

Controle inteligente de processos industriais: fermentador alcoólico

Thiago Rossato Francisco, Márcio Mendonça, Lucas Botoni de Souza, Thiago Martinhago Minato

Resumo: Este trabalho aborda o uso de controladores adaptativos por meio de mecanismo de ajuste inteligente FCM-PID para o controle de um processo de fermentação alcoólica. Os resultados das integrais do erro quadrático (ISE), erro ponderado no tempo (ITAE), máximo sobressinal e tempo de acomodação foram comparados entre as diferentes técnicas de controle empregadas. Para isso, foram escolhidas metodologias baseadas no conhecimento especialista do sistema, Mapas Cognitivos Fuzzy e lógica Fuzzy clássica, tornando a modelagem dos controladores menos dependente do conhecimento do modelo dinâmico do processo analisado.

Palavras chave: Processos Industriais, Mapas Cognitivos Fuzzy, Controle Inteligente, Fermentador alcoólico.

Intelligent control of industrial processes: alcoholic fermenter

Abstract: This work addresses the use of adaptive controllers by means of intelligent tune mechanism FCM-PID of an alcoholic fermentation process control. The integral square error (ISE) and time-weighted absolute error (ITAE), overshoot and settling time results were compared among different techniques used. For this, methodologies based on the system expert knowledge, Fuzzy Cognitive Maps and classical Fuzzy logic were chosen, making controller modeling less dependent on knowledge of the dynamic model of the analyzed process.

Key-words: Industrial Processes, Fuzzy Cognitive Maps, Intelligent Control, Alcoholic Fermenter.

1. Introdução

Com o crescente número de entradas e saídas dos sistemas de controle moderno, aumentando assim sua complexidade, a teoria clássica de controle tornou-se insuficiente para a resolução desses problemas, uma vez que trata de sistemas com uma entrada e uma saída (OGATA, 2010). Nesse trabalho, foram estudados foram utilizados métodos de controle inteligente para a adaptação dos ganhos de um controlador PID clássico.

A história do controle adaptativo surge na década de 60, possibilitando o tratamento de sistemas complexos no domínio do tempo a partir de variáveis de estado, proporcionando uma ampla pesquisa nessa área por meio do advento dos computadores digitais. A partir da análise dos sistemas de controle modernos, nota-se que o controle linear se torna insuficiente quando as condições de funcionamento de um sistema não são fixas, flutuando em mais de um ponto de operação. Assim, um dos objetivos do controle adaptativo é de compensar variações dos parâmetros de sistemas de controle não-lineares que, de modo geral, são uma interconexão de componentes formando uma configuração que produz uma resposta desejada (ÅSTRÖM; WITTENMARK, 2008).

Uma ferramenta importante para auxiliar no controle de sistemas complexos são os sistemas computacionais inteligentes. Sua vantagem consiste no fato de que podem ser utilizados quando não se tem totalmente o modelo matemático do processo. Isso implica em uma modelagem por meio de conhecimento humano, como o de especialistas e operadores. De modo específico, esse trabalho busca investigar a aplicação de sistemas baseados em

lógica Fuzzy clássica (por meio de conhecimento especialista) e Mapas Cognitivos Fuzzy (FCM).

Nesses processos onde ocorrem incerteza de informações, a tática de controle utilizada pode ser de natureza imprecisa, comumente expressa em termos linguísticos, principalmente quando a complexidade de obtenção de um modelo matemático do sistema for elevada. Desse modo, partindo de conceitos Fuzzy, pode-se modelar essas informações a partir dos dados provenientes da operação de um sistema, podendo se obter também outros dados e, com isso, sua manipulação pode ser realizada através de procedimentos de identificação e modelagem de sistemas, como o processo heurístico utilizado nesse trabalho (PASSINO; YURKOVICH, 1998).

A heurística consiste na capacidade de possibilitar a elaboração de uma função de entrada versus saída de maneira linguística. A vantagem de sua abordagem é a facilidade de compreensão, visto que se baseiam mais no senso comum do que na matemática. Sua conveniência se dá quando pretende-se desenvolver um algoritmo para a modelagem, de forma estruturada, de conhecimento de especialistas, no caso dos FCMs, e por meio de regras no Fuzzy clássico, construindo as tomadas de decisões. Entretanto, a princípio, soluções deste tipo não fornecem nenhuma garantia da melhor solução, porém proporcionam um atalho em relação a custo e tempo (ROSS, 2010).

Este trabalho aborda a síntese de controlador inteligente aplicado ao controle de um processo de fermentação alcoólica inicialmente proposto por Maher (1995), abrangendo a construção de uma arquitetura de controle a partir de um PID adaptativo nos ganhos proporcional e derivativo (K_p e K_d) por um mecanismo de ajuste FCM-PID. Para a inserção do mecanismo de ajuste inteligente, primeiramente um PID clássico foi ajustado de forma híbrida, inicialmente pelo método de Ziegler-Nichols, e a posteriori refinado empiricamente a partir da análise do processo.

No processo, o PID tem como função realizar a abertura e/ou fechamento das válvulas de entrada (*Fin*) e de saída (*Fout*). A parcela adaptativa do controlador, tanto com Fuzzy quanto com FCM, tem atuação exclusiva na válvula de saída. A válvula *Fin* controla o fluxo de substrato no tanque e a válvula *Fout* controla o fluxo de produto retirado da cuba.

O mecanismo de ajuste FCM, a partir dos erros em regime, derivativo e integral, passam os parâmetros de ganho proporcional e derivativo (K_p e K_d) para o controlador PID ajustado previamente, e o ganho integral foi (K_i) mantido constante.

A partir das equações descritivas do processo, a simulação do sistema foi realizada no software Matlab®. Com isso, a partir do processo e do PID discretizados, foram aplicados os mecanismos de ajuste inteligentes para comparação de resultados através da análise dos critérios da integral do erro absoluto ponderado no tempo (*ITAE*), integral do erro quadrático (*ISE*), máximo sobressinal (*Overshoot*), tempo de acomodação (*Ta*), e também de complexidade computacional, como tempo de execução das simulações.

2. Fundamentação teórica

2.1 Engenharia de Produção

A engenharia de produção é uma combinação de tecnologia de fabricação, ciências da engenharia e ciência da administração. Um engenheiro de produção normalmente possui um amplo conhecimento das práticas de engenharia e está ciente dos desafios de

gerenciamento relacionados à produção. O objetivo é realizar o processo de produção da maneira mais suave, criteriosa e econômica possível.

A engenharia de produção abrange a aplicação de peças fundidas, processamento de usinagem, processos de união, corte de metais e design de ferramentas, metrologia, máquinas-ferramentas, sistemas de usinagem, automação, gabaritos e acessórios, design de moldes e matrizes, ciência de materiais, design de peças de automóveis e design de máquinas e fabricação. A engenharia de produção também se sobrepõe substancialmente à engenharia de fabricação e engenharia industrial. Os nomes são frequentemente intercambiáveis.

Na indústria, uma vez realizado o projeto, os conceitos de engenharia de produção referentes a estudo de trabalho, ergonomia, pesquisa operacional, gerenciamento de fabricação, gerenciamento de materiais, planejamento de produção etc. desempenham papéis importantes em processos de produção eficientes. Eles lidam com design integrado e planejamento eficiente de todo o sistema de fabricação, que está se tornando cada vez mais complexo com o surgimento de métodos sofisticados de produção e sistemas de controle (OGATA, 2010).

2.1 Mapas Cognitivos Fuzzy

Os Mapas Cognitivos Fuzzy (FCM) são compostos de uma metodologia que combina as vantagens das RNAs e da lógica Fuzzy clássica, utilizando conhecimento já existente e experiência humana para modelagem de sistemas complexos (PAPAGEORGIOU, 2014).

Os FCMs surgiram a partir do trabalho de Kosko (1986), que ampliou os conceitos dos mapas cognitivos de Axelrod (1976), que usava grafos ponderados e direcionados para relacionar contextos políticos, unindo a isso conceitos da lógica Fuzzy clássica para expressar melhor as causalidades encontradas nos sistemas, que são de natureza Fuzzy (AXELROD, 1976; KOSKO, 1986).

Como representação visual do conhecimento, os FCMs descrevem um sistema à maneira como os seres humanos o percebem, e são capazes de incorporar conhecimento de especialistas e conhecimento disponível a partir de dados na forma de regras. Além disso, grandes FCMs podem ser decompostos em estruturas menores e mais simples, gerando uma hierarquia (MENDONÇA, 2011; PAPAGEORGIOU, 2014).

Devido à sua simplicidade, suporte a conhecimento inconsistente (Fuzzy), são aplicáveis em inúmeras áreas, como medicina, engenharia, desenvolvimento de softwares etc. A Figura 1 mostra o exemplo de um FCM, em que C_i são chamados de conceitos e W_{ij} mostram os níveis de causalidade (pesos relacionados aos conceitos) (PAPAGEORGIOU, 2014).

O valor $A_i(k+1)$ de cada conceito C_i no momento $k+1$ é calculado pela soma de $A_i(k)$ no momento k , com o produto de $A_j(k)$ do conceito C_j pelo valor da causalidade W_{ji} , dado na faixa $[-1 \ 1]$. Vale ressaltar que W_{ji} pode ser representado como uma matriz, tendo como elementos os pesos atribuídos às ligações dos conceitos (KOSKO, 1986).




Figura 1 – Exemplo de um FCM

A representação matemática da inferência FCM é dada por (1) (PAPAGEORGIOU, 2014).

$$A_i(k+1) = f\left(A_i(k) + \sum_{j=1, j \neq i}^N A_j(k)W_{ji}\right) \quad (1)$$

Em (1), $f(\cdot)$ denota a função de ativação sigmoide, resultando em valores na faixa $[0, 1]$, mostrada em (2). Nela, λ é um número positivo real, denominado fator de esquecimento da rede, e x é o valor de A_i no ponto de equilíbrio.

$$f(x) = \frac{1}{1+e^{-\lambda x}} \quad (2)$$

Desse modo, pode-se resumir a construção de um FCM em cinco passos (MENDONÇA, 2011):

- Identificação dos conceitos, suas relações e sua natureza (positiva, negativa ou neutra);
- Aquisição dos dados iniciais por conhecimento especialista ou dados do processo, quando conhecidos;
- Apresentação dos dados para o cálculo dos pesos do FCM;
- Tratamento dos valores obtidos para otimização do FCM;
- Validação do modelo nas condições de operação propostas.

2.2 Parâmetros de análise do controle

Para a realização do método de ajuste de Ziegler-Nichols, deve-se ter em mãos as características desejadas para o sistema, traduzidas nos parâmetros de análise do controle. Como o nome sugere, são eles que definem a qualidade do controle empregado em um determinado processo, de modo que os resultados atinjam os valores desejados.

Nos processos utilizados nesse trabalho, foram analisados o tempo de acomodação (T_a), máximo sobressinal (*Overshoot*), assim como os erros *ITAE* e *ISE*. Quanto menor o valor desses parâmetros, melhor será o controle, visto que são almejados valores pequenos de erro e baixo tempo de resposta nos sistemas controlados. De maneira simples, o tempo de acomodação é o período necessário para que a resposta do sistema atinja de 2% a 5% do valor final. O máximo sobressinal é dado pelo percentual do valor relativo entre o valor de pico e da referência desejada no instante de pico (OGATA, 2010).

O outro fator analisado é chamado de *ITAE*, rotineiramente utilizado no meio acadêmico para a análise de controle como visto em (MAITI et al., 2008) e em (MARZAKI et al., 2015).

Seu cálculo é dado por (3), em que t é o tempo e $E(t)$ o erro no instante t .

$$ITAE = \int_0^{\infty} t \cdot |E(t)| dt \quad (3)$$

Para a análise computacional, o ITAE é calculado nesse trabalho como a soma dos erros com o ITAE anterior, de modo que os dados em tempos maiores possuem mais peso do que os obtidos nos instantes iniciais. De forma semelhante, o erro ISE (Integral do erro quadrático) também é utilizado para a análise da resposta de sistemas de controle, calculado de forma simples (4), onde $E(t)$ é o erro no instante t . Esse método penaliza tanto erros positivos e negativos encontrados no sistema (MARZAKI et al., 2015).

$$ISE = \int_0^{\infty} E(t)^2 dt \quad (4)$$

2.3 Indústria 4.0

A utilização de robôs autônomos, como podemos ver na Figura 1, é um dos pilares para a implementação de um dos conceitos recentemente abordados, a Indústria 4.0. Nesse conceito, tem-se a integração de todo o sistema de produção, maior flexibilidade e eficiência, utilizando sistemas inteligentes baseados em rede (GOMEZ et al., 2017).

Os robôs que atuam nessa área compartilham de uma grande quantidade de dados e informações obtidas, o chamado *Big Data* – outro conceito presente na Indústria 4.0, permitindo que seu sistema tome decisões com maior precisão de forma colaborativa. Seguindo essa linha de pensamento, a utilização de um sistema inteligente de baixo custo computacional que consiga processar tais dados é de suma importância.

No trabalho realizado por Pereira (2017), robôs são feitos com base em celulares e utilizam da “Nuvem” (*Cloud Computing*) para compartilhar as informações mais rapidamente. Esse trabalho parte de outros que utilizam do chamado Robótica em Rede (*Networked Robotics*) que é grupo de sistemas robóticos conectados através de uma rede de comunicação de dados, sendo esta cabeada ou sem fio (PEREIRA, 2017). Na figura a seguir pode-se observar todos os pilares para a implementação da Indústria 4.0.




Figura 2 - Pilares para a implementação da Indústria 4.0

Fonte: <embalagemmarca.com.br/2017/05/conheca-os-nove-pilares-para-implantacao-da-industria-4-0/>
Acessado em: 28/03/2019.

3. Metodologia

Como abordado anteriormente, no processo do fermentador alcoólico de Maher (1995), foi implementado um controlador PID adaptativo com mecanismo de ajuste via FCM. Posteriormente, através da interpretação dos parâmetros de análise de controle citados no trabalho, embarcou-se o mecanismo de ajuste escolhido como melhor na plataforma Arduino, comparando seus resultados com os obtidos nas simulações (MAHER, 1995).

Para o processo de fermentação alcoólica, escolheu-se uma arquitetura de controle denominada auto-sintonização (*auto tune*), mostrada na Figura 3. Nela, as variáveis *Erro*, *Interro* e *Differro* representam os erros relacionados aos parâmetros dos ganhos do PID, com *Erro* o erro em regime, *Interro* o erro integrativo e *Differro* o derivativo.

A arquitetura de controle mostrada na Figura 3 foi utilizada para o mecanismo de ajuste do PID utilizados no trabalho: FCM (FCM-PID). Em relação a seu funcionamento, o mecanismo de ajuste realiza a interpretação dos valores de saída, ou seja, os erros provenientes dos parâmetros do controlador e, a partir da análise proposta para cada mecanismo, aplica multiplicadores aos ganhos K_p e K_d do PID, adaptando-os a cada iteração nas simulações.

Para uma melhor comparação entre os dois mecanismos de ajuste utilizados, foram elaboradas duas campanhas distintas de fermentação (conjunto de valores de *setpoint* a serem seguidos), de forma a possibilitar uma melhor visualização em relação a flexibilidade de cada mecanismo utilizado.

A fermentação é um processo de liberação de energia no qual não há participação de oxigênio, e é utilizado nas indústrias em processos de fabricação de bebidas alcoólicas. O processo de fermentação desse trabalho foi retirado da proposta inicial de Maher (1995), que tem sido um sistema recorrente para validação de diferentes arquiteturas de controle devido à alta correlação entre suas variáveis e a elevada ordem do sistema. O processo possui quatro variáveis de estado: as concentrações, em g/l, de substrato (S), de biomassa (C), e do produto (P), e o volume (V), em litros, do tanque de fermentação.




Figura 3 – Arquitetura de controle proposta para o fermentador

A Figura 4 mostra o esquemático do tanque de fermentação, com as válvulas de entrada (F_{in}) e saída (F_{out}). F_{in} é responsável pelo fluxo de substrato no tanque e F_{out} pelo fluxo de produto, também chamado de fermentado, retirado da cuba. O controle dessas válvulas é feito por dois controladores PID independentes, que foram adaptados pelos mecanismos de ajuste propostos.




Figura 4 – Esquemático do tanque do fermentador

Nesse processo, quatro equações diferenciais regem o comportamento do sistema, e são dadas de (5) a (8).

$$\frac{dS}{dt} = -\frac{1}{Y_{C/S}}\mu_c + \frac{F_{in}}{V}Sa - \frac{F_{out}}{V}S \quad (5)$$

$$\frac{dC}{dt} = \mu_c - \frac{F_{out}}{V}S \quad (6)$$

$$\frac{dP}{dt} = \frac{Y_{P/S}}{Y_{C/S}}\mu_c - \frac{F_{out}}{V}P \quad (7)$$

$$\frac{dV}{dt} = F_{in} - F_{out} \quad (8)$$

As variáveis são: S_a : concentração de substrato da alimentação; $Y_{C/S}$: constante de conversão da biomassa; $Y_{P/S}$: constante de conversão do produto; μ_c : função de crescimento da biomassa (9); μ_0 : taxa máxima de crescimento; K_S : constante de Michaelis-Menten; P_m : coeficiente de inibição de P ao longo da reação.

$$\mu_c = \mu_0 \frac{S}{K_S + S_a} \left(1 - \frac{P}{P_m}\right) \quad (9)$$

Valores iniciais das variáveis de estado: S : 4,5 g/l; C : 5 g/l; P : 50 g/l; V : 2 l. Valores admitidos do processo: S_a : 100 g/l; P_m : 100; K_S : 10; μ_0 : 0,31; $Y_{C/S}$: 0,44; $Y_{P/S}$: 0,07. Nesse sistema, a resposta ao degrau apresentada é não-linear. Fatores importantes da dinâmica são o grande tempo de acomodação e alta correlação entre as variáveis de estado, vista nas equações de (1) a (4). Outro dado importante é que esse é um sistema de fase não-mínima, ou seja, possui zeros no semiplano direito do plano S de Laplace. Com isso, nota-se que a estabilização do processo depende rigorosamente das concentrações corretas para ocorrer.

Assim, de modo geral, o controle desse processo contém muitas variáveis controladas simultaneamente, que respondem aos estímulos de sinais distintos de entrada, ou seja, múltiplas entradas e saídas (MIMO).

Para isso, algumas restrições devem ser seguidas para garantir uma campanha (conjunto de valores de *setpoint* desejados) correta de fermentação: a concentração de biomassa (C) não deve exceder 8 g/l, enquanto que o substrato (S) deve se manter sempre acima de 0,5 g/l,

pois caso contrário a reação acabaria, e assim o processo deveria ser iniciado novamente. Outra restrição é a faixa de valores do *setpoint* para a concentração de produto (P), na faixa discreta de 10 a 50 g/l, de acordo com os trabalhos desenvolvidos por (FABRO; ARRUDA, 2003).

Por questões de segurança, foram adotados um volume (V) máximo do tanque de 4,75 l e volume mínimo de 1 l. Automaticamente, se o primeiro caso ocorrer, a válvula *Fin* é completamente fechada e, se ocorrer o segundo caso, a válvula fechada é a *Fout*. Como abordado anteriormente, neste trabalho foram utilizadas as equações de (5) a (8) para simular esse processo pelo MatLab® (MENDONÇA; ARRUDA, 2015).




Figura 5 – FCM do fermentador

A primeira etapa no desenvolvimento foi a sintonização dos parâmetros iniciais do controlador PID, K_p , K_d e K_i (constante). Inicialmente os valores utilizados foram obtidos através do Método de Ziegler-Nichols mas, através da heurística e análise do processo, os valores foram alterados de maneira a melhorar os resultados do controle. Com isso, chegou-se a $K_p = 2$, $K_d = 4,95$ e $K_i = 0,35$.

O primeiro mecanismo de ajuste a ser explorado foi o FCM-PID, construído a partir da análise do controle PID tradicional do processo, utilizando-se de conhecimento especialista. Com isso, tem-se o FCM desenvolvido na Figura 5.

Na figura acima, os conceitos 4 e 5 correspondem aos multiplicadores a serem aplicados nos ganhos K_p e K_d do PID. A partir do conhecimento de especialista empregado no projeto do FCM, verificou-se que os conceitos de 1 a 3 possuem influência negativa fraca em 4 e 5. A matriz de pesos do FCM é dada por (10).

$$W_{ji} = \begin{pmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ -0,2799 & -0,2466 & -0,1532 & 0 & 0 \\ -0,3082 & -0,2465 & -0,1727 & 0 & 0 \end{pmatrix} \quad (10)$$

4. Resultados e discussão

Primeiramente foram feitas as simulações da campanha de fermentação 1, para o PID e FCM-PID. Os resultados para o produto (P), substrato (S), volume (V) e biomassa (C) são mostrados a seguir, juntamente com as variações dos ganhos, erros e o tempo de execução de cada campanha por ambos os mecanismos de ajuste e PID não-adaptativo.




Figura 6 – Resultados FCM-PID campanha 1




Figura 7 – Variação dos ganhos FCM-PID campanha 1




Figura 8 – Resultados FCM-PID campanha 2




Figura 9 – Variação dos ganhos FCM-PID campanha 2

Campanha	PID		FCM-PID	
	1	2	1	2
Biomassa máx. (g/l)	6,5719	6,6584	6,5366	6,3331
Substrato mín. (g/l)	3,3463	5,0022	2,7367	4,7029
Volume mín. (l)	1,8665	1,7459	1,2488	1,2596
Volume máx. (l)	4,1005	4,0341	4,1005	4,0341

Tabela 2 – Valores críticos das variáveis de estado

A partir da análise das Figuras 6 e 7 (campanha 1), 8 e 9 (campanha 2) e da Tabela 2, tem-se que as três abordagens utilizadas obtiveram resultados dentro das faixas desejadas para as variáveis de estado do processo.

Na primeira campanha o FCM-PID apresentou os valores mais baixos para todos os aspectos analisados, indicando, apoiando-se também pela visualização das figuras, que a mudança dos parâmetros do PID desse mecanismo ocasionou valores mais constantes para as variáveis analisadas.

Para a segunda campanha, que conta com mais mudanças no setpoint do que a primeira, nota-se que o controlador PID apresentou os maiores valores na Tabela 2, sugerindo que, para essas condições, o uso do controlador não-adaptativo resultou em maior variação para os parâmetros do processo. Em relação as variações dos ganhos, dadas pelas Figuras 6 e 7 (campanha 1), 8 e 9 (campanha 2), percebe-se que Kp e Kd são adaptados de forma acentuada nas mudanças de setpoint, tendo seus valores diminuídos para FCM-PID.

As Figuras 6 e 7 (campanha 1), 8 e 9 (campanha 2) apresentam os erros durante o processo de fermentação para o PID e FCM-PID. Assim como as análises anteriores, tem-se que os erros apresentam seus maiores valores nas mudanças de *setpoint*, solicitando assim as adaptações nos ganhos do controlador. Nesse trabalho utilizou-se apenas a soma do erro atual com o anterior para Interro, causando os resultados vistos para esse parâmetro nas figuras citadas acima.

PID	FCM-PID
-----	---------

Campanha	1	2	1	2
<i>Ta</i> (h)	20	20	20	20
<i>Overshoot</i> (g/l)	2,6488	3,1931	2,4274	2,8071
ITAE	0,9324	1,2827	0,7303	0,9790
ISE	0,0557	0,0517	0,0541	0,0488

Tabela 3 – Parâmetros de análise do controle

Com isso, chega-se a análise dos parâmetros de controle utilizados, mostrados na Tabela 3. Para o tempo de acomodação (*Ta*), não há vantagem para PID e FCM-PID, visto que a diferença encontrada é pequena, devido ao elevado número de horas (350) utilizado para as campanhas.

Para o *overshoot*, o FCM-PID leva vantagem, sendo que o PID apresenta o maior valor para as duas campanhas, fato que endereça uma maior flexibilidade do mecanismo de ajuste FCM-PID.

Como esperado na análise do ITAE e do ISE, os resultados do PID foram os piores, visto sua natureza não-adaptativa. Entretanto, para o ISE os valores obtidos foram aproximados entre os três analisados, para as duas campanhas. Os resultados do ITAE foram de acordo com os demais obtidos, com o FCM-PID se saindo 20% melhor do que o PID.

5. Considerações finais

No processo do fermentador alcoólico industrial, o mecanismo FCM-PID obteve as melhores respostas de acordo com os parâmetros escolhidos, se mostrando uma opção viável para utilização em sistema de controle reais.

Como futuros trabalhos, pode-se citar uma evolução dos scripts utilizados para embarcar o controlador juntamente com o mecanismo adaptativo FCM-PID na plataforma Arduino, embarcando um controlador inteligente que se comunica com o MatLab® Simulink® através do Arduino.

Agradecimentos

Agrademos a UTFPR Campus Cornélio Procopio e o Grupo Contrafo pelo apoio financeiro na inscrição.

Referências

- ÅSTRÖM, K. J.; WITTENMARK, B. **Adaptive Control**. 2. ed. USA: Dover Publications, 2008.
- AXELROD, R. **Structure of decisions: the cognitive maps of political elites**. 1. ed. Princeton, NJ, USA: Princeton University Press, 1976.
- FABRO, J. A.; ARRUDA, L. V. R. Fuzzy-neuro predictive control, tuned by genetic algorithms, applied to a fermentation process. **Proceedings of the 2003 IEEE International Symposium on Intelligent Control ISIC-03**, p. 194–199, 2003.
- KOSKO, B. Fuzzy cognitive maps. **International Journal of Man-Machine Studies**, v. 24, n. 1, p. 65–75, 1986.

MAHER, M. **Modélisation et élaboration d'algorithmes d'estimation et de commande : application à un bioprocédé.** 1995.

MAITI, D. et al. Tuning PID and PI D Controllers using the Integral Time Absolute Error Criterion. **2008 4th International Conference on Information and Automation for Sustainability**, p. 1–6, 2008.

MARZAKI, M. H. et al. Performance of FOPI with error filter based on controllers performance criterion (ISE, IAE and ITAE). In: 2015 10th Asian Control Conference (ASCC), **Anais...IEEE**, maio 2015.

MENDONÇA, M. **A Contribution to Intelligent System Modeling based on Dynamic Cognitive Networks.** 2011. Federal University of Technology - Paraná, Curitiba, 2011.

MENDONÇA, M.; ARRUDA, L. V. R. de. **A Contribution to the Intelligent Systems Development Using DCN.** 1. ed. Riga, Latvia: Scholars Press, 2015.

OGATA, K. **Modern Control Engineering.** [s.l: s.n.]v. 17

PAPAGEORGIOU, E. I. (ed.). **Fuzzy Cognitive Maps for Applied Sciences and Engineering.** Heidelberg: Springer-Verlag Berlin Heidelberg, 2014.

PASSINO, K. M.; YURKOVICH, S. **Fuzzy Control.** 1. ed. Menlo Park, CA, USA: Addison Wesley, 1998.

PEREIRA D. S; SANTANA, A. S.; MAIA R. S.; SOUZA A. **A Cloud Robotics Architecture Clone Based for a Cellbots Team.** IEEE Latin America Transactions, v. 15, n. 9, p. 1587–1594, 2017.

ROBLA-GOMEZ S.; BECERRA V. M.; LLATA J. R.; GONZALEZ-SARABIA E.; TORRE-FERRERO C.; PEREZ-ORIA J. **Working Together: A Review on Safe Human-Robot Collaboration in Industrial Environments.** IEEE, 2017.

ROSS, T. J. **Fuzzy logic with engineering applications.** 3. ed. New Mexico, USA: John Wiley & Sons, 2010.