

DIAGNÓSTICO DE DISTÚRBIOS UTILIZANDO REPRESENTAÇÃO DE CONHECIMENTO DO ESPECIALISTA PARA UMA PLANTA INDUSTRIAL - TENNESSEE EASTMAN PROCESS

Abstract – This work presents a methodology to represent the knowledge of a specialist about the disturbances in a didactic plant. Experience is shown through logical rules and translated into a neural network that serves as the engine of inference. The presentation of a neural network that represents the knowledge about the aspects of the plant is important to combine the expert knowledge with connectionism present in the neural networks, therefore an information that is not completely described can be improved through examples introduced to the neural network and later presented again through logical rules. The CILP (Connectionist Inductive Learning and Logic Programming) system, which is a neural network describing the behavioral logic, is used to represent disturbances and the plant refers to the Tennessee Eastman (TE) Benchmark. The objective of this process is to produce two products (G, H) in the presence of four reagents (A, C, D, E). The process totals 12 manipulated variables and 41 measurements available for plant monitoring and control. In addition, 20 disturbances are available, of which 10 are studied.

Keywords – Intelligent Systems, Industrial Automation, Knowledge Representation, Chemical Processes, Disturbances.

Resumo – Este trabalho apresenta uma metodologia para representar o conhecimento de um especialista sobre os distúrbios em uma planta didática. A experiência é mostrada através de regras lógicas e traduzida para uma rede neural que serve como motor de inferência. A apresentação de uma rede neural que represente o conhecimento sobre os aspectos da planta é importante para combinar o conhecimento especialista com o conexionismo presente nas redes neurais, desse modo uma informação que não esteja completamente descrita poderá ser aprimorada através de exemplos apresentados a rede neural e depois apresentada novamente através de regras lógicas. Foi utilizado para a representação dos distúrbios o sistema CILP (*Connectionist Inductive Learning and Logic Programming*) que é uma rede neural que descreve a lógica do comportamento e a planta refere-se ao Benchmark do processo Tennessee Eastman (TE). O objetivo deste processo é produzir através de duas reações, dois produtos (G, H) diante de quatro reagentes (A,C,D,E). O processo totaliza 12 variáveis manipuláveis e 41 medições disponíveis para monitoramento e controle da planta. Além disso, são disponibilizados 20 distúrbios, dos quais 10 são utilizados.

Palavras-chave – Sistemas Inteligentes, Automação Industrial, Representação do Conhecimento, Processos Químicos, Distúrbios.

1 Introdução

Durante certo tempo a comunidade acadêmica de engenharia química especificamente a área de automação e controle de processos, mostrou interesse em estudar um problema real de tecnologia para teste de controle de processo. O *American Institute of Chemical Engineers* (AIChE) iniciou uma sessão tratando de temas relacionados à problemas de teste na indústria química, pelo qual esse problema apareceu pela primeira vez. Em consequência, Downs and Vogel (1993, *apud* Souza, 2017, p. 52) encontraram um processo que acreditaram ser adequado para o uso como um *benchmark*. Este processo é conhecido como o *Tennessee Eastman* (TE), que até hoje é amplamente utilizado na literatura para comparação e/ou validação de algoritmos.

Este *benchmark* foi classificado como um modelo de processo multivariável e não-linear, codificado em um conjunto de sub-rotinas na linguagem FORTRAN, descrevendo as relações no processo conforme implementadas por Downs and Vogel (1993, *apud* Souza, 2017, p. 73). Quanto à simulação, foi utilizado para obtenção dos resultados o software MATLAB® como ambiente de trabalho para o código implementado. Juntamente com a implementação, a simulação do processo também disponibiliza um conjunto de rotinas para 20 distúrbios.

Neste trabalho pretende-se conhecer as regras lógicas para a caracterização de cada distúrbio. Um especialista pode determinar quais serão as variáveis afetadas para então definir uma metodologia de como extrair o conhecimento adquirido pela experiência profissional dos operadores sobre o comportamento de

10 distúrbios distribuídos a serem incorporados em um sistema especialista baseado em rede neural.


