
REDES DINÂMICAS COGNITIVAS APLICADAS NO CONTROLE SUPERVISÓRIO DE UM FERMENTADOR

Márcio Mendonça*
mendonca@utfpr.edu.br

L. V. R. Arruda†
lvrarruda@utfpr.edu.br

Flávio Neves-Jr.†
neves@utfpr.edu.br

*Universidade Tecnológica Federal do Paraná
Campus Cornélio Procópio – Av. Alberto Carazzai, 1640
CEP 86300-000, Cornélio Procópio, Paraná, Brasil

†Campus Curitiba – Av. Sete de Setembro, 3165
CEP 80230-901, Curitiba, Paraná, Brasil

ABSTRACT

Dynamic Cognitive Networks applied to supervisory control of a fermentation process

This paper uses dynamic cognitive networks (DCN) as an intelligent tool for supervisory control. The DCNs are an evolution of fuzzy cognitive maps (FCM). Intelligent systems and tools use expert knowledge to build models with inference and / or decision taking abilities. A supervisory control architecture for an alcoholic fermentation process is developed from the acquisition of empirical knowledge from an expert. The objective of the supervisor is to operate the process in normal and critical situations. For this, we propose the use of a DCN model with new types of concepts and relationships that not only represent cause-effect as in FCM models. Simulation results are presented to validate the architecture developed.

KEYWORDS: Dynamic cognitive networks, fuzzy cognitive maps, graph, intelligent control, supervision.

RESUMO

Este trabalho usa redes cognitivas dinâmicas (*Dynamic Cognitive Networks* – (DCN), como uma ferramenta inteligente para controle supervísório. As DCNs são uma evolução dos mapas cognitivos fuzzy (Fuzzy Cognitive Map – FCM). Os sistemas inteligentes se baseiam no conhecimento de especialistas a fim de construir modelos com capacidade de inferência e/ou tomada de decisão. Uma arquitetura de controle supervísório para um processo de fermentação alcoólica é desenvolvida a partir da aquisição de conhecimento empírico de um especialista. O objetivo do supervisor é operar o processo em situações normal e crítica. Para isto, propõe-se o uso de uma DCN que incorpora novos tipos de conceitos e relações que não apenas as relações de causa-efeito presentes nos modelos baseados em FCMs. Resultados de simulação são apresentados para validar a arquitetura desenvolvida.

PALAVRAS-CHAVE: Redes cognitivas dinâmicas, mapas cognitivos *fuzzy*, grafo, controle inteligente, supervisão.

1 INTRODUÇÃO

Seres humanos são capazes de lidar com processos complexos, baseados em informações imprecisas e/ou apro-

Artigo submetido em 24/03/2010 (Id.: 01119)

Revisado em 13/05/2010, 21/12/2010

Aceito sob recomendação da Editora Associada Profa. Emilia Villani

ximadas. A estratégia adotada por eles é também de natureza imprecisa e geralmente passível de ser expressa em termos linguísticos. Deste modo, através de conceitos da lógica *fuzzy*, é possível modelar esse tipo de informação (Zadeh, 1992). Entretanto, informações também podem ser adquiridas a partir dos dados de operação e/ou, funcionamento de um sistema através de técnicas de identificação e modelagem (Passino e Yourkovich, 1998). Entre estas técnicas as redes neurais se destacam pela capacidade de processar dados massivos de uma maneira paralela (Haykin, 2000). Por outro lado, os mapas cognitivos difusos, do inglês *Fuzzy Cognitive Maps* (FCM), é uma ferramenta para a modelagem do conhecimento humano, principalmente relações de causa-efeito, obtido através de termos linguísticos, inerentes aos sistemas *fuzzy*, mas com uma estrutura semelhante a das Redes Neurais Artificiais (RNA). Esta estrutura confere ao mapa a capacidade de treinamento e adaptação baseada em dados do sistema (Kosko, 1986). Neste contexto, um FCM pode ser considerado um modelo híbrido (fusão de duas áreas de conhecimento) de sistema inteligente com um forte grau de iteração, no qual não se pode identificar e separar as estruturas das áreas de origens, somente a semântica de construção. Além das vantagens e características herdadas das técnicas primárias, FCM tem sido usado como uma ferramenta para construção de modelos e/ou mapas mentais em diversas áreas de conhecimento (Taber, 1991), (Miao e Liu, 1999), (Stach, et al., 2005), (Chun-Mei, 2008). Este fato sugere que a técnica é versátil na abstração de informações, facilitando a modelagem do conhecimento devido à sua semelhança de construção com o raciocínio humano. Entretanto, esses modelos cognitivos têm dificuldades para modelar não linearidades e principalmente comportamentos variantes no tempo (Miao et al., 2001)-(Kolouriotis et al., 2005).

Para contornar esses problemas e conferir adaptabilidade aos modelos baseados em FCMs, alguns autores propuseram diversas variantes dos FCMs aptas a modelar sistemas dinâmicos, entre elas destacam-se as Redes Cognitivas Dinâmicas (Miao et al., 2001) - (Kolouriotis et al., 2005). De acordo com a literatura, os FCMs estendem os mapas cognitivos (Axelrold, 1976), descrevendo a força das relações causais (Kosko, 1986) e as DCNs estendem os FCMs por incluir os aspectos dinâmicos, ao considerar que ao longo do tempo uma mesma relação de causa-efeito pode apresentar diferentes graus de intensidade (Miao et al., 2001).

Sendo técnicas neuro-*fuzzy*, os FCMs, e em especial as DCNs, são capazes de modelar sistemas complexos com boa precisão. De fato os mapas cognitivos em geral são grafos ponderados e direcionados (dígrafo) com reali-

mentação, formados por nós e arcos. Os nós do grafo são utilizados para modelar conceitos descrevendo o comportamento do sistema. Estes conceitos são conectados entre si por arcos ponderados que representam as relações de causalidade existentes entre eles. Os mapas cognitivos *fuzzy*, por sua vez, são uma classe de mapa cognitivo em que os valores dos conceitos e relações causais são números *fuzzy* (Kosko, 1986). Como um grafo ponderado e direcionado, um FCM pode também ser considerado um autômato (ou máquina de estado finito), gerado a partir de conhecimento especialista e calibrado com dados do sistema (Miao e Liu, 1999). Nesse sentido, Miao e Liu (1999) também demonstram a convergência das trajetórias de inferência de um FCM e propõem teoremas que mostram que para um grande FCM, estas trajetórias podem ser decompostas, gerando uma hierarquia de FCM menores que são mais facilmente construídos. Com isto eles demonstram que os FCM são uma ferramenta eficiente para a análise e modelagem de sistemas de grande escala existentes no mundo real.

As DCNs por sua vez, são mapas cognitivos, fuzzy ou não, que consideram os seguintes aspectos de uma relação causal:

- A força da relação de causalidade;
- A força da causa;
- O grau de efeito.

Deste modo as relações de causalidade em DCNs diferem não apenas na duração do efeito provocado por uma determinada causa, mas também sobre como a causa gera o efeito. As DCNs têm a capacidade de modelar e gerenciar comportamentos não-lineares dependentes do tempo, muitas vezes em tempo real, porém não existe uma solução fechada e ainda há um amplo espaço para modificações e atualizações dessa técnica (Koulouriotis, et al., 2005),(Miao et al., 2010). Neste contexto, se insere o presente trabalho ao propor uma nova arquitetura de DCN aplicada a controle de processos.

Para processos complexos como os existentes nas indústrias químicas e petroquímicas, a operação e supervisão das malhas de controle tem se tornado cada vez mais crítica. Um dos motivos disso é que os processos não são bem compreendidos e a sua operação é realizada com base na experiência antes que em leis de controle rígidas. Algumas abordagens existentes na literatura para a supervisão de tais processos são baseadas em técnicas de aquisição de dados e, especificamente em métodos de agrupamento para tratar com a dificuldade na modelagem dos processos. Com isso, o comportamento do sistema é modelado com uma máquina de estado finito (Kempowsky et al, 2006) que evolui ao longo de

uma trajetória de estados alcançáveis. Este tipo de técnica considera o comportamento de um sistema dinâmico como uma sequência de estados em que o estado atual contém todas as informações do comportamento do sistema. Neste contexto, Kempowsky e seus colaboradores (2006) discutem aspectos teóricos e práticos da construção de um sistema supervisorio para controle de processos modelados como máquina de estado finito.

A partir dos resultados apresentados por esses autores (Miao e Liu, 1999), (Miao et al., 2001), (Kempowsky et al, 2006), o presente artigo propõe o desenvolvimento de um sistema supervisorio em que a máquina de estado finito é substituída por uma DCN construída a partir do conhecimento especialista de como controlar um processo. A fim de modelar todas as relações existentes em um sistema dinâmico não linear, são utilizadas na construção da DCN além das relações de causa-efeito comuns aos mapas cognitivos, relações do tipo *fuzzy* e do tipo seleção. A inclusão destas relações na DCN agrega versatilidade à técnica e é uma contribuição deste trabalho para a área de representação de conhecimento e modelagem de sistemas utilizando DCNs.

O artigo é organizado como segue: a sessão 2 faz uma introdução à teoria de modelagem baseada em mapas cognitivos e apresenta uma breve revisão da literatura associada à utilização de FCM e DCN em controle de processos. A sessão 3 descreve o processo de fermentação que foi utilizado para testar a proposta do artigo e constrói um sistema supervisorio para este processo. A sessão 4 apresenta os resultados de simulação e a sessão 5 conclui o trabalho.

2 MODELOS COGNITIVOS

Os mapas cognitivos foram inicialmente propostos por Axelrod (1976) para representar palavras, idéias, tarefas ou outros itens ligados a um conceito central e dispostos radialmente em volta deste conceito. Axelrod desenvolveu também um tratamento matemático para esses mapas, baseado na teoria de grafos e em operações com matrizes. Através de mapas cognitivos, as crenças ou afirmações a respeito de um domínio de conhecimento limitado são expressas por meio de palavras ou expressões linguísticas, interligadas por relações simples de causa e efeito (causa/não-causa).

Estes mapas podem assim ser considerados como um modelo matemático da “estrutura de crenças” de uma pessoa ou grupo, permitindo inferir ou predizer as consequências que esta organização de idéias causa no universo representado. Este modelo matemático foi adaptado para inclusão de incertezas através da lógica *fuzzy*

por Kosko (1986) gerando os mapas cognitivos *fuzzy*. Posteriormente, os FCMs foram adaptados para a inclusão de um comportamento dinâmico gerando as redes dinâmicas cognitivas (Miao et al., 2001).

À semelhança dos mapas cognitivos originais, os FCMs e as DCNs são grafos direcionais (dígrafos), em que os valores numéricos são variáveis ou conjuntos *fuzzy*. Os “nós” destes grafos são conceitos linguísticos, representados por conjuntos *fuzzy* e cada “nó” é associado com outros através de conexões. A cada uma dessas conexões é associado um peso numérico, que representa uma variável *fuzzy* relacionada com o nível de causalidade existente entre os conceitos. Um exemplo de mapa cognitivo é dado na figura 1 e a sua matriz de conexão ou pesos equivalente é dada na equação 1.




Figura 1: Mapa cognitivo

$$W = \begin{bmatrix} 0 & w_{12} & w_{13} & 0 & 0 \\ w_{21} & 0 & 0 & 0 & 0 \\ w_{31} & 0 & 0 & 0 & 0 \\ 0 & w_{42} & 0 & 0 & w_{45} \\ w_{51} & w_{52} & w_{53} & 0 & 0 \end{bmatrix} \quad (1)$$

Os conceitos de um mapa cognitivo podem ser atualizados através da iteração com os outros conceitos e com o seu próprio valor. Isto é dado pela equação (2) em que as relações causais são representadas pelos pesos da soma-tória. Resumindo, os valores dos conceitos vão evoluindo após várias iterações até normalmente estabilizarem-se num ponto fixo ou num ciclo limite.

$$A_i^k = f \left(\sum_{\substack{j=1 \\ j \neq i}}^n W_{ij} \cdot A_j^{k-1} + A_i^{k-1} \right) \quad (2)$$

Onde k é o contador de iterações, n é o número de nós no grafo, W_{ij} é o peso do arco que conecta o conceito C_i ao conceito C_j , A_i^k é o valor do conceito C_i na iteração k e a função f é uma função do tipo sigmóide:

$$f(x) = \frac{1}{1 + e^{-\lambda x}} \quad (3)$$

Desta forma um modelo baseado em FCM ou DCN usa uma representação de conhecimento estruturada através de relações causais calculadas matematicamente a partir de operações matriciais.

No caso particular dos FCMs, alguns autores argumentam que esses modelos não estão aptos a representar os sistemas reais corretamente, em especial os sistemas dinâmicos, pois através deles é possível apenas expressar relações causais monotônicas e simétricas. Essas relações causais também não conseguem modelar o conceito de realimentação e os aspectos temporais associados aos sistemas reais (Miao et al, 2001), (Carvalho, 2001). Como solução, Carvalho (2001) introduz outros tipos de relações além das relações causais nos FCMs, e também classifica os conceitos de acordo com o seu comportamento temporal. Já Miao e seus colaboradores (2001) propõem a utilização de conexões variantes no tempo e utilizam funções de transferência no domínio de Laplace para calcular ao longo do tempo os valores das ponderações dadas pela matriz (1). Esses autores denominam os mapas cognitivos assim obtidos de redes cognitivas dinâmicas (DCN).

Seguindo as recomendações de Carvalho (2001), Miao et al. (2001) e Stylios et al (2008), utilizam-se neste artigo para a construção da DCN, além de conceitos e relações causais empregados no desenvolvimento de mapas cognitivos, os seguintes tipos de conceito e relação:

Conceito Nível: é um conceito que é perfeitamente representado por um valor absoluto.

Conceito Variação: é um conceito cujo valor representa uma variação em um determinado instante de tempo.

Conceito de entrada: é um conceito que recebe dados de entrada, descritivos do estado do sistema, e que podem interagir entre si, para representar a evolução do sistema.

Conceito de saída (decisão): são os conceitos resultantes da evolução da DCN e que não interagem entre si.

Relações causais: são relações de causa e efeito entre dois conceitos, modeladas através das equações (1) As relações causais podem ser estáticas calculadas através de uma matriz W constante ou variantes no tempo, calculadas a partir de um $W(t)$.

Relações fuzzy: são relações de causa-efeito entre um antecedente e um conseqüente modelada através de uma regra *fuzzy*. Estas relações são naturalmente variantes

no tempo, já que o valor da matriz $W(t)$ é resultado da execução de um sistema lógico fuzzy.

Declarações condicionais: são relações de causa-efeito expressas na forma de regras se-então. Como as anteriores, estas declarações também geram conexões variantes no tempo.

Outro aspecto relativo à construção de FCMs e por extensão de DCNs diz respeito à otimização da matriz de pesos dada em (1) e a sua aderência aos dados reais do sistema.

Para isto, uma estratégia de aprendizado baseado em dados pode ser aplicada após a construção do mapa por especialista. Os métodos utilizados nessas estratégias são em geral baseados em aprendizado hebbiano (Dickerson e Kosko, 1994), (Papageorgiou, Stylios e Groumpos, 2004) ou algoritmo evolucionários (Koulouriotis, Diakoulakis e Emiris, 2001), (Stach, Kurgan e Pedrycz, 2005), *simulated annealing* (Ghazanfari et al., 2007), ou ainda otimização por nuvem de partículas (Papageorgiou et al, 2005), (Petalas, Parsopoulos, e Vrahatis, 2009). Uma extensão destes métodos pode ser mantida para garantir a adaptabilidade do mapa a mudanças no sistema durante sua utilização. Este tipo de estratégia não é utilizado nesse artigo.

2.1 Construção de uma Rede Dinâmica Cognitiva

A construção de uma rede cognitiva dinâmica (DCN), como uma evolução do mapa cognitivo *fuzzy* (FCM), pode ser realizada em seis passos, de acordo com o algoritmo mostrado no Quadro 1. Este algoritmo é uma modificação do algoritmo de construção de FCMs utilizado em (Kosko, 1986), (Stylios e Groumpos, 2000) e (Ghazanfari et al., 2007). Nesses trabalhos, por exemplo, o Passo 1 do algoritmo do Quadro 1 possui apenas relações causais, a extensão para outros tipos de relação é uma proposta deste trabalho.

2.2 Revisão da literatura – FCM e DCN

Desde o trabalho pioneiro de Kosko em 1986, que estendeu os mapas cognitivos de Axerold para a inclusão de incertezas no modelo cognitivo, através da lógica *fuzzy*, várias aplicações de FCM são reportadas na literatura. Essas aplicações abrangem diversas áreas, tais que sistemas sociais (Taber, 1991), vida artificial (Dickerson e Kosko, 1994), tomada de decisão em rodovias de acesso rápido (Perusich, 1996), modelagem e tomada de decisão em ambientes corporativos, comércio eletrônico (Lee e Lee, 2003), detecção de pontos em imagens geradas por sistema de câmeras estéreo (Pajares e de La Cruz, 2006),

tomada decisão na área médica (Papageorgiou, Stylios e Groumpos, 2007) entre vários outros. Observa-se que, estes trabalhos também apresentam variações semânticas da proposta original de FCM, adaptando a estrutura do FCM de acordo com o problema tratado e tentando atenuar as dificuldades de modelagem reportadas nas sessões anteriores.

De um modo mais específico, os trabalhos a seguir empregam FCM para apoiar a tomada de decisão em sistemas dinâmicos, em especial para controle supervísório e/ou adaptativo de aplicações industriais, área de pesquisa na qual se enquadra este artigo.

Stylios e Groumpos (2000) apresentam um sistema de controle supervísório em dois níveis aplicado a um processo de manufatura. O FCM de baixo nível modela o funcionamento do processo e características qualitativas do produto final, com vistas à detecção de falhas. O segundo FCM utiliza técnicas de agrupamento na construção de diferentes funcionalidades no nível supervísório. Para ambos os FCM, regras de tomada de decisão *fuzzy* do tipo **SE-ENTÃO** são empregadas nas relações causais do mapa e uma interface dedicada permite a comunicação e troca de dados entre os dois níveis. A mesma arquitetura é utilizada para modelar e descrever o comportamento dinâmico de um trocador de calor em Stylios e Groumpos (2004) e para controle de nível de um sistema de tanques acoplados em (Papageorgiou et al., 2004).

O controle hierárquico de um sistema de radioterapia para cálculo e tomada de decisões quanto à dosagem a ser aplicada em pacientes com câncer é proposto em (Papageorgiou, Stylios e Groumpos, 2007). O FCM de baixo nível é responsável pelo cálculo de três variáveis de saídas (fatores e seletores) associadas a níveis de radiação, as quais devem ser analisadas no nível superior. O FCM de alto nível atua como um sistema de tomada de decisão. As diferentes opções de ajuste entre os parâmetros dos fatores e seletores são feitas através de regras de decisão simples do tipo **SE-ENTÃO**. Observa-se que as inferências alteram os valores dos conceitos e não das relações causais previamente ajustadas de acordo com o conhecimento empírico do processo. O FCM do nível superior ajusta a dosagem final e a dosagem planejada da radiação aplicada dentro de limites máximos e mínimos de protocolos médicos já pré-estabelecidos. A interface entre os dois níveis de controle também é feita através de regras *fuzzy* em que variações nos conceitos do FCM do nível inferior alteram os conceitos no FCM do nível superior e vice-versa. Uma extensão deste trabalho é apresentada em (Stylios, Georgopoulos e Chouliara, 2008).

Passo 1: Identificação dos conceitos, estabelecendo seu tipo (entrada, saída, nível ou variação), e de suas interconexões ou relações, determinando a natureza (positiva, negativa, neutra) dessas relações e o seu tipo (puramente causal ou variante no tempo, *fuzzy* e / ou declaração condicional).

