evolução de um DFCM por meio de AGs, pode ser exemplificado em o estudo [6] para testar nível de controladores. Este caso foi selecionado para ilustrar a necessidade de refinamento de um modelo baseado em FCM construído exclusivamente com o conhecimento. O sistema a ser controlado consiste em um misturador industrial (SOUZA *et al.*, 2017) com duas válvulas de entrada (V1 e V2) de ar para diferentes líquidos, uma válvula de saída (V3) para a remoção de líquido produzido por mistura e medidor de densidade, que mede a qualidade do líquido produzido. O processo apresenta um controle de faixa para o volume e o peso do líquido e um seguidor de *setpoint* para V3.

As válvulas (V1) e (V2) inserem dois líquidos diferentes no tanque. Durante a reação

dos dois líquidos, um novo líquido é caracterizado pelo seu valor de densidade que é produzido. Neste instante a válvula (V3) esvazia o reservatório de acordo com um fluxo de saída de campanha, mas a mistura líquida deve estar nos níveis especificados.




Figura 1 – Controlador DFCM

Para sua modelagem, utilizou-se uma população de 30 indivíduos, com cruzamento simples (torneio) e 1% de mutação. Nesse trabalho serão comparados dois casos, um que utiliza os valores encontrados no trabalho (SOUZA *et al.*, 2017) (abordagem 1) e outro que utiliza metade desses valores, considerando o conhecimento prévio dos autores sobre o processo em análise (abordagem 2).

Para cada uma das abordagens foram realizadas 100 simulações. Isso devido ao fato de que o AG é uma técnica probabilística de otimização, ou seja, não há garantia de solução ótima. Nesse sentido, a comparação entre as abordagens é definida por meio do menor erro relativo ao decorrer de todas as simulações. A Figura 1 apresenta o controlador DFCM modelado para o sistema estudado. Na qual, W são os valores para as relações causais entre os conceitos, evoluídas de forma *off-line* com o AG e *on-line* por meio do algoritmo de Hebb (SOUZA *et al.*, 2017).

4 | RESULTADOS

As melhores soluções encontradas para as duas abordagens utilizadas, relativas as 100 simulações, são apresentadas nas Figuras 2 e 3.






Figura 2a. Evolução do AG, V1 e V2 – Figura 2b. Evolução do AG, V1 e V2


As Figuras 2a e 2b— são respectivamente abordagem 1 e 2. Ressalta-se que a solução na abordagem 2 foi mais rápida, usou menos gerações, em outras palavras. Entretanto, os resultados da abordagem 2 foram mais promissores.

Pode-se observar que, além da evolução mais rápida da abordagem 2, o conhecimento prévio da faixa de valores, em que se encontra a solução, resultou também em melhores resultados.

Na Figura 3, é apresentado o histograma com os erros obtidos para as duas abordagens, comprovando os melhores resultados para a abordagem 2. É possível notar que as ocorrências dos erros para a abordagem 2 estão relativamente mais próximas a zero, com valor máximo na ordem de 0,03.



(a) Erro - abordagem 1



(b) Erro - abordagem 2

Figura 3 - Histograma para abordagens 1 e 2

5 | CONCLUSÕES

Os resultados das simulações foram promissores, e demonstram que o conhecimento prévio da faixa de valores das relações causais (abordagem 2), na abordagem 2, os pesos das relações causais foram inicializados dentro de uma faixa de valores, baseada em conhecimento prévio do sistema. O que ocasiona em uma convergência mais rápida para o AG em comparação com uma população inicial totalmente aleatória (abordagem 1). É possível observar também que a abordagem 2 obteve a melhor distribuição de erros, como mostrado na Figura 3.

Como futuros trabalhos, sugere-se investigar a combinação de diferentes configurações do AG, como outros tipos de cruzamento e maior número de indivíduos, com outros métodos de otimização, como por exemplo, *simulated annealing*.

REFERÊNCIAS

AXELROD, R. **Structure of decisions: the cognitive maps of political elites**. 1. ed. Princeton, NJ, USA: Princeton University Press, 1976.

BÄCK, T., FOGEL, D. B., & MICHALEWICZ, Z. **Handbook of evolutionary computation**. Springer, 1997.

COPPIN, B. **Artificial Intelligence Illuminated**. 2. ed. Burlington, MA, USA: Jones & Bartlett Learning, 2004.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization, and Machine Learning**. 1. ed. Boston, MA: Addison-Wesley Longman Publishing Co., Inc., 1989.

HOLLAND, J. H. **Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control and Artificial Intelligence**. 1. ed. Cambridge, USA: MIT Press, 1992.

KENNEDY, J.; EBERHART, R. **Particle swarm optimization**. Proceedings of ICNN'95 - International Conference on Neural Networks. Perth, WA, Australia, Australia: IEEE, 1995

KOSKO, B. **Fuzzy cognitive maps**. International Journal of Man-Machine Studies, v. 24, n. 1, p. 65–75, 1986.

NAPOLES, G. *et al.* **Fuzzy Cognitive Maps Tool for Scenario Analysis and Pattern Classification**. 2017 IEEE 29th International Conference on Tools with Artificial Intelligence (ICTAI). Boston, MA, USA: IEEE, 2017 Disponível em: <<https://ieeexplore.ieee.org/document/8372006/>>

REEVES, C. R.; ROWE, J. E. **Genetic Algorithms: Principles and Perspectives - A Guide to GA Theory**. 1. ed. New York, USA: Springer US, 2002.

SOUZA, L. B. DE *et al.* **Dynamic Fuzzy Cognitive Maps Embedded and Classical Fuzzy Controllers Applied in Industrial Process**. ICAS 2017 : The Thirteenth International Conference on Autonomic and Autonomous Systems. Barcelona, Spain: IARIA, 2017

SMITH, J. Q., & MENCZER, F. (2007). Fuzzy cognitive maps: **A survey**. In **Proceedings of the 2007 ACM SIGKDD international conference on Knowledge discovery and data mining** (pp. 1197-1206). ACM.

STACH, W. *et al.* **Genetic learning of fuzzy cognitive maps**. *Fuzzy Sets and Systems*, v. 153, n. 3, p. 371–401, 1 ago. 2005.

ZHOU, X., & LIU, B. (2011). Fuzzy cognitive maps: **A survey of applications**. *International Journal of Intelligent Systems*, 26(10), 1076-1106.