

# SOFT SENSOR PARA ESTIMAÇÃO DOS PRINCIPAIS COMPONENTES DO GLP BASEADO EM REDES NEURAS ARTIFICIAIS

JEAN MÁRIO MOREIRA DE LIMA\*, FÁBIO MENEGHETTI UGULINO DE ARAÚJO\*

\* UFRN/CT, DCA - Laboratório de Controle de Processos  
Natal, RN, Brasil 59078-970

Emails: jean@dca.ufrn.br, meneghet@dca.ufrn.br

**Abstract**— In NGPUs, one of the most profitable products is LPG which is composed mainly of propane (C3) and butane (C4), and pentane (C5) and ethane (C2) as contaminants. Measurement of the molar fraction of these components has been done through gas chromatography, which is a slow process. This fact makes the monitoring of the quality of the product in real time impossible. In this work, a soft sensor is proposed, using artificial neural networks, in order to infer the molar fractions of the components of the GLP minute by minute. The results obtained are promising, showing that the soft sensor can satisfactorily infer the molar fractions of the LPG components, improving the quality of LPG monitoring and its profitability.

**Keywords**— NGPU, LPG, Inference System, Artificial Intelligence, Artificial Neural Network

**Resumo**— Em UPGNs, um dos produtos de maior rentabilidade é o GLP que é composto majoritariamente por propano (C3) e butano (C4), e o pentano (C5) e o etano (C2) como contaminantes. A medição da fração molar desses componentes é feita através da cromatografia a gás, que é um processo lento, impossibilitando que o monitoramento da qualidade do produto seja feito em tempo real. Neste trabalho, propõe-se um *soft sensor*, utilizando a redes neurais artificiais, com o objetivo de inferir as frações molares dos componentes do GLP minuto a minuto. Os resultados obtidos são promissores, mostrando que o *soft sensor* pode inferir os frações molares dos componentes do GLP de forma satisfatória, melhorando o monitoramento da qualidade do GLP, consequentemente, lucratividade.

**Palavras-chave**— UPGN, GLP, Sistema de Inferência, Inteligência Artificial, Redes Neurais Artificiais.

## 1 INTRODUÇÃO

Nos dias atuais, têm-se mercados cada vez mais competitivos entre si, logo produzir de forma eficiente e eficaz é essencial para se obter um balanço econômico positivo. Diante disso, técnicas que podem melhorar e/ou garantir otimização de processos, como o monitoramento da qualidade do produto tornam-se fundamentais para a indústria como um todo.

No caso de Unidades de Processamento de Gás Natural (UPGNs), o monitoramento da qualidade do produto produzido é intrínseco a uma produção satisfatória, e esse controle da qualidade faz-se através da composição química dos produtos. Composições químicas são variáveis de difícil mensuração (Linhares, 2010). A medição da composição química de um componente é normalmente feita através de análise em laboratório (Warne et al., 2004a). Dessa forma, longos intervalos de tempo para obtenção das amostras e análise laboratorial são requeridos.

De acordo com (Bolf et al., 2008), instrumentos de medição online da composição química de produtos até estão disponíveis como os cromatógrafos à gás e analisadores NIR (Near-InfraRed), mas apresentam custo elevado e longos intervalos de medição.

Quando limitações técnicas e alto custo impossibilitam o uso de sensores das variáveis primárias, isto é, as variáveis de processo, em tempo real, sistemas de inferência apresentam uma forma interessante de se lidar com o problema

de medição das mesmas (Zamprogna et al., 2005) (Hongmei et al., 2015). O objetivo de desenvolver um *soft sensor* é modelar uma relação entre as variáveis primárias, de difícil medição, com as variáveis ditas secundárias, de fácil e rápida medição (Bolf et al., 2008), (Cao et al., 2010).

Normalmente, o produto de maior rentabilidade econômica em uma UPGN é o GLP. De forma ideal, é formado por propano e butano (C3 e C4). Na prática, porém, há contaminantes como o etano e pentano (C2 e C5). O *soft sensor* aqui proposto tem como principal objetivo estimar as frações molares dos constituintes do GLP (variáveis primárias), isto é, C3, C4, C2 e C5, a partir de várias de fácil medição como temperatura e vazão (variáveis secundárias). Espera-se que esse sensor virtual possa fazer a função que um cromatógrafo a gás faz, gerando percentuais das composições do GLP, só que minuto a minuto. Dessa forma, o monitoramento da qualidade, em tempo real, do GLP produzido torna-se possível. Assim, melhora-se a qualidade do processo e, consequentemente, sua lucratividade.