Passo 2: Aquisição de dados iniciais, através de ponderação de opinião de especialistas e / ou análise do sistema de equações, quando se conhece o modelo matemático.

Passo 3: Apresentação dos dados referentes à opinião dos diversos especialistas a um sistema lógico *fuzzy* que tem como saída os valores dos pesos para as relações puramente causais.

Passo 4: Construção da base de regras *fuzzy* que tem como inferência os valores de pesos da DCN para as relações *fuzzy*, ou da base de regras com declarações condicionais.

Passo 5: Tratamento da informação, adaptação e ou otimização da DCN inicialmente proposta, ajustando suas respostas às saídas desejadas.

Passo 6: Validação da DCN ajustada nas condições de operação do sistema ou processo modelado.

Quadro 1 - Construção de uma DCN

O FCM apresentado em (Carvalho, 2001) também utiliza regras de inferência *fuzzy* entre as relações causais. Esta arquitetura é denominada **RB-FCM** (*Rule based FCM*). De acordo com o autor, somente as relações causais entre os conceitos restringem a aplicação de FCM em sistemas dinâmicos. O uso de regras de inferência (**SE-ENTÃO**) entre as relações permite a tomada de decisões, alterando conceitos para diferentes pontos de operação ou para conectar vários FCMs em diferentes níveis hierárquicos. Além disso, um autômato celular é utilizado para transição entre diferentes tipos de regras *fuzzy* em diferentes cenários de um sistema dinâmico.

Jones, Roy e Corbett (2004) apresentam uma variação da proposta original de Kosko, em que um FCM é acrescido de capacidade de inferência através da inclusão de um sistema **ANFIS** (*Adaptive-Network-Based Fuzzy Inference System*) na modelagem das relações causais. O **FICM** (*Fuzzy Inference Cognitive Maps*) emprega dois tipos de conceitos diferentes. Os conceitos e relações causais comumente utilizados na construção de FCMs e conceitos auxiliares para a tomada de decisão.

O trabalho de Aguilar (2004) apresenta uma nova arquitetura cognitiva denominada *Dynamic Random Fuzzy Cognitive Map* (DR-FCM) que propõe mudanças dinâmicas nas relações causais inspirados nas redes neurais aleatórias. Nessa arquitetura, funções densidades de

probabilidade são inseridas no lugar de um simples valor numérico para determinar o valor das relações causais. Essas relações deverão ser atualizadas de acordo com condições específicas das variações no ambiente. O mecanismo dinâmico de atualização usa algoritmos de aprendizagem por reforço. Para validação, é proposta uma aplicação de realidade virtual (modelo de soldados em combate), que permite avaliar o desenvolvimento, a capacidade de inferência e a estabilidade da arquitetura DR-FCM.

Recentemente, Chun-Mei (2008) apresenta e discute a evolução de topologias FCMs para a construção de modelos qualitativos, desenvolvendo uma proposta de controle multivariado com uso de FCM.

Um FCM é utilizado em (Neves, Arruda e Mendonça, 2009) para gerar *set-points* no nível supervisorio para o mesmo processo de fermentação utilizado neste artigo. Nesse trabalho, os autores utilizam um FCM para modelar o processo de fermentação e um algoritmo genético para alterar as relações causais entre os conceitos do mapa a fim de garantir o funcionamento adequado do processo nos diversos pontos de operação desejados. O desempenho da arquitetura proposta é comparado com duas outras arquiteturas, em que a tarefa de gerar *set-points* para o nível regulatório é implementada via controlador *fuzzy* ou via controle preditivo baseado em DMC (*Dynamic Matrix Control*).

Outra ferramenta baseada em mapas cognitivos encontrada na literatura é o Fuzzy-SDG (*Signed Direct Graph*) (Wang et al, 1995). Esta topologia utiliza o conhecimento de especialistas de forma estruturada gerando um mapa cognitivo. Os conceitos dão origem a variáveis fuzzy e as relações causais originam uma base de regras do tipo antecedente – consequente. Em (Ghazanfari et al, 2002), um sistema dinâmico de compras é desenvolvido para exemplificar o uso de Fuzzy-SDG. Esse sistema inteligente modela o tempo através do disparo de regras e inclui um fator de probabilidade para cada regra modelada. O uso de funções de probabilidade atenua os efeitos das incertezas, imprecisões, ambiguidade, entre outros, decorrentes do processo de aquisição de conhecimento indutivo.

Em (Huang e Wang, 1999) é apresentado outro tipo de mapa cognitivo, as redes *fuzzy* causais (FCN – *Fuzzy Causal Network*), em que o mecanismo de inferências se dá através da criação e ativação dinâmica de subconjuntos dos conceitos modelados. Esses conjuntos e subconjuntos são contidos em intervalos mínimos e máximos das variáveis modeladas (conceitos) e, de acordo com regras de funcionamento, são ativados considerando

também sua evolução temporal. Os autores consideram as FCNs uma extensão dos grafos Fuzzy-SDG e argumentam que a ferramenta é eficiente na representação de sistemas dinâmicos. Em (Zhang, Liu e Zhou, 2006), um sistema de tomada de decisão baseada em políticas propostas por diferentes especialistas é modelado utilizando FCN e aplicado a um departamento universitário, exemplificando o uso da ferramenta proposta.

Como uma combinação de FCMs e FCNs surgem em seguida as redes cognitivas dinâmicas que pretendem combinar as propriedades dos FCMs aos sistemas de inferência causal das FCNs. A DCN descrita em (Miao et al, 2001) é uma das primeiras propostas de DCN e utilizam funções de transferência no domínio de Laplace para representar o comportamento dinâmico das relações causais de um mapa cognitivo. Assim cada arco de uma DCN tem seu valor calculado a partir de uma função de transferência ou de um modelo em espaço de estado. Estruturalmente uma DCNs é mais flexível que um FCM. De um modo geral, uma DCN pode ser tão simples quanto um mapa cognitivo (CM), um FCM, ou tão complexo como um sistema dinâmico não-linear. Em (Miao et al, 2001), para demonstrar o potencial da ferramenta, um sistema de estratégia e tomada de decisão financeira para gerenciamento de plantações é construído e resultados simulados são apresentados e comparados com um FCM.

O trabalho de Koulouriotis e colaboradores (2004) apresenta uma proposta de rede cognitiva dinâmica (DCN) para aproximação de séries temporais aplicada em sistemas financeiros. Segundo os autores, os FCMs têm limitações para modelagem de sistemas complexos principalmente devido a não-linearidades e fenômenos temporais. A arquitetura proposta desse trabalho é semelhante à proposta em (Miao et al, 2001) na medida em que uma DCN é obtida a partir de um FCM. No entanto, a DCN proposta guarda mais semelhança com as redes neurais que com os FCMs, uma vez que usa o algoritmo de Levenberg Marquadt para treinamento e/ou sintonia da rede cognitiva. Os autores validam e concluem a proposta através de comparativos entre DCN e RNA.

Uma nova proposta de mapa cognitivo dinâmico é apresentada em (Kottas, Boutallis e Christodoulou, 2007) e denominado rede cognitiva *fuzzy* (*Fuzzy Cognitive Network - FCN*). Essas FCNs são semelhantes às DCN e utilizam um mecanismo de atualização da matriz *W* baseado no algoritmo do gradiente (regra delta) a partir da realimentação do erro medido entre o estado atual e o estado desejado da rede. Os autores aplicam a FCN assim projetada no controle de nível de um modelo sim-

plificado de hidroelétrica. Como as DCNs em (Koulouriotis et al., 2004), essas FCNs estão mais próximas de uma rede neural do que de um mapa cognitivo, propriamente dito.

Recentemente, Miao e seus colaboradores (2010) demonstram que as DCNs são uma família geral de mapa cognitivo e que em particular, os mapas de Axelrod (1976) e os FCMs de Kosko (1986) são modelos simplificados de DCNs. Além disso, esses autores também desenvolvem modelos de transformação fornecendo uma base teórica sólida para as aplicações de DCNs.

No presente trabalho, adota-se a abordagem proposta em (Miao et al., 2001) e (Miao et al., 2010), a qual define uma DCN como um grafo direcional, podendo ou não conter realimentação, e cujo valores (*fuzzy* ou não) de nós e arestas são variantes no tempo. A partir desta definição, uma DCN é construída para emular o comportamento de um operador, o qual é capaz de supervisionar um processo de fermentação em condições normais e críticas. O operador interage com o processo através da aplicação de diferentes valores de *set-point* para o nível regulatório, garantido condições ótimas para a reação. A DCN resultante é considerada um sistema supervisor inteligente.

3 PROCESSO DE FERMENTAÇÃO ALCOÓLICA

O processo de fermentação utilizado nas simulações deste artigo foi estudado inicialmente por Maher (1995) e tem servido como *test-bed* pelos autores deste artigo para validar arquiteturas de controle com diferentes enfoques (Melo-Jr. et al., 2002), (Fabro e Arruda, 2003) e (Neves-Jr., Arruda e Mendonça, 2009). Um diagrama representando o processo é apresentado na figura 2. Existem duas válvulas, F_{in} e F_{out} , que controlam respectivamente o fluxo de substrato inserido no tanque e o fluxo de produto (fermentado) retirado. Estas válvulas são controladas por dois controladores independentes do tipo Proporcional – Integral - Derivativo (PID). O processo apresenta quatro variáveis de estado: as concentrações de substrato (S), de biomassa (C), de produto (P) e o volume (V) do tanque onde ocorre a fermentação. As concentrações são dadas em gramas/litro (g/l), e o volume em litros (l). As equações diferenciais descrevendo o comportamento dinâmico do processo são dadas em (4) a (7).

$$\frac{dS}{dt} = -\frac{1}{Y_{c/s}}\mu C + \frac{F_{in}}{V}S_a - \frac{F_{out}}{V}S \quad (4)$$




Figura 2: Processo de Fermentação Alcoólica

$$\frac{dC}{dt} = \mu C - \frac{F_{out}}{V}S \quad (5)$$

$$\frac{dP}{dt} = -\frac{Y_{p/s}}{Y_{c/s}}\mu C - \frac{F_{out}}{V}P \quad (6)$$

$$\frac{dV}{dt} = F_{in} - F_{out} \quad (7)$$

onde S_a é a concentração de substrato da alimentação, $Y_{P/S}$ e $Y_{C/S}$ são as constantes de conversão de biomassa e produto respectivamente. A variável μ representa a função de crescimento da biomassa durante o processo de fermentação e é dada por:

$$\mu = \mu_0 \frac{S}{K_s + S_s} \left(1 - \frac{P}{P_m}\right) \quad (8)$$

O valor inicial μ_0 corresponde a máxima taxa de crescimento, K_s é a constante de *Michaelis-Menton*, e P_m é o coeficiente de inibição do produto durante a reação. Neste artigo as equações 4 a 8 são utilizadas para simular o processo de fermentação e são resolvidas através do método de *Runge-Kutta* de 4ª ordem.

Este processo é não-linear e apresenta um comportamento de fase não mínima e tempo de acomodação grande, como mostra a figura 3. Além disso, por medida de segurança quando o volume do reservatório excede 3,5 litros, a válvula F_{in} é completamente fechada e se ao contrário o volume cair abaixo do mínimo (1,5l), a válvula de saída F_{out} é completamente fechada. Estas

duas ações são automáticas e funcionam como perturbação durante a evolução do processo.

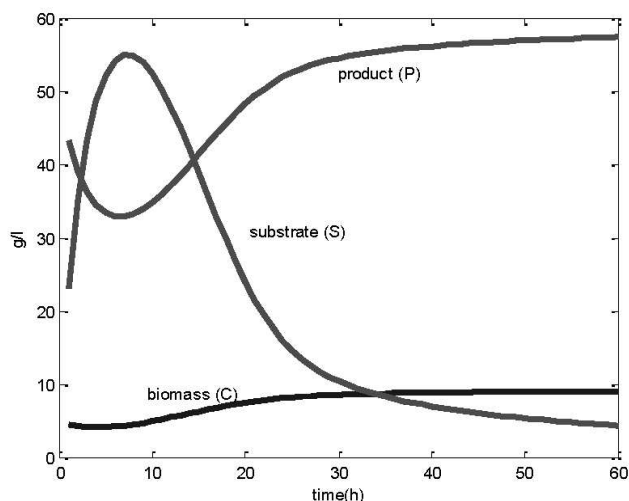


Figura 3: Comportamento dinâmico das variáveis de estado do Processo de Fermentação

4 CONTROLE SUPERVISÓRIO ATRAVÉS DE DCN

O crescente interesse pela aplicação de sistemas inteligentes no controle automático de processos industriais complexos é devido principalmente à presença de não-linearidades em regime dinâmico, e, em alguns casos baixa qualidade na aquisição de medidas, altos níveis de ruído e sensoriamento fortemente distribuído. Em geral, nesses sistemas, controlam-se apenas variáveis secundárias, as quais podem ser medidas e controladas (temperatura, pressão, fluxo, entre outros), deixando a cargo do operador a tomada de decisão que influencia a quantidade e a qualidade final e/ou parcial do processo. Com isto, o maior fator de paradas de produção é a falha humana, devido a erros inerentes à cognição humana, como por exemplo, erro de interpretação dos alarmes e respostas do sistema, sobrecarga de informação, que ocasionam erros em tomadas de decisão, entre outros.

Neste contexto, uso de sistemas inteligentes baseados em redes dinâmicas cognitivas apresentam vantagens na modelagem e simulação de sistemas complexos, devido à flexibilidade da representação do conhecimento através de grandezas *fuzzy*, agregada à facilidade de abstração do conhecimento presente nos mapas cognitivos e a possibilidade de construção de grandes mapas a partir da união de pequenos mapas que representam porções do conhecimento.

Por outro lado, a utilização de sistemas hierárquicos

para o controle supervisório é amplamente aceita na literatura (Pasino e Yurkovitch, 1998). Uma arquitetura hierárquica baseada em FCM é proposta em Stylios e Groumpos (2004) para supervisão de processos complexos. Esta arquitetura, adaptada para DCN é mostrada na figura 4, e possui um supervisor no nível superior composto por várias DCNs interconectadas, cada uma delas realizando uma tarefa específica do controle supervisório tais que detecção de falhas, monitoramento, planejamento, tomada de decisão entre outros.

Este artigo propõe o desenvolvimento de uma DCN para implementar a tarefa de operação do processo de fermentação durante uma campanha com objetivos fixos, substituindo o operador do sistema por uma tarefa do supervisor. O objetivo é minimizar os efeitos de transição de *set-points*, determinado pelas mudanças de ponto de operação, sobre as variáveis do processo e dispositivos (válvulas), além de melhorar o desempenho da reação, ao mesmo tempo em que satisfaz restrições operacionais.

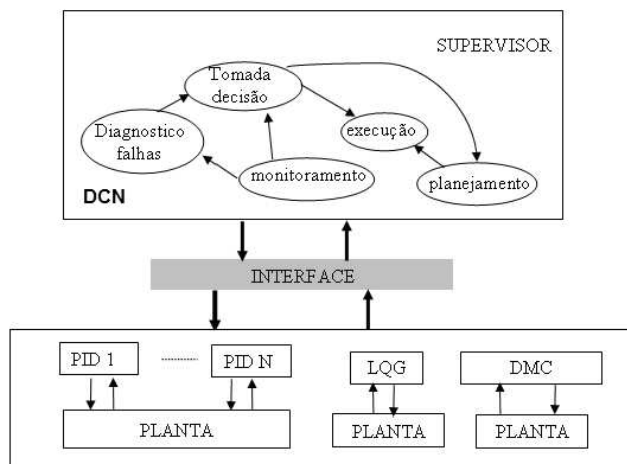


Figura 4: Arquitetura baseada em DCN para controle supervisório (adaptado de Stylios e Groumpos, 2004)

4.1 Construção da DCN para operação do fermentador.

A construção da DCN segue os passos do quadro apresentado na sessão 2.1. Entretanto, seguindo as recomendações de Miao e Liu (1999) e a arquitetura dada na figura 4, foram construídas duas DCNs distintas, uma para o modo de operação normal e outra para o modo de operação crítico. Estas redes foram desenvolvidas, testadas e validadas separadamente e em seguidas unidas para formar uma DCN maior que realiza a tarefa de supervisão do processo.

As DCNs foram construídas a partir da observação do comportamento do processo em diferentes situações e

das relações entre as suas variáveis físicas (Substrato, Biomassa, Produto e o Volume) e os dispositivos de controle (Válvulas de entrada *Fin* e saída *Fout*), após ações de controle. Para isto, além de se analisar as equações diferenciais (4) -(8) que descrevem a reação química de fermentação, procedeu-se a uma análise de causa e efeito entre as variáveis físicas (biomassa, produto, substrato e volume) do processo para diferentes valores de *set-points* dos PIDs que acionam as válvulas *Fin* e *Fout*, caracterizando os diversos pontos de operação do fermentador.

Como resultado observou-se o seguinte comportamento para o processo:

1. A concentração de produto no reator, variável controlada do processo, é afetada por variações no *set-point* do PID que controla a válvula de entrada. Este comportamento é modelado através de uma relação causal representada por um arco na DCN. (W_2)
2. A concentração de produto no reator, variável controlada, é afetada por variações no *set-point* do PID que controla a válvula de saída. (W_3)
3. O valor do *set-point* desejado do processo, que caracteriza o ponto de operação da reação, determina o valor de *set-point* efetivamente aplicado ao PID que controla a válvula de entrada. (W_4)
4. O valor do *set-point* desejado do processo, que caracteriza o ponto de operação da reação, determina o valor do *set-point* efetivamente aplicado ao PID da válvula de saída. (W_5)
5. A variação de *set-point* desejado (mudança de ponto de operação) afeta o valor do *set-point* aplicado à válvula de entrada. (W_6)
6. Variação do *set-point* desejado (mudança de ponto de operação) afeta o valor do *set-point* aplicado à válvula de saída. (W_7)
7. Uma variação acentuada na concentração (superior a 3g/l) de substrato no reator determina uma variação no *set-point* do PID que controla a válvula de entrada, a fim de garantir o equilíbrio da reação de fermentação. (W_1)
8. Esta variação da concentração de substrato não influencia o *set-point* do PID da válvula de saída, pois a inserção de substrato é feita por *Fin*, e válvula *Fout* está relacionada à retirada de produto.
9. O volume no tanque é afetado pelo valor do *set-point* da válvula *Fin*, no entanto esta relação é assimétrica e possui uma restrição quanto ao volume máximo, sendo modelada como uma relação do tipo *fuzzy*, como será explicado a seguir. (WF_1)

10. O volume no tanque é afetado pelo valor do *set-point* da válvula *Fout*, no entanto esta relação também é assimétrica e possui uma restrição quanto ao volume mínimo, sendo modelada como uma relação do tipo *fuzzy*, como será explicado a seguir. (WF_2)

A partir deste comportamento, é construída a primeira DCN para a operação do fermentador, mostrada na figura 5. Esta DCN corresponde à operação do processo em modo normal e será denominada DCNn. Como pode ser visto na figura 5, a DCNn corresponde a um grafo acíclico simples, representando o modo como um operador ajusta os *set-points* efetivamente aplicado aos PIDs do processo. O objetivo do supervisor é minimizar os efeitos de transição de *set-points*, determinado pelas mudanças de ponto de operação, e melhorar o desempenho da reação, ao mesmo tempo em que satisfaz as restrições de operação tal que manter o volume do produto dentro de seus limites.

A obtenção de um grafo acíclico ou mapa cognitivo trivial está de acordo com Miao e colaboradores (2001) que atestam que na construção por etapas de grandes mapas cognitivos, sempre aparecem mapas menores geralmente acíclicos, que correspondem a relações de causa-efeito unidirecional, bem definidas.

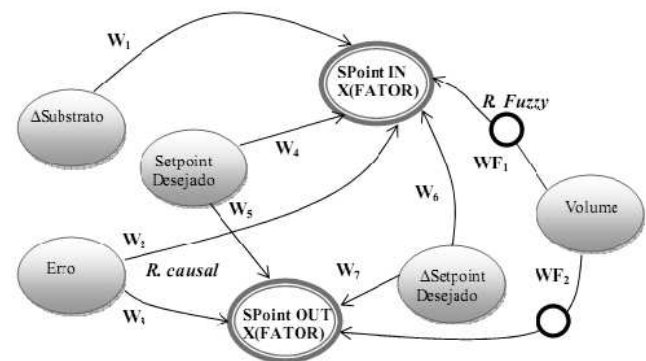


Figura 5: DCNn para operação em modo normal.

Na DCNn da figura 5, as variáveis físicas como o produto, volume e *set-point* desejado são conceitos de entrada do tipo nível e tem seus valores normalizados no intervalo [0, 1] a partir de medidas do processo. As variáveis “variação de substrato” e “variação de *set-point* desejado” são conceitos de entrada do tipo variação, e as variáveis *set-point Fin* e *set-point Fout* são variáveis de saída do tipo decisão, e assumem valores no intervalo [0, 1]. O valor de *set-point* efetivamente aplicado na entrada do PID corresponde ao valor desta decisão multiplicado pelo *set-point* desejado.

As relações W_2 a W_7 são relações causais cujos valores são obtidos a partir de dados simulados. Já a relação

Tabela 1: Relação causal do DCN₁

Conexão	Valor
W_1	-0.1
W_2	0.25
W_3	0.25
W_4 (<i>setpoint</i> =35)	-0.8845
W_4 (<i>setpoint</i> =40)	-0.507
W_4 (<i>setpoint</i> =45)	-0.223
W_5	0.25
W_6	-0.5
W_7	-0.1

W_1 é uma relação causal trivalente, determinada por restrições de equilíbrio da reação química, e dada por:

$$W_1 = \left\{ \begin{array}{l} w_1, \text{ se } \Delta_{substrato} > 3 \\ 0, \text{ se } -3 < \Delta_{substrato} < 3 \\ w_1, \text{ se } \Delta_{substrato} < -3 \end{array} \right\} \quad (9)$$

Onde: $\Delta_{substrato}$ corresponde à variação de substrato ocorrida entre dois instantes de tempo consecutivos. A matriz de conexão da DCN_n obtida a partir de dados de simulação e da aplicação dos passos 2 a 4 do algoritmo do quadro 1 é dada na tabela 1.

A intensidade da relação modelada por W_4 depende do ponto de operação do processo (valor de *set-point*) e está associado ao comportamento da reação química (Neves, Arruda e Mendonça, 2009). As relações WF_1 e WF_2 são relações *fuzzy* cujos valores são obtidos a partir de uma base de regras *fuzzy*. A criação de uma relação *fuzzy* torna-se necessária sempre que a natureza das variáveis observadas é não monotônica, isto é, as variáveis não são crescentes ou decrescentes ou estritamente crescentes e decrescentes. Esta situação ocorre com o volume em presença de variações negativas ou positivas de *set-points*, para ambas as válvulas. Para ilustrar tal comportamento, a figura 6 mostra o volume e sua variação quando ocorrem mudanças no *set-point* do PID associado à válvula *Fin*. Observa-se que as variações de volume são mais acentuadas quando ocorre transição positiva de *set-point*. De acordo com esse comportamento, foi criado um sistema *fuzzy* do tipo Mandami (Pasino e Yourkovich, 1999) que tem como entrada os valores de volume e variação de volume e como saída o valor da relação *fuzzy* WF_1 que altera o conceito do *set-point* efetivamente aplicado na válvula *Fin*.

As seguintes regras são utilizadas para calcular a relação *fuzzy* WF_1 :

- Se **volume** é baixo e **variação do volume** é média então **WF1**




Figura 6: Setpoint, volume e variação do volume.

é alta.

- Se **volume** é baixo e **variação do volume** é alta então **WF1** é alta.
- Se **volume** é baixo e **variação do volume** é baixo então **WF1** é igual a 1.
- Se **volume** é alto e existe **variação do volume** então **WF1** é baixa
- Se **volume** é médio e existe **variação do volume** então **WF1** é média.

A figura 7 mostra a superfície *fuzzy* associada à base de regras desenvolvida que descreve o efeito não-linear (WF_1) causado pelas variáveis de entrada “volume” e “variação de volume” sobre o *set-point* aplicado ao PID da válvula *Fin*.

De modo semelhante, uma relação *fuzzy* foi criada para relacionar os conceitos “volume” e “*set-point* da válvula *Fout*” através da relação dada por WF_2 .

No entanto foi constatado que em algumas campanhas de longa duração, a concentração de substrato e/ou de biomassa no interior do reator pode cair a níveis que não permitam a realização do processo de fermentação. Neste caso, a operação torna-se crítica e é necessário recuperar os componentes do processo através de uma variação de *set-point*, independente dos valores determinados para a campanha. Para isto foi desenvolvido um novo modelo que se interliga à DCN da figura 5 para a determinação dos *set-points* enviados a ambos PIDs. Este novo modelo corresponde a uma DCN para operação em modo crítico e será denominado DCN_c.




Figura 7: Superfície fuzzy da relação WF_1 .

Este novo modelo cognitivo tem por função monitorar condições críticas no processo e assim possui uma inferência orientada a eventos. A DCNc construída utiliza um outro tipo relação, denominada relação de seleção, que é modelada através de regras do tipo **SE-ENTÃO** (implicação linguística) que ativam um conceito cujo valor é retirado de um conjunto de valores discretizados (Papageorgiou, Stylios e Groumpos, 2007). Neste caso, as seguintes restrições devem ser modeladas:

1. A quantidade de biomassa não deve superar uma concentração máxima de 8 g/l.
2. Como explicado anteriormente, o volume no reator não pode exceder 3,5l, nem cair abaixo de 1,5l.
3. A quantidade de substrato não pode cair abaixo de uma concentração mínima de 0,5 g/l.
4. Os valores de *set-point* para concentração de produto correspondem a uma lista de valores de concentração discretizados no intervalo [10, 50] g/l descrevendo os pontos de operação do processo.

O modelo construído para operação crítica é mostrado na figura 8. Três novos conceitos associados às variáveis do processo: “seleção substrato”, “seleção biomassa” e “seleção volume” são inseridos para modelar o processo em operação crítica. Esses três conceitos são do tipo seleção e influenciam o valor do *set-point* a ser aplicado no processo (conceito “Set Point Processo IN” na figura 8). O número de regras associadas aos conceitos de seleção irá depender das condições modeladas. A relação de seleção de volume emprega duas regras que testam os limites máximos e mínimos para o volume, enquanto

que as relações de seleção de substrato e biomassa empregam somente uma. Essas relações e conceitos são resultantes do conhecimento empírico sobre a operação do processo.

De um modo geral, o conceito de seleção representa a ação que executa uma mudança no conceito relacionado e a relação de seleção representa o mecanismo que dispara a ativação do conceito.

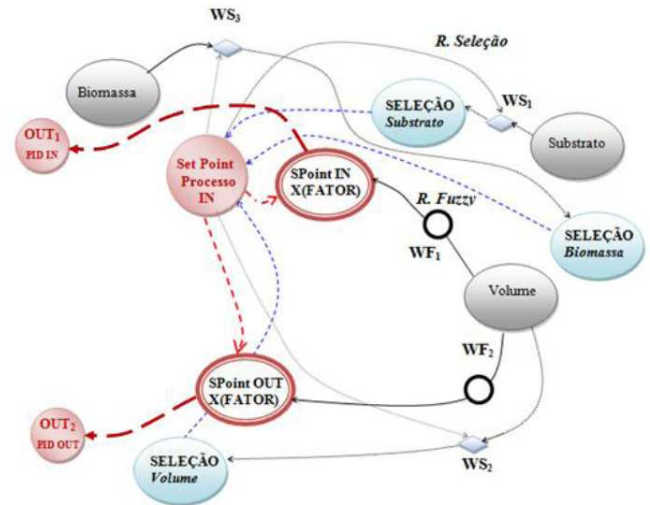


Figura 8: DCNc para operação em modo crítico. Para a DCNc da figura 8, as restrições 1 a 4 citadas acima são expressas através das seguintes regras:

- Se o volume é maior que um limiar máximo, e o *set-point* da variável de entrada “Set point processo IN” é menor que o máximo **então** incrementa o valor atual do *set-point* desejado na campanha (“Set Point processo IN”). Isto é, seleciona-se como *set-point* de entrada o próximo valor da lista de pontos de operação do processo via conceito “seleção volume” (**WS2**).
- Se o volume é menor que o mínimo e *set-point* da variável de entrada “Set Point Processo IN” é menor que o mínimo **então** decrementa valor atual de *set-point* via conceito “seleção volume” (**WS2**).
- Se a concentração de substrato é menor do que mínimo e o *set-point* atual é menor que o máximo **então** incrementa o valor de *set-point* atual do conceito de seleção “Set Point Processo IN”, via conceito “seleção substrato” (**WS1**).
- Se a concentração de biomassa é maior que o limite máximo e *set-point* atual é igual ao máximo **então** decrementar o valor de *set-point* atual do conceito de seleção “Set Point Processo IN”, via conceito “seleção biomassa” (**WS3**).

A conexão entre os dois modelos cognitivos se dá através das duas variáveis “SPoint IN” e “SPoint OUT” as quais

se conectam as variáveis de interface (OUT1 e OUT2) que enviam valores para o fermentador. Também o conceito “volume” é o mesmo para ambas DCNs. O valor das variáveis OUT1 e OUT2 é resultado do produto entre os conceitos de saída dos dois modelos.

$$out_1 = (SP_{pointIN}) \times [(WF1) \times (SetPoint_{ProcessoIn})] \quad (10)$$

$$out_2 = (SP_{pointOUT}) \times [(WF2) \times (SetPoint_{ProcessoIn})] \quad (11)$$

A figura 9 mostra a DCN resultante da união dos dois modelos cognitivos (DCNn + DCNc) para a supervisão do processo. Esta DCN final foi testada para diferentes valores de concentrações de produto, com variação de *set-point* no intervalo 10 a 50g/l e em todos eles estabeleceu em um número finito de iterações.

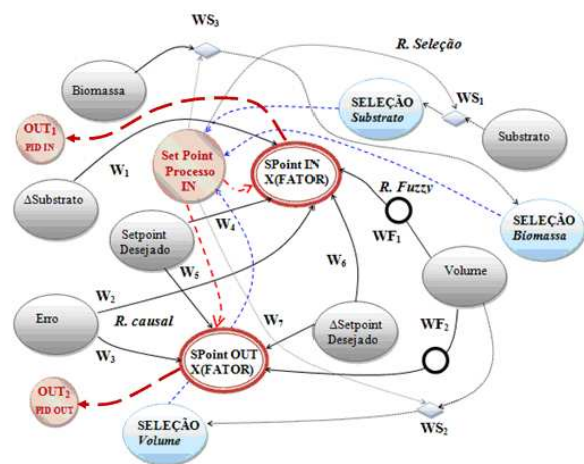


Figura 9: Supervisor baseado em DCN.

A DCN assim construída é inserida na arquitetura de controle supervísório mostrada na figura 10. Nesta arquitetura coexistem dois tipos de decisões: as decisões resultantes da análise de relações causa-efeito (relações causais e *fuzzy*) e decisões orientadas a eventos, resultantes da análise de condições específicas de operação do processo, modeladas através de uma base de regras.

As DCNs apresentados nas figuras 5, 8 e 9 são utilizados na próxima sessão para controlar o processo de fermentação apresentado na sessão 2.

5 RESULTADOS DE SIMULAÇÃO.

Três conjuntos de testes foram executados para avaliação de desempenho e robustez dessa arquitetura. Em todos eles, é simulada uma campanha que tem por objetivo levar o fermentador de um estado inicial caracterizado por uma concentração de aproximadamente 25 g/l

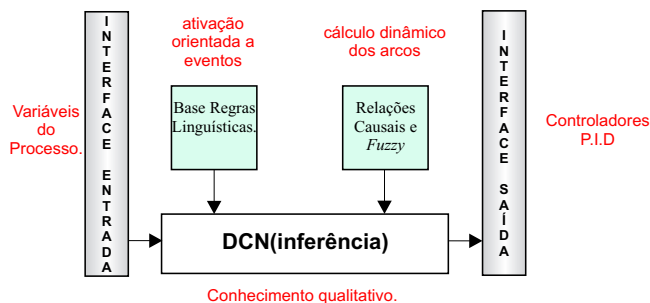


Figura 10: Arquitetura do Supervisor

de produto até um estado final em que a concentração de produto é de 45g/l, passando por 3 pontos de operação intermediários caracterizados por valores de *set-point* de 30, 35 e 40g/l.

No primeiro experimento, o processo é considerado operando em modo normal e o desempenho do controle regulatório é comparado ao controle supervísório realizado através da DCNn da figura 5. Convém ressaltar que no controle regulatório, os dois PIDs atuam a partir de um *set-point* único e o incremento de controle calculado é somado ao valor atual da válvula *Fin* e decrementado do valor atual da válvula *Fout*. No controle supervísório, a operação das válvulas é independente, o incremento de controle é calculado a partir de dois conjuntos de *set-points* distintos, um para cada PID do nível regulatório, gerado pela DCN. Além disso, quando uma das válvulas é completamente fechada, a outra também será por medida de segurança.

No segundo experimento, a mesma campanha é realizada, e conforme será explicado a seguir, a reação atinge um estado crítico após um determinado instante de tempo, sendo necessária uma operação mais criteriosa do processo. Neste caso, avalia-se o desempenho do controle supervísório realizado através da DCN da figura 9, o qual incorpora os dois modos de funcionamento (em operação normal e crítica).

No último experimento, a mesma campanha é realizada, no entanto uma falha é simulada, forçando a válvula *Fin* a permanecer temporariamente fechada durante certo instante de tempo, o que leva a uma perturbação não controlada do processo. O desempenho do controle regulatório é novamente comparado com o controle supervísório com a DCN dada na figura 9, a fim de testar o modo de operação crítica quando uma causa externa (fechamento de válvulas) leva a um desequilíbrio da reação. Em todos os experimentos as condições iniciais são dadas na tabela 2.

No experimento 1, a fim de validar a arquitetura proposta, os seguintes critérios de desempenho são calcula-

Tabela 2: Condições iniciais

Variáveis		Constantes	
S	4.5 g/l	Sa	100 g/l
C	5 g/l	Pm	100
P	50 g/l	Ks	10
V	2 l	μ_0	0.31
		YP/S	0.07
		YC/S	0.44

Tabela 3: Índices de desempenho para o experimento 1

Critério	PID	DCN+PID
ITAE	1.0729	1.0242
$\sigma_{y(\text{produto})}^2$	14.2712	14.5266
$\sigma_{(\text{erro})}^2$	1.2104e-04	9.2023e-05
$\sigma_{F_{in}}^2$	0.0156	0.0177
$\sigma_{F_{out}}^2$	0.0133	0.0132

dos para cada arquitetura: índice ITAE (*Integral Time of Absolute Value Error*) e as variâncias dos sinais de controle e saída do processo. O ITAE foi escolhido por ser um indicador de desempenho largamente aceito na comunidade de controle para avaliação de malhas PID. A variância observada no sinal de saída $y(t)$ do processo mede a robustez do sistema em malha fechada na presença de perturbações e a variância do sinal de controle $u(t)$ é um indicador da suavidade das ações de controle efetivamente utilizadas (Åström e Wittenmark, 1995). As figuras 11, 12 e 13 mostram os resultados das arquiteturas de controle obtidas com o primeiro conjunto de *set-points*. A figura 11 traz os resultados para o controle regulatório apenas com o PID, o *set-point* aplicado a ambos os controladores é o mesmo, no entanto, como explicado acima o incremento de controle calculado a partir do erro é adicionado à válvula *Fin* e decrementado da válvula *Fout*. As saídas dos PIDs estão mostradas bem como os valores das variáveis de estado concentração, substrato, biomassa e volume. Os resultados para o controle supervisorório são dados nas figuras 12 e 13. A figura 12 traz os diferentes *set-points* aplicados aos PIDs e as respostas destes controladores. A figura 13 mostra a evolução das variáveis de estado do processo. Os índices de desempenho deste experimento são dados na tabela 3.

Para a análise desses resultados, convém ressaltar que todos os valores só foram calculados até o instante $t = 285h$. Isto porque a partir deste instante para ambas as arquiteturas de controle, a reação atinge um valor limite, com volume igual a 3,5l, determinando o fechamento da válvula de entrada e em consequência a válvula de

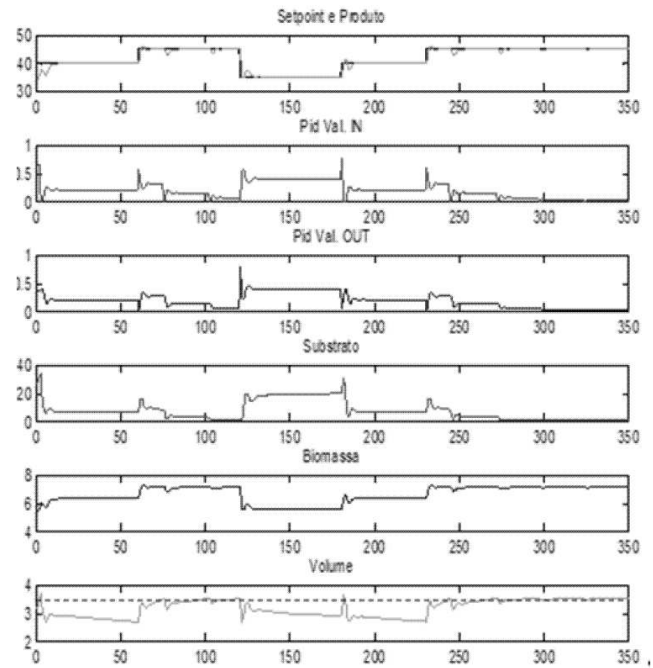


Figura 11: Controle Regulatório (PID): Experimento 1

saída também é fechada. De fato a partir deste instante a biomassa atinge sua concentração máxima de 7g/l, o substrato é inteiramente consumido e não acontece mais a reação química, ou seja, o processo é desligado. Esta situação pode ser comprovada através da análise do comportamento das variáveis citadas nas figuras 11 e 12.




Figura 12: Controle Supervisorório (DCNn + PID): Experimento 1 - Sinais de Controle

Analisando os resultados mostrados na tabela 3, nota-se que a métrica ITAE indicou um desempenho de aproximadamente 5% menor para o controle supervisorório (DCN+PID) em relação ao controle regulatório apenas, confirmado pelos valores de variância do erro. No que se refere ao sinal de saída associada à válvula *Fout*, os valores de variância (coluna $\sigma_{F_{out}}^2$) são equivalentes. O controle efetivo do processo é feito sobre a válvula *Fin* que regula a entrada de substrato no reator e que é in-




Figura 13: Controle Supervisório (DCNn + PID): Experimento 1 - Variáveis do Processo

fluenciado fortemente pelas variações de *set-points*. No instante $t = 120\text{h}$ há uma transição de *set-point* de 45g/l para 35g/l. Neste caso, para o controle regulatório o erro é calculado e as válvulas são abertas o suficiente para corrigir esse erro. Já o controle supervisorio, considera que além do erro há uma variação de substrato em instantes anteriores, em consequência o valor de $W1$ é invertido (relação trivalente dada pela equação 9), diminuindo mais ainda o valor do *set-point* desejado e determinando uma abertura completa da válvula *Fin*. Este fato é responsável pelas diferenças observadas nos valores de variância da válvula *Fin* (coluna σ_{Fin}^2) e da variável de saída, gerando uma variação do sinal de controle na válvula *Fin* 13,5% maior para o controle supervisorio. No entanto o impacto disto na variância de saída do controle supervisorio é de apenas 1,8% em relação ao controle regulatório. As variações positivas de *set-point* são tratadas igualmente por ambas as arquiteturas.

Em resumo, para o modo de operação normal com diferentes variações de *set-point*, o comportamento do controle supervisorio é equivalente ao controle regulatório, indicando que quando não há ocorrência de eventos críticos, se a malha de controle regulatório está operando satisfatoriamente a inclusão de um nível supervisorio não interfere nesta operação. O supervisor cumpre assim o seu papel.

Durante a simulação da campanha, como explicado anteriormente, uma situação crítica para o processo ocorre a partir do instante $t = 285\text{h}$, determinando o fechamento do reator (as válvulas *Fin* e *Fout* são completamente fechadas) e o término da reação (ver figura 11). Para analisar esta situação, um segundo experimento, exatamente igual ao primeiro é realizado, a diferença é que neste experimento o controle supervisorio incorpora o modo de operação crítico, sendo assim implementado pelo modelo cognitivo dinâmico (DCN) da figura 9.

As figuras 14 e 15 mostram os resultados obtidos com controle supervisorio realizado pela DCN. A partir de uma avaliação das variáveis do processo, um novo con-

Tabela 4: Índices de desempenho para o experimento 2

Critério	PID	(DCNn+PID)	(DCN+PID)
ITAE	1.0192	1.0038	0.9771
$\sigma_y^2(\text{produto})$	13.5921	13.6985	13.4003
$\sigma^2(\text{erro})$	1.3708e-004	1.2696e-004	1.0728e-004
σ_{Fin}^2	0.0154	0.0169	0.0220
σ_{Fout}^2	0.0127	0.0118	0.0169

junto de *set-points* diferentes do experimento 1, é gerado pela heurística modelada pela base de regras. Por exemplo, um pouco antes do instante em que ocorre a transição de *set-point* de 45g/l para 35g/l ($t = 115\text{h}$ até $t = 120\text{h}$), o supervisor agora comandado pela DCN da figura 9, gera um *set-point* intermediário de 40g/l, a fim de recuperar a quantidade de substrato que está caindo. Com isso, quando ocorre a transição de *set-point* em $t = 120\text{h}$, os erros considerados nos PIDs são menores e os sinais de controle calculados também são menores se comparados com os do experimento 1 (compare os gráficos das figuras 12 e 14 em $t = 120\text{h}$). A fim de comprovar, a atuação do supervisor DCN, os índices de desempenho são recalculados até o instante $t = 250\text{h}$, para as três arquiteturas de controle: regulatório (PID), supervisorio com a DCNn (etapa 1) da figura 5 (DCNn+PID) e supervisorio com a DCN da figura 9 (DCN+PID). Estes valores são dados na tabela 4 e mostram que o supervisor DCN+PID apresenta um desempenho ligeiramente superior às outras duas arquiteturas.




Figura 14: Controle Supervisório (DCN+PID): Experimento 2 - Sinais Controle

Do mesmo modo, analisando ainda as figuras 14 e 15, a situação crítica que no experimento 1 ocorre a partir de $t = 285\text{h}$, é antecipada (a concentração mínima de substrato considerada pela DCN não pode cair abaixo de 0,5 g/l), e o supervisor determina logo no instante $t = 264\text{h}$ (ver figura 14) uma diminuição do *set-point* de 45 g/l




Figura 15: Controle Supervisório (DCN+PID): Experimento 2 - Variáveis do Processo

para 40g/l e logo em seguida para 35g/l. Este *set-point* permanece até o instante $t = 275$ h, quando o supervisor tenta recuperar o *set-point* determinado para a campanha e incrementa o *set-point* aplicado para 40 g/l e em seguida para 45 g/l. Esta situação se repetirá indefinidamente, a menos que o *set-point* da campanha seja expressamente diminuído a fim de retirar a reação de seu estado crítico, caracterizado por concentração de $P = 45$ g/l, concentração de substrato $S = 0.5$ g/l, concentração de biomassa $C = 7$ g/l e volume $V = 3,5$ l (valores aproximados).

Como conclusão do experimento 2, tem-se que a combinação dos dois modelos (DCNn e DCNc), uma para cada modo de operação normal e crítica, em um único supervisor melhora o comportamento do processo em ambas as situações (normal e crítica), validando a arquitetura proposta.

O terceiro experimento analisa o comportamento do supervisor DCN quando ocorre uma falha no processo. Neste caso, simulou-se um fechamento temporário (travamento) da válvula *Fin* durante os instantes $t = 195$ h até $t = 205$ h, cortando a entrada de substrato no reator. Novamente compara-se o desempenho do controle regulatório, mostrado na figura 16, com o desempenho do controle supervisorório feito pelo modelo cognitivo da figura 9 (DCN) que é ilustrado nas figuras 17 e 18. Nestas figuras é mostrado apenas o comportamento das variáveis do processo a partir do instante $t=150$ h. Analisando-se os gráficos na figura 16, observa-se uma parada na reação química logo após o fechamento da válvula *Fin*, com controle regulatório apenas. A válvula *Fout* também é fechada, a concentração de produto cai, mas é recuperada tão logo a válvula seja liberada. No entanto a retirada de produto do reator é mínima, as válvulas estão praticamente fechadas, (instantes $t =$

210h até $t = 230$ h) até que ocorra a mudança de *set-point* em $t = 230$ h. A partir deste ponto, o controle regulatório, tenta manter a concentração de produto, com uma retirada pequena (valores de sinal de controle *Fin* e *Fout* pequenos) até que novamente uma situação crítica é atingida ($t = 280$ h) e as válvulas são fechadas, parando outra vez a reação.

Com o controle supervisorório, o fechamento da válvula *Fin*, leva a uma diminuição do *set-point* de 40g/l para 35g/l enquanto durar o travamento da válvula, em seguida este *set-point* é restaurado, e a retirada de produto não é prejudicada (figuras 17 e 18). Quando ocorre a mudança de *set-point* em $t = 230$ h os efeitos do fechamento da válvula *Fin* já não são mais sentidos, e como no experimento 2, o processo antecipa o estado crítico da reação e tenta recuperá-la como acontece no experimento 2




Figura 16: Controle Regulatório (PID): Experimento 3




Figura 17: Controle Supervisório (DCN+PID): Experimento 3 - Sinais Controle

Como resultado do experimento 3, conclui-se que apesar do supervisor não ter sido especificamente projetado para funcionar durante uma falha causada por agentes externos, este é capaz de amenizar a influência da falha

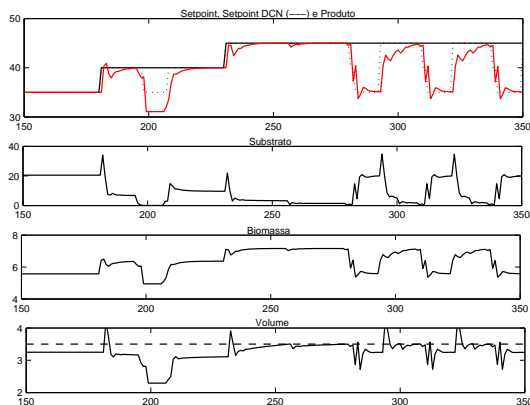


Figura 18: Controle Supervisório (DCN PID): Experimento 3 - Variáveis do Processo

sobre o desempenho do processo, validando mais uma vez a função da arquitetura proposta. Uma das vantagens do uso da arquitetura proposta está no fato de que novas funções tais que alarme de situação crítica para a reação e detecção de falhas como as que ocorrem nos experimentos mostrados podem ser facilmente incorporadas ao supervisor, através da criação de novos modelos cognitivos. Estes novos modelos cognitivos são conectados entre si, através de conceitos comuns, configurando-se num supervisor completo como o proposto na figura 9.

6 CONCLUSÃO

Este trabalho desenvolveu um sistema supervisório baseado em redes cognitivas dinâmicas, as quais são uma evolução dos mapas cognitivos, para o controle de um processo de fermentação. O supervisor representa uma abstração do conhecimento especialista sobre o comportamento do processo em operação normal e com restrições. A construção do mapa cognitivo foi obtida através de análise de resultados de simulação, utilizando exclusivamente conhecimento qualitativo, não sendo necessária a utilização de um modelo matemático do processo. O supervisor assim obtido é bastante simples, de fácil implementação e de fácil compreensão, e apresentou um bom desempenho nas situações simuladas.

Apesar de implementar apenas a ação de calcular *set-points* para o controle regulatório em modo de operação normal e crítico, o supervisor proposto pode ser facilmente expandido, para incorporar outras tarefas supervisórias tais que detecção de falhas, escalonamento de ganho, inferência, entre outras. Para isto basta que sejam construídos novos modelos baseados em mapas mentais do tipo DCN que sejam associados a estas tarefas e conectados entre si constituindo um supervisor completo como mostrado na figura 4. Atualmente, uma

DCN para análise de tendência (inferência) de variáveis está em vias de desenvolvimento.

Uma das restrições à utilização de modelos baseados em mapas cognitivos, como por exemplo, os FCMs, na representação de sistemas dinâmicos mais frequentes na literatura é que os FCMs apesar de simples não são capazes de modelar os diversos tipos de relação existentes em sistemas dinâmicos, principalmente aqueles relacionados à realimentação e ao comportamento temporal das variáveis. De fato, um mapa cognitivo ou um FCM construído segundo a proposta original de Axerold (1976) e/ou Kosko (1986) somente representa relações causais monotônicas e simétricas. Para contornar este problema, foi proposto neste artigo o uso de diferentes tipos de conceito (nível, variação, decisão e seleção) e de relações (causal, *fuzzy*, implicação linguística) capazes de modelar todos os relacionamentos existentes entre as variáveis de um sistema dinâmico. Este novo tipo de mapa cognitivo, denominado rede cognitiva dinâmica, estende a abordagem proposta em (Miao et al, 2001) na medida em que utiliza novas formas de cálculo dinâmico dos arcos de um mapa cognitivo.

Esta nova ferramenta foi inserida em uma arquitetura em que partes do mapa cognitivo são acionadas continuamente e outras apenas a partir da ocorrência de eventos. Com isso foi possível emular as ações de um operador humano para a correta supervisão de uma malha de controle de processos. O sistema resultante “supervisor + processo” pode ser considerado um sistema híbrido em que é possível monitorar e calcular variáveis contínuas, ao mesmo tempo em que determinadas ações são realizadas a partir da ocorrência de eventos discretos.

Desta forma, a DCN apresentada é um sistema computacional inteligente com capacidade de inferência que abstrai e modela o conhecimento humano de forma estruturada por meio de relações de causa-efeito e/ou baseado em regras. Através dela, é possível modelar de forma similar comportamentos dinâmicos contínuos e/ou orientado a eventos. Além disso, apesar de não ter sido explorado neste artigo, é possível refinar a DCN (versão final modelo cognitivo), conferindo-lhe capacidade de generalização a partir de um conjunto de dados, através do uso técnicas de aprendizado baseado em metaheurísticas tais que algoritmos evolucionários, *simulated annealing*, enxames de partículas entre outras, ou ainda técnicas de aprendizado por reforço.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro da Agência Nacional do Petróleo (ANP) através do CTPE-TRO/FINEP Financiadora de Estudos e Projetos: Programa de Recursos Humanos para o Setor de Petróleo e Gás Natural (PRH-ANP/MCT 10 UTFPR) e ao CNPq.

REFERÊNCIA BIBLIOGRÁFICA

- Aguilar J. (2004). Dynamic random fuzzy cognitive maps, *Computación y Sistemas*, Vol. 7, no. 4, pp. 260-270.
- Åström, K.J. and B., Wittenmark (1995). *Adaptive Control*, 2nd ed., Addison–Wesley, Reading, MA.
- Axelrod, R. (1976). *Structure of Decision: the Cognitive Maps of Political Elites*. Princeton University Press, New Jersey.
- Carvalho, J.P.B. (2001). Mapas cognitivos baseados em regras difusas: modelação e simulação da dinâmica de sistemas qualitativos. Dissertação de doutorado. Universidade Técnica de Lisboa, Lisboa, Portugal.
- Chun-Mei, L. (2008). Using fuzzy cognitive map for system control. *WSEAS Transactions on Systems*, Vol. 7, no. 12, pp 1504-1515.
- Dickerson, J.A. and B. Kosko (1994). Virtual worlds as fuzzy cognitive maps. *Presence*, Vol. 3, no. 2, pp. 173-189.
- Fabro, J.A. and L.V.R. Arruda (2003). Fuzzy-neuro predictive control, tuned by genetic algorithms, applied to a fermentation process. *Proceedings of the 2003 IEEE International Symposium on Intelligent Control*, Houston, Texas.
- Ghazanfari, M., Alizadeh, S. and Jafari, M., (2002). Using Fuzzy Expert System for solving fuzzy system dynamics. *Proceeding of the first EuroAsia-Advances in Information and Communication Technology Conference*, Shiraz, Iran.
- Ghazanfari, M., S. Alizadeh, M. Fathian, and D.E. Koulouriotis (2007). Comparing simulated annealing and genetic algorithm in learning FCM. *Applied Mathematics and Computation*, Vol. 192, pp. 56–68.
- Haykin, S. (2000). *Redes Neurais, Princípios e Prática* Bookman C. Editora, São Paulo, 2ª Edição.
- Huang Y.C. and X.Z. Wang (1999). Application of fuzzy causal networks to waste water treatment plants, *Chemical Engineering Science*, Vol. 54, no. 13-14, pp. 2731-2738.
- Jones, P.M., R. Roy and J. Corbett (2004). Modeling physical systems using fuzzy inference cognitive maps, *IEEE Annual Meeting of Fuzzy Information Processing, NAFIPS '04.*, Vol. 2, pp. 533-538.
- Kempowsky, T., A.Subias and J. Aguilar-Martin (2006). Process situation assessment: from a fuzzy partition to a finite state machine. *Engineering Applications of Artificial Intelligence*, Vol. 19, pp. 461 – 477.
- Kosko, B., (1986). *Fuzzy Cognitive Maps*. *Int. Journal of Man-Machine Studies*, Vol. 24, pp. 65-75.
- Kottas T.L., Y.S Boutalis and M.A. Christodoulou (2007). Fuzzy cognitive network: A general framework. *Intelligent Decision Technologies*, Vol. 1, pp. 183-196.
- Koulouriotis, D.E., I.E. Diakoulakis and D.M. Emiris (2001). Learning fuzzy cognitive maps using evolution strategies: a novel schema for modeling and simulating high-level behavior. *Proc. of IEEE Congress on Evolutionary Computation*, pp. 364–371.
- Koulouriotis, D.E., I.E. Diakoulakis, D.M. Emiris and C.D. Zopounidis (2005). Development of dynamic cognitive networks as complex systems approximators: validation in financial time series. *Applied Soft Computing*, Vol. 5, no. 2, pp. 157-179.
- Lee K.C. and S. Lee (2003). A cognitive map simulation approach to adjusting the design factors of the electronic commerce web sites. *Expert Systems with Applications*, Vol. 24, no. 1, pp. 1-11.
- Maher, M.(1995). *Modélisation et élaboration d’algorithmes d’estimation et de commande: Application à um bioprocédé*, Ph.D. dissertation, Université Paul Sabatier, LAAS/CNRS, Toulouse, France.
- Melo Jr., W.S., M. A. Evangelista, L.V.R. Arruda, F. Neves Jr. and L.C.A. Rodrigues (2002). Controle preditivo multivariável baseado em modelo adaptativo aplicado a um fermentador alcoólico. *Anais do XIV Congresso Brasileiro de Automática*, Natal, RN, Brazil, pp. 2816–2821.
- Miao, Y. and Z.Q. Liu (1999). On causal inference in Fuzzy Cognitive Maps. *IEEE Transactions on Fuzzy Systems*, Vol. 8, no. 1, pp. 107-119.

- Miao, Y., Z.Q. Liu, C.K. Siew and C.Y. Miao (2001). Dynamical cognitive network — an extension of fuzzy cognitive. *IEEE Trans. on Fuzzy Systems*, Vol. 9, no. 5, pp. 760-770.
- Miao, Y., C.Y. Miao, X.H. Tao, Z.Q. Shen, and Z.Q. Liu (2010). Transformation of cognitive maps. *IEEE Trans. on Fuzzy Systems*, Vol. 18, no. 1, pp. 114-124.
- Neves-Jr. F., L.V.R. Arruda and M. Mendonça (2009). A combined FCM-GA approach to supervise industrial process. *IFAC-SAFEPROCESS - 3rd International Conference on Safety and Security Engineering*, Barcelona, Spain.
- Pajares, G. and J.M. de la Cruz (2006). Fuzzy cognitive maps for stereovision matching. *Pattern Recognition*, Vol. 39, no. 11, pp. 2101-2114.
- Papageorgiou E., D.C. Stylios and P.P. Groumpos (2003). An Integrated two-level hierarchical system for decision making in radiation therapy based on fuzzy cognitive maps. *IEEE Transactions on Biomedical Engineering*, Vol 50, no. 12, pp. 1326-1339.
- Papageorgiou, E.I., D.C. Stylios and P.P. Groumpos (2004). Active hebbian learning algorithm to train fuzzy cognitive maps. *Int. Journal of Approximate Reasoning*. Vol. 37, no. 3, pp. 219-249.
- Papageorgiou, E.I., D.C. Stylios and P.P. Groumpos (2007). Novel architecture for supporting medical decision making of different data types based on fuzzy cognitive map framework. *Proc. of the 29th Annual Int. Conference of the IEEE EMBS*, Lyon, France.
- Passino, M.K. and S. Yourkovich (1999). *Fuzzy Control*, Addison - Wesley Pub. Co., USA.
- Petalas, Y.G., K.E. Parsopoulos and M.N. Vrahatis (2009). Improving fuzzy cognitive maps learning through memetic particle swarm optimization, *Soft Computing*, Vol. 13, pp. 77-94.
- Perusich, K (1996) Fuzzy cognitive maps for policy analysis. In *Proc. Int. Symp. Technol. Soc. Tech. Expertise Public Decisions*, New York, pp. 369-373.
- Stach, W., L. Kurgan, W. Pedrycz, and R. Marek (2005) Genetic learning of fuzzy cognitive maps. *Fuzzy Sets System*, Vol. 153, pp. 371-401.
- Stylios, D.C. and P.P. Groumpos (2000). Fuzzy cognitive maps in modeling supervisory control systems. *Journal of Intelligent & Fuzzy Systems*, Vol. 8, no. 2, pp. 83-98.
- Stylios, D.C. and P.P. Groumpos (2004). Modeling complex systems using fuzzy cognitive maps. *IEEE Trans. on SMC – part A: Systems and Humans*, Vol. 34, no. 1, pp. 115-162.
- Stylios D.C., V.C. Georgopoulos, G.A. Malandraki and S. Chouliara (2008). Fuzzy cognitive map architectures for medical decision support systems. *Appl. Soft Computing*, Vol. 8, no. 3, pp. 1243-1251.
- Taber, R. (1991). Knowledge processing with fuzzy cognitive maps. *Expert Systems with Applications*, Vol. 21, pp. 83-87.
- Wang, X.Z., S.A. Yang, E. Veloso, M.L. Lu, and C. McGreavy (1995). Qualitative process modeling—a fuzzy signed directed graph method. *Computer Chem. Engineering*, Vol. 19, pp 735-740.
- Zadeh L.A, (1992). *An introduction to fuzzy logic applications in intelligent systems*, 1st edn. Kluwer Academic Publisher, Boston.
- Zhang J.Y., Z.Q. Liu and S. Zhou (2006). Dynamic domination in fuzzy causal network. *IEEE Transactions on Fuzzy Systems*, Vol. 14, no. 1, pp. 42 - 57.