O conhecimento de especialistas sobre o comportamento de distúrbios da planta é adquirido através da experiência na operação. O presente trabalho procura traduzir essa experiência em uma rede neuro-conexionista na qual os neurônios juntamente com os pesos sinápticos representam a lógica do comportamento dos distúrbios definidos por regras lógicas. A rede neural desenvolvida oferece uma maneira de executar paralelamente todas as regras para determinação dos distúrbios por meio do conhecimento do especialista.



2 Aspectos Teóricos

Nesta seção é apresentado o funcionamento geral do processo (TE), sua constituição, produtos e subprodutos gerados.

2.1 Descrição do processo

Para um melhor entendimento quanto ao processo (TE), a Figura 1 descreve de forma clara seu funcionamento. Os reagentes gasosos (A, D, E) são alimentados pelo reator, os quais na presença de um catalisador e um componente inerte (B) reagem com o elemento (C), que é alimentado pelo compressor de reciclo a partir da coluna de *stripper*, formando os produtos líquidos (G, H) resultantes de (1) e (2) e o subproduto (F) resultado de (3) e (4):





Caracterizando a reação que acontece no reator como exotérmica, que possui um pacote de resfriamento que tem como objetivo evitar o superaquecimento do sistema. Dessa forma, os produtos saem dele como vapores junto à alimentação não reagida. Como o catalisador é uma substância não volátil, o mesmo necessariamente permanece no reator. Os vapores provenientes do reator são parcialmente condensados no condensador, de onde seguem para o separador vapor-líquido.

No separador, os componentes não condensados são reciclados de volta, através de um compressor de reciclo, para a alimentação do reator. Outra parte dos componentes não condensados seguem para o descarte, sendo (A), (B) e (F) os principais componentes a serem descartados, o que fica claro com a realização da simulação. A remoção de (F) nessa etapa é de extrema importância para a obtenção de uma maior pureza do produto final, visto que o mesmo é um produto não desejado. A grande presença de (A) no descarte se dá devido à baixa presença deste na fase condensada.

Quanto aos componentes líquidos, estes constituem a carga de coluna do *stripper*. Nessa coluna, ocorre a remoção parcial dos reagentes remanescentes (D, E) por meio do contra fluxo da corrente 4 predominante no componente C, a qual funciona como gás de arraste. (Cortez, 2016; Heidrich, 2004).




Figura 1. Diagrama do processo Tennessee Eastman (TE).

Atingindo o objetivo do processo TE, os produtos saem da base de extração e por fim, são separados em uma seção de refinação após o processo.

2.2 Sistemas especialistas

Nas áreas de engenharia, muitas aplicações que utilizam o diagnóstico de perturbações, aplicam técnicas baseadas no conhecimento buscando

resoluções cada vez mais próximas de ações humanas, uma dessas técnicas é conhecida como sistemas especialistas. A experiência de um especialista pode ser formulada em termos de regras, que podem ser combinadas com o conhecimento dos seus princípios ou uma descrição estrutural do sistema para diagnosticar perturbações. Um sistema especialista bem desenvolvido é capaz de representar o conhecimento especializado existente, acomodam bancos de dados, acumulam novos conhecimentos, fazem inferências lógicas, estabelecem recomendações, e tomam decisões com raciocínio. A forma mais simples de representação do conhecimento em um sistema especializado é usar uma série de regras IF-THEN para representar o conhecimento especializado no sistema. A maioria dos sistemas especialistas industriais usam um sistema baseado em regras, o qual é composto por uma base de regras, uma memória de trabalho e um interpretador (Chiang et al., 2001). Neste trabalho aplica-se o conceito de sistemas especialistas ao ser definida a base de regras e a memória de trabalho é utilizada na rede neural para representar o interpretador da regra.

3 Metodologia

A metodologia utilizada para o desenvolvimento do trabalho está relacionada em fazer o levantamento dos processos que ocorrem na planta. Quanto ao conhecimento do especialista sobre distúrbios, é construída uma ferramenta de decisão baseada nos conjuntos estatísticos determinados através da análise dos especialistas. Esta ferramenta é representada pela função de uma rede neural específica, CILP, que incorpora regras lógicas definidas pelos conjuntos de médias e variâncias.

3.1 Representação do conhecimento do especialista sobre os distúrbios

De uma forma geral, a etapa inicial relacionada ao funcionamento da planta é importante, pois, torna-se necessária para a junção dessa fase seguido da representação do conhecimento do especialista na presença ou não de distúrbios. A Figura 2 ilustra o fluxograma com todas as etapas de representação do conhecimento aplicado à planta de (TE).

Os dados estatísticos utilizados (média e desvio padrão) são utilizados como indicativo para a construção de regras, que através da experiência do operador, são descritos também conjuntos válidos de pertinência, símbolos lógicos e a associação desses símbolos lógicos no formato proposicional das regras. Todos esses passos definem a base de regras a serem utilizadas.

Depois da etapa de identificação, a base de regras é traduzida para a rede neural conforme descrita na figura seguinte como Especialista Computador que poderá a partir do cálculo contínuo e iterativo de média juntamente com o desvio padrão, diagnosticar a situação atual da planta.

O monitoramento do distúrbio apresenta finalmente a situação da planta, que dependerá de como as regras foram construídas.




Figura 2. Fluxograma geral de representação do conhecimento aplicado ao processo de (TE).

Deve-se apresentar a experiência analisando os gráficos de desempenho das diversas entradas do sistema. Um especialista utiliza desse conhecimento para determinar se os valores estão nos limiares permitidos ou então detectar qual problema pode estar ocorrendo. O método de como escolher estes limites dependem essencialmente do conhecimento que os especialistas possuem das variáveis da planta e que requerem um tempo necessário para que os operadores determinem os modelos de comportamento. Neste trabalho, esse papel foi realizado analisando medidas estatísticas de sinais na presença ou ausência de distúrbios. Esses sinais foram obtidos a partir da aplicação dos distúrbios definidos na Tabela 1, nas entradas da simulação do processo (TE), realizada no *Simulink*. Esses distúrbios provocaram os sinais utilizados como base para as análises estatísticas. Ao visualizar os gráficos que representam as saídas na presença de um conjunto de distúrbios.

Tabela 1. Distúrbios do processo de *Tennessee Eastman* (TE).

Número da Variável	Variável do Processo	Tipo
IDV(1)	Razão de alimentação A/C, composição de B constante (Corrente 4)	Degrau
IDV(2)	Composição de B, razão A/C constante (Corrente 4)	Degrau
IDV(4)	Temperatura de entrada da água de refrigeração do reator	Degrau
IDV(8)	Composição de A, B, C na alimentação (Corrente 4)	Variação Aleatória
IDV(9)	Temperatura da alimentação D (Corrente 2)	Variação Aleatória
IDV(10)	Temperatura da alimentação C (Corrente 2)	Variação Aleatória
IDV(11)	Temperatura de entrada da água de refrigeração do reator	Variação Aleatória
IDV(12)	Temperatura de entrada da água de refrigeração do condensador	Variação Aleatória
IDV(14)	Válvula da água de refrigeração do reator	Agarramento
IDV(15)	Válvula da água de refrigeração do condensador	Agarramento

Os distúrbios sensibilizam os sinais de maneira diferente e isto foi percebido através de medidas estatísticas para cada perturbação. Deste modo, a cada perturbação estudada foram verificadas quais variáveis apresentaram-se sensibilizadas de maneira diferente a situação normal visualizando a média e o desvio padrão. Foi aplicado um limiar inferior e superior de 5% nestas medidas para indicar a situação de comportamento anômalo.

Apesar do sistema apresentar um total de 41 saídas, para esta pesquisa foram selecionadas 12 saídas de acordo com suas relevâncias para o processo, com o objetivo de abranger as principais variáveis, como temperatura do fluido de refrigeração do reator, composição da saída dos produtos, pressão do reator, dentre outras. Dessas 12 variáveis controladas, foi observado durante a determinação dos símbolos que apenas três destas, como visto na Tabela 2, são suficientes para determinar os distúrbios considerados relevantes.

Tabela 2. Variáveis manipuladas da *Tennessee Eastman* (TE).

Número da variável	Variável controlada
Saída 1	Alimentação de A (kscmh)
Saída 7	Pressão do reator (kPa)
Saída 9	Temperatura do reator (°C)

Para algumas saídas, esses limites excederam os pontos de mínimo e máximo dos sinais provocados por alguns distúrbios, causando uma incoerência com relação a esses dados. Para estes casos, os pontos de mínimo e de máximo foram estipulados como os novos limites e, desta forma, apresentando limiares abaixo de 5%. Essa abordagem determina o conhecimento adquirido do processo, pois deve-se identificar os distúrbios que ocorrem analisando apenas a entrada de sinais. Em uma segunda etapa, são determinados os símbolos lógicos que serão entregues à rede neural.

Os símbolos correspondem a uma representação escrita dos conjuntos de sinais que correspondem os distúrbios. Estes conjuntos são compostos pela interseção dos subconjuntos, de média ou desvio padrão, dos sinais de entrada que serão fornecidos à rede neural. Esses valores de entrada serão comparados a um subconjunto e se esses valores de entrada, que são as médias e desvios padrões das respostas do processo, pertencerem a um subconjunto de um desses parâmetros estatísticos simultaneamente, então o distúrbio associado a aqueles subconjuntos será determinado. A escolha desses símbolos foi realizada através dos sinais que melhor caracterizam os distúrbios.

Desta forma são calculados continuamente a média e variância, caso estejam nas determinadas faixas de valores especificadas, um sinal de entrada é ativado na rede neural. A determinação do distúrbio que está ocorrendo é verificada através das medidas dessas variâncias e médias dos sinais. O especialista

define quais são sensíveis à presença de um distúrbio e entrega para a rede essa informação.

Uma vez a rede treinada, os neurônios são capazes de na presença de um conhecimento aproximado da planta, descrever o que realmente ocorre (conhecimento exato). Este conhecimento é determinado de maneira a oferecer a oportunidade de que novas informações sejam adicionadas, caso alguma informação não seja verdadeira, a rede pode se ajustar baseado em *feedbacks* do que realmente ocorre.

Além de representar o conhecimento, pretende-se extrapolar essa característica permitindo que a rede aprenda com os próprios erros de diagnóstico e consiga melhorar as conexões com o propósito de corrigir informações incorretas ou incompletas transmitidas pelos especialistas. Um erro de diagnóstico pode surgir por informações incorretas descritas sobre a planta ou então características que não foram descritas pelo especialista, já que toda informação passada através do especialista está descrita no formato de regras.

As regras por sua vez são definidas neste trabalho no formato de condições lógicas e um predicado. Sendo as condições, as situações apresentadas na planta e os predicados a conclusão de que o distúrbio está presente ou não. Com isso obtêm-se um conjunto de regras que determina o que ocorre para diagnosticar o distúrbio. A proposta é verificar se a rede neural consegue descrever completamente essas regras.

3.2 Definições

μ_x : Média calculada para a saída x .

σ_x : Desvio Padrão calculado para a saída x .

M_x : Conjunto de médias para a saída x .

Σ_x : Conjunto dos desvios padrões para a saída x .

$S_y^{M_x}$: Conjunto y das médias para a saída x .

$S_y^{\Sigma_x}$: Conjunto y dos desvios padrões para a saída x .

$A_y^{M_x}$: Variável lógica que será verdadeira apenas quando $(\mu_x \in S_y^{M_x})$.

$A_y^{\Sigma_x}$: Variável lógica que será verdadeira apenas quando $(\sigma_x \in S_y^{\Sigma_x})$.

D_z : Variável lógica verdadeira quando o distúrbio z estiver ocorrendo.

$\neg D$: Operador lógico que representa a negação da variável lógica D .

Exemplo para o caso sem distúrbio e saída 1:

$S_0^{M_1}$: Subconjunto zero das médias para a saída 1.

$S_0^{\Sigma_1}$: Subconjunto zero dos desvios padrões para a saída 1.

$A_0^{M_1}$: Variável lógica que será verdadeira apenas quando $(\mu_1 \in S_0^{M_1})$.

$A_0^{\Sigma_1}$: Variável lógica que será verdadeira apenas quando $(\sigma_1 \in S_0^{\Sigma_1})$.

Portanto, a lógica para inferir que o distúrbio zero está ocorrendo, segue a proposição abaixo:

$$A_0^{M_1}, A_0^{\Sigma_1} \rightarrow D_0$$

Se o valor da média medida pertence ao subconjunto das médias da resposta ao caso sem distúrbio e o valor do desvio padrão pertence ao subconjunto dos desvios padrões da resposta no caso sem distúrbio, ambos para a saída 1, então o sinal sem distúrbio será identificado.

3.3 Sistema de aprendizagem simbólico neural

A integração de redes neurais e conhecimento simbólico já recebiam atenção considerável nos anos 90. Assim, Towell and Shavlik (1993, *apud* Yu, et al., 2008, p. 490) apresentaram o influente modelo KBANN (Rede Neural Artificial Baseada no Conhecimento), um sistema para regras de inserção, refinamento e extração de redes neurais. Resumidamente, o algoritmo de regras para rede do KBANN constrói árvores AND/OR. O KBANN define pesos e limites para que a rede se comporte como um conjunto de neurônios AND/OR, derivada de um conjunto de regras. Desta forma, pode-se dizer que o modelo KBANN serviu de inspiração para a construção do Sistema de Aprendizagem Conexionista, Indutiva e Programação Lógica (CILP). O CILP se baseia em KBANN, de modo a fornecer uma fundamentação teórica sólida para raciocínio em redes neurais, e usa a programação lógica como uma linguagem de representação do conhecimento. É definido como modelo computacional baseado na rede neural artificial *feedforward*, que integra a aprendizagem indutiva a partir de exemplos e conhecimento prévio com raciocínio dedutivo usando programação lógica (Garcez, Broad and Gabbay, 2002).

3.4 Sistema CILP

O sistema CILP utiliza a estrutura de uma rede neural *feedforward* N para descrever um programa lógico P . O algoritmo descreve uma maneira automática de como calcular os pesos, *bias* e estrutura da rede. Desta forma, o conhecimento atual do modelo é definido anteriormente das regras que os especialistas conhecem sobre o processo. Um refinamento da rede é possível desde que as regras sejam parcialmente conhecidas.

Um programa lógico é um conjunto de cláusulas no formato $r_i: L_1, L_2, \dots, L_k \rightarrow A_i$ sendo L_i ($1 \leq i \leq k$) os literais e A o átomo que representa a conclusão da cláusula (Lloyd, 1987). Nesse formato $L_1, L_2, \dots, L_k$ integram o corpo e A_i a cabeça da cláusula (Holldobler and Kalinke, 1994).

Portanto, a partir do programa P é necessário definir além da estrutura da rede, os pesos sinápticos e valores dos *bias* para cada neurônio da rede N . Para

isso, são introduzidos alguns conceitos (Garcez, Broad and Gabbay, 2002):

A_{min} : Menor valor de ativação para que o neurônio seja considerado *ativo*. $A_{min} \in (0,1)$.

A_{max} : Maior valor de ativação para que o neurônio seja considerado *inativo*. $A_{max} \in (-1,0)$.

$h(x) = 2/(1 + e^{\beta x}) - 1$: Função de ativação semilinear bipolar.

$g(x) = x$: Função de ativação linear.

W e $-W$: Representam os pesos das conexões associados a uma cláusula r_i . Sendo W para os pesos em que os literais estão positivamente conectados (L) e $-W$ representando uma conexão em que o literal está no formato de negação $\neg L_i$.

θ_i : Bias dos neurônios localizados na camada oculta.

θ_A : Bias dos neurônios localizados na camada de saída.

k_i : Representa o número de literais no corpo da cláusula r_i .

p_i : Representa o número de literais positivos no corpo da cláusula r_i .

μ_i : Representa o número de cláusulas em P com o mesmo átomo da cabeça da cláusula r_i .

$MAX_{r_i}(k_i, \mu_i)$: Representa o maior elemento entre k_i e μ_i para a cláusula r_i .

$MAX_P(k_1, \dots, k_q, \mu_1, \dots, \mu_q)$: Representa o maior elemento entre todos os k_i e μ_i do programa lógico P .

Desse modo pode-se calcular o valor A_{min} como descrito pela Equação (5) (Garcez, Broad and Gabbay, 2002):

$$A_{min} > \frac{MAX_P - 1}{MAX_P + 1} \quad (5)$$

Sabendo que a MAX_P é um valor no mínimo igual a um, denota-se que $A_{min} \in (0,1)$. Por definição, A_{max} é apresentado como sendo $-A_{min}$. Utilizando essa metodologia, a rede neural não apresentará valores no intervalo $(-A_{max}, A_{min})$ (Garcez, Broad and Gabbay, 2002).

O peso sináptico W e os *bias* θ_i e θ_A da camada oculta e de saída são determinadas respectivamente pelas Equações (6), (7) e (8).

$$W > \frac{2 \ln(1+A_{min}) - \ln(1-A_{min})}{\beta MAX_P(A_{min}-1) + A_{min}+1} \quad (6)$$

$$\theta_i = \frac{(1+A_{min})(k_i-1)}{2} W \quad (7)$$

$$\theta_A = \frac{(1+A_{min})(1-\mu_i)}{2} W \quad (8)$$

A tradução do programa lógico P para a rede neural segue os passos seguintes:

Para cada cláusula $r_i: L_1, L_2, \dots, L_k \rightarrow A_i (k \geq 0)$, realize:

- A criação de neurônios da camada de entrada para cada L_i e a dos neurônios de saída rotulados como A_i ;
- A criação do neurônio da camada oculta rotulado por N_i ;
- A conexão dos neurônios entre a camada de entrada e oculta através do peso W se o literal L_j associado for não negado e $-W$ caso seja negado. Realizar a mesma operação entre a camada oculta e de saída;
- Determinação do *bias* como descrito pelas Equações (7) e (8).

Defina a função de ativação da camada oculta e intermediária como sendo $h(x)$ e da camada de entrada para $g(x)$.

4 Resultados

Para apresentar os resultados obtidos, a etapa de escolha das 41 variáveis medidas presentes na planta, 11 foram selecionadas como parâmetros essenciais num processo químico, dos quais 3 das variáveis medidas do processo foram utilizadas.

4.1 Análise dos resultados das simulações

A saída 1 conforme a Figura 3, na presença de 10 distúrbios e uma situação base ou ideal, foi observado que nem todos os distúrbios provocaram perturbações relevantes ao sistema e que apenas os distúrbios D1, D2 e D8 são possíveis de serem diferenciados graficamente do caso ideal. Realizando uma análise mais detalhada do comportamento dessa saída a esses distúrbios, observou-se que a resposta da saída 1 à D1, apresenta uma média e um desvio padrão superiores ao caso base, apresentando claramente a sua relevância.

A resposta ao D8 não diverge consideravelmente do caso base com relação à média, mas apresenta um desvio padrão maior, sendo D8 então definido como relevante a partir desse parâmetro. A resposta à D2 se destaca devido à sua média e ao seu desvio padrão suficientemente altos para considerá-lo como anômalo quando comparado ao caso base. Porém a decisão da escolha do D2 é menos evidente como foi para D1 e D8. Com as análises gráficas e estatísticas realizadas como visto na Tabela 3, os distúrbios mais relevantes foram definidos e então, os sinais necessários para a identificação dos mesmos foram determinados.

Tabela 3. Dados das simulações no processo de (TE) na saída 1, sem distúrbios (SD) e com distúrbios, médias e desvios padrões.

	SD	D1	D2	D8
Média (kscmh)	0,2667	0,7686	0,3024	0,2751
Desvio Padrão (kscmh)	0,0064	0,1329	0,0112	0,1203




Figura 3. Resposta da saída 1 as simulações sem distúrbio (SD) e com distúrbios.

A metodologia adotada na obtenção dos resultados da saída 1 foi a mesma utilizada nas saídas 7 e 9. Através da Tabela 4 e da Figura 4, foi verificado os distúrbios que sensibilizaram a saída 7, por meio da análise da média e desvio padrão, como também interpretando o gráfico.

Tabela 4. Dados das simulações no processo de (TE) na saída 7, sem distúrbios (SD) e com distúrbios, médias e desvios padrões.

	SD	D1	D8	D11	D12
Média (kPa)	2,8000	2,7977	2,7995	2,8000	2,8000
Desvio Padrão (kPa)	0,0009	0,0081	0,0058	0,0033	0,0021




Figura 4. Resposta da saída 7 as simulações sem distúrbio (SD) e com distúrbios.

Quanto à saída 9, em relação aos dados presentes na Tabela 5 e observando a Figura 5, os distúrbios mais significativos nessa saída foram: D4, D11 e D14.

Tabela 5. Dados das simulações no processo de (TE) na saída 9, sem distúrbios (SD) e com distúrbios, médias e desvios padrões.

	SD	D4	D11	D14
Média (°C)	122,8997	122,9012	122,9007	122,8998
Desvio Padrão (°C)	0,0108	0,0204	0,1842	0,1635




Figura 5. Resposta da saída 9 as simulações sem distúrbio (SD) e com distúrbios.

4.2 Simbologias dos resultados das simulações

A partir da análise dos dados e dos gráficos, durante a criação dos símbolos que representam as variáveis lógicas, foi observado que as saídas 1, 7 e 9 são suficientes para o reconhecimento de todos distúrbios estudados que provocam alterações nos sinais de saída da planta. A representação lógica exposta a seguir será aplicada na rede neural, considerando apenas as saídas e distúrbios de interesse:

Geração de regra a partir da saída 1

$$A_0^{M_1}, A_0^{\Sigma_1}, \neg D_4, \neg D_{11}, \neg D_{12}, \neg D_{14} \rightarrow D_0$$

$$A_1^{M_1}, A_1^{\Sigma_1} \rightarrow D_1$$

$$A_2^{M_1}, A_2^{\Sigma_1} \rightarrow D_2$$

$$A_3^{M_1}, A_3^{\Sigma_1} \rightarrow D_8$$

Geração de regras a partir das saídas 7 e 9:

$$A_3^{M_7}, A_3^{\Sigma_7} \rightarrow D_{11}$$

$$A_4^{M_7}, A_4^{\Sigma_7} \rightarrow D_{12}$$

$$A_1^{M_9}, A_1^{\Sigma_9} \rightarrow D_4$$

$$A_3^{M_9}, A_3^{\Sigma_9} \rightarrow D_{14}$$

Posteriormente a etapa de criação dos símbolos, estes foram utilizados para a construção da rede neural, apresentada, de forma reduzida. A Figura 6 apresenta a estrutura da rede neural para os distúrbios identificados por (D4, D11, D12, D14) e o caso normal (D0).




Figura 6. Rede lógica CILP para representação dos distúrbios (D0, D4, D11 e D12).

Foram verificados os resultados para cada regra através de gráficos em que cada distúrbio estava agindo. A Figura 7 apresenta os disparos da rede neural para as regras que tem como conclusão D11 e

D14 na presença do distúrbio D14 ocorrendo. Observou-se que a partir de 700 segundos o distúrbio D14 apresenta correta identificação enquanto que o D11 não apresenta algum disparo apesar de $A_3^{M_7}$ estar ativo. Os gráficos demonstram o funcionamento da rede neural na utilização de regras lógicas, todas as regras foram avaliadas simultaneamente e, neste caso, apenas a regra identificada para o D14 foi sensibilizada.




Figura 7. Representação dos distúrbios D11 não ativo e D14 ativo.

5 Conclusão

Este trabalho apresenta uma metodologia de como extrair informações lógicas sobre o comportamento dos distúrbios de uma planta industrial didática que pode ser reproduzido por outros modelos de processos e como implantar esse conhecimento na representação de uma rede neural artificial. Foi utilizado para isso o modelo da planta didática *Tennessee Eastman* (TE). Na etapa da simulação, além das variáveis de entrada e saída, foi disponibilizada a opção de incluir 20 distúrbios, dos quais 10 foram aplicados. Para a rede neural, foi utilizado o sistema CILP. Os resultados foram construídos a partir do levantamento de medidas estatísticas sobre sinais na presença ou não de cada distúrbio e essa experiência então foi convertida para a rede neural a partir de sequências lógicas. Os resultados apresentados mostraram quais foram às lógicas encontradas e a interpretação do CILP sobre o que está ocorrendo na planta. A mesma oferece situações complexas nas quais distúrbios diferentes possuem características parecidas de comportamento. Mesmo assim, com a correta descrição do conhecimento do especialista, as regras de comportamento dos distúrbios da planta mostraram-se representadas adequadamente na rede neural permitindo que todas as situações fossem avaliadas simultaneamente.

Agradecimentos

Os autores agradecem à Comissão de Aperfeiçoamento de Pessoal do Nível Superior (CAPES), pelo suporte financeiro para realização desta pesquisa, e ao apoio do Laboratório de Automação em Petróleo (LAUT/UFRN).

Referências Bibliográficas

- Chiang, L. H., Braatz, R. D. and Russell, E. L. (2001). *Fault detection and diagnosis in industrial systems*, Springer Science & Business Media
- Cortez, G. A. C (2016). Estratégias de definição de estruturas de controle global. 2016. 224f. Tese (Doutorado em Engenharia Química) - Universidade Federal do Rio de Janeiro - Programa de Pós Graduação em Engenharia Química, Rio de Janeiro - RJ.
- Garcez, A. d'A.; Broad, K. and Gabbay, D.M. (2002). *Neural-Symbolic Learning Systems: Foundations and Applications*, Perspectives in Neural Computing, Springer.
- Heidrich, A (2004). Heurísticas para projeto de estruturas de controle. 2004.126f. Dissertação (Mestrado em Engenharia Química) - Universidade Federal do Rio Grande do Sul - Programa de Pós-Graduação em Engenharia Química, Porto Alegre, RS.
- Holldobler, S. and Kalinke, Y. (1994). Toward a new massively parallel computational model for logic programming. In *Proceedings of the Workshop on Combining Symbolic and Connectionist Processing, ECAI 1994*, pp. 68-77.
- Lloyd, J.W. (1987) *Foundations of Logic Programming*. Springer.
- Souza, D. C. (2017). Sistema especialista baseado em regras ponderado por tendências aplicado ao monitoramento de processos industriais estruturas de controle global. 2017. 101f. Tese (Doutorado em Engenharia Elétrica e de Computação) - Universidade Federal do Rio Grande do Norte - Programa de Pós Graduação em Engenharia Elétrica e de Computação, Natal - RN.
- Yu, J., Xi, L. and Zhou, X. (2008). *Intelligent monitoring and diagnosis of manufacturing processes using an integrated approach of KBANN and GA*, Computers in industry. Elsevier Science Direct.