Para implementação do soft sensor deste trabalho, aplica-se a técnica de inteligência artificial conhecida como redes neurais artificiais. No escopo deste trabalho, o principal benefício é que elas podem associar as relações dinâmicas não-lineares entre as variáveis primárias e secundárias de um processo (Rani et al., 2013).

Para o desenvolvimento deste trabalho, utilizou-se uma UPGN simulada em software

HYSYS baseada na UPGN-II GMR, da Petrobrás, localizada na cidade de Guamaré/RN. É formada por uma coluna deetanizadora em série com uma coluna debutanizadora. A inferência é baseada nas variáveis de processo dos controladores PID presentes na planta. Neste trabalho, é proposto também um sistema de correção do erro do sistema de inferência, tendo com base a leitura da composição do GLP feita por cromatógrafos presentes no processo.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 Redes Neurais Artificiais

De acordo com (Haykin, 2001), uma rede neural artificial pode ser definida como uma estrutura maciçamente paralela, distribuída e formada em sua totalidade por unidades simples de processamento: os neurônios. São capazes de aprender a partir do ambiente através de um processo de aprendizagem e esse conhecimento é armazenado pela força de conexão entre os neurônios. Ainda de acordo com Haykin (2001), as principais propriedades de uma rede neural artificial são: capacidade de generalização, adaptabilidade, não-linearidade intrínseca, mapeamento entrada-saída.

De acordo com (Linhares, 2010), RNAs são poderosas ferramentas para a identificação de dinâmicas não lineares complexas, como em uma UPGN. No escopo deste trabalho, o principal benefício é que elas podem associar as relações dinâmicas não-lineares entre as variáveis primárias e secundárias de um processo cujo sistema é complexo.

Há diversas arquiteturas de redes neurais artificiais. A forma como os neurônios da rede estão estruturados é intrinsecamente ligada ao algoritmo de aprendizado utilizado no treinamento da rede. Uma vez que apresentou resultados satisfatórios em sistemas de inferências, como de (Fortuna et al., 2005), a arquitetura utilizada neste trabalho será a perceptron de múltiplas camadas (PMC).

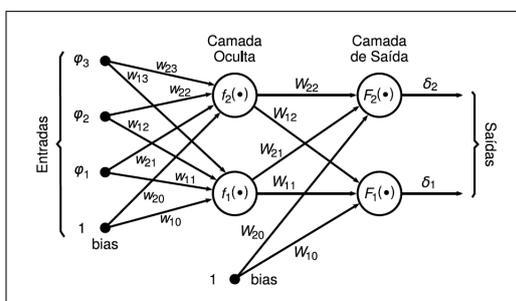


Figura 1: PMC interconectada de duas camadas com dois neurônios.

Uma rede PMC, também chamada de *feed-*

*forward*, é constituída basicamente por uma camada de entrada, uma ou mais camadas ocultas nas quais os neurônios estão interconectados e uma camada de saída. Nesse esquema, cada neurônio recebe o sinal da camada imediatamente anterior ou das entradas. Este tipo de rede é totalmente interconectada, ou seja, todas as entradas e neurônios de uma camada estão conectados com todos os neurônios da camada seguinte. É possível sintetizar o funcionamento de uma rede PMC matematicamente:

$$\delta_i(t) = g_i(\varphi, \theta) = F_i \left[ \sum_{j=1}^{n_h} W_{i,j} f_j \left( \sum_{l=1}^{n_\varphi} w_{j,l} \varphi_l + w_{j,0} \right) + W_{i,0} \right] \quad (1)$$

Sendo  $\theta$  um vetor dos parâmetros ajustáveis: biases e pesos sinápticos ( $W_{i,j}$ ,  $w_{j,0}$ ).  $n_h$  e  $n_\varphi$  são respectivamente o número de neurônios na camada oculta e o número de entradas da rede. Por fim, tem-se  $f_j$  e  $F_i$  que são as funções de ativação dos neurônios nas camadas oculta e de saída, respectivamente. Comumente, as funções de ativação utilizadas são a linear, sigmóide e tangente hiperbólica.

De acordo com (Haykin, 2001), uma das mais importantes propriedades de uma rede neural artificial é sua capacidade de aprender. Esse aprendizado deve-se aos ajustes dos parâmetros a cada iteração do processo de aprendizagem. Dentre os variados métodos de aprendizagem, cita-se o supervisionado que será o utilizado neste trabalho. As regras estabelecidas para lidar com esse problema de aprendizagem, isto é, o ajuste iterativo citado acima, é denominado algoritmo de aprendizagem ou de treinamento. O algoritmo mais usual no processo de aprendizagem supervisionado de redes PMC é o de retropropagação de erros ou, do inglês, *backpropagation*, que é o algoritmo utilizado para treinamento da rede proposta.

### 2.2 Identificação de Sistemas

Inferir o comportamento de um sistema, é representar a dinâmica do mesmo de forma satisfatória por alguma técnica. De acordo com (Aguirre, 2004), há várias técnicas de modelar a dinâmica de um sistema, identificando-o. Basicamente, deve-se considerar o conhecimento que se tem sobre o sistema que se deseja inferir. Assim, classifica-se a técnicas em: caixa branca, caixa preta e caixa cinza. Caso a identificação baseie-se apenas em dados coletados do sistema e assumindo que nenhum ou pouquíssimo conhecimento sobre o sistema é usado, a técnica de modelagem é dita caixa preta.

A realização da identificação de um sistema caixa preta assemelha-se as etapas do projeto de redes neurais. Logo, devido a essa semelhança e a características intrínsecas das redes, a identificação de sistemas complexos tem sido feita por

RNAs que conseguem representar a dinâmica de forma satisfatória e relativamente simples. Neste trabalho, utiliza-se a modelagem caixa preta uma vez que o sistema que se deseja identificar é complexo e não há conhecimento de sua modelagem fenomenológica. Coleta-se dados experimentais do sistema simulado formado pelas colunas de destilação deetanizadora e debutanizadora com o objetivo de obter o sistema de inferência baseado em um modelo neural capaz de representar as dinâmicas entre as variáveis primárias e secundárias do sistema.

### 2.3 Identificação Utilizando Modelos Neurais

Basicamente, as estruturas de modelagem com base em RNAs com características para identificar sistemas não-lineares, são generalizações das que apresentam modelagem linear. São exemplos de estruturas de modelagem linear: modelo ARX (*AutoRegressive eXogenous input*), ARMAX (*AutoRegressivo, Moving Average, eXogenous input*), OE (*Output Error*). Esses modelos são caracterizados por um vetor que armazena valores passados das variáveis utilizadas na estimativa da saída. Esse vetor chama-se vetor de regressão  $e$ , de acordo com a escolha desse vetor, diferentes estruturas de modelos neurais podem ser obtidos. Por exemplo, se o vetor de regressão escolhido é equivalente ao utilizado no modelo ARX, a estrutura de modelo neural é chamada NNARX (*Neural Network ARX*).

No modelo NNARX, o vetor de regressão, além de armazenar os valores passados das variáveis utilizadas na estimativa da saída, também guarda os valores passados das variáveis de saída do processo. De acordo com (Norgaard et al., 2001), esse modelo é estável uma vez que apresenta relações puramente algébricas entre suas variáveis. Devido a isso, a estrutura de modelagem neural escolhida como base a ser utilizada no sensor virtual aqui proposto é o modelo NNARX ilustrada na Figura 2.

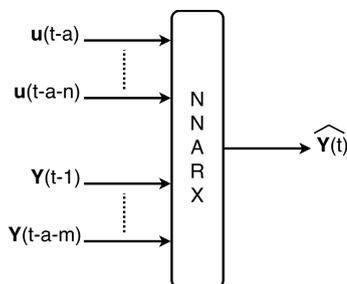


Figura 2: Estrutura de modelagem NNARX.

A Figura 2 apresenta o diagrama de uma estrutura de modelagem NNARX. Nesta estrutura  $\hat{Y}$  é a saída da rede, isto é, o vetor de estimativas da saída da planta. O termo  $a$  é o atraso de

transporte da planta,  $n$  é a ordem de entrada da planta,  $m$  é a ordem de saída da planta,  $Y$  e  $u$  são os vetores de entrada e saída da planta. Também é possível observar regressores. Sabendo-se que o projeto da estrutura é feito para identificar a dinâmica de um sistema físico, a utilização de regressores é intrínseca pois os mesmos fazem com que a saída da rede neural esteja diretamente relacionada com valores anteriores tanto de entrada como de saída do sistema.

O modelo NNARX exposto será utilizado para treinamento do sistema de inferência. Entretanto, como descrito acima, nas suas entradas, também estará presente as saídas passadas do sistema, ou seja, variáveis primárias de difícil medição. Sendo assim, o sistema de inferência não seria capaz de reduzir o tempo de medição dos cromatógrafos, já que seriam necessárias informações das medições dos mesmos. Para contornar isso, após treinamento, utilizaremos como entrada, para os testes e validações posteriores, os valores passados estimados pelo próprio modelo neural. Assim, garante-se que a avaliação do modelo seja com relação ao seu potencial de inferir as variáveis primárias a partir das secundárias e de suas próprias estimativas em tempo de execução.

## 3 METODOLOGIA

### 3.1 Módulo RNA - Saídas

A inferência de variáveis primárias de difícil medição a partir de variáveis secundárias de fácil medição para monitoramento é o objetivo deste trabalho. Por isso, adota-se a fração molar dos principais componentes do GLP como as variáveis primárias, uma vez que a medição das mesmas através de cromatógrafos a gás é lenta. Sendo assim, as saídas do modelo neural proposto são ilustradas na Tabela 1:

Tabela 1: Variáveis primárias do processo.

i	Variável Primária ( $VP_i$ )
1	Fração Molar do Propano (C3)
2	Fração Molar do Butano (C4)
3	Fração Molar do Etano (C2)
4	Fração Molar do Pentano (C5)

### 3.2 Módulo RNA - Entradas

A seleção das entradas, ou variáveis secundárias que servirão de instrumento para a inferência das variáveis primárias, é importante uma vez que a quantidade dessas variáveis vai influenciar no grau de qualidade e na complexidade do sistema de inferência. De acordo com Linhares (2010), em sistemas de coluna de destilação, comumente, podem

ser variáveis secundárias temperaturas dos diferentes pratos perfurados, vazão de refluxo, pressão de coluna, temperatura do refeedor e condensador e volume de condensado.

Como o sistema simulado buscar manter características reais da planta UPGN-II GMR, apenas leva-se em consideração os valores de variáveis secundárias que podem ser obtidos através de sensores físicos reais.

Para a inferência, escolheu-se a temperatura do estágio 16 e vazão de refluxo da coluna debutanizadora e temperatura do estágio 40 e o percentual de volume de condensado da coluna detanizadora, respectivamente. A escolha é feita com base na influência dinâmica que as variáveis secundárias impõe sobre as primárias, isto é, a correlação entre as mesmas.

Tabela 2: Variáveis secundárias do processo.

<b>p</b>	<b>Va. Secundária (<math>VS_p</math>)</b>	<b>Controlador</b>
1	Temp. do estágio 40	TIC-100
2	Volume de Condensado	LIC-101
3	Temp. do estágio 16	TIC-102-2
4	Vazão de Refluxo	FIC-101-2

A Tabela 2 esquematiza as variáveis secundárias escolhidas para compor a entrada do módulo neural. A coluna Controlador, informa a tag do controlador PID associado a variável secundária da planta simulada.

### 3.3 Estrutura do modelo

Mapear as relações dinâmicas entre variáveis primárias e variáveis secundárias do processo em estudo, é o objetivo da rede neural do sistema de inferência proposto. A arquitetura a ser utilizada é a perceptron de múltiplas camadas. A estrutura de modelagem utilizada é a NNARX para o treinamento da rede, ou seja, durante o treinamento, será realimentada pelos valores de saída da planta. Nas validações e testes da rede neural do sistema, será realimentada por suas próprias estimativas dos valores das frações molares do C3, C4, C2 e C5.

A Figura 3, ilustra o modelo RNA adotado para treinamento. O vetor  $\mathbf{u}$  de 4 dimensões, representa cada uma das variáveis secundárias utilizadas nesse trabalho. C4, C3, C2 e C5 representam o vetor de regressão constituído pelas variáveis primárias. São valores coletados do próprio sistema simulado. Já  $\widehat{C3}$ ,  $\widehat{C4}$ ,  $\widehat{C2}$  e  $\widehat{C5}$  são as variáveis primárias inferidas no treinamento da rede. O termo  $\mathbf{n}$  junto a um índice de acordo com a respectiva variável secundária representa a ordem do vetor de regressão. Da mesma forma, o termo  $\mathbf{m}$  é a ordem de regressão do vetor constituídos pelas variáveis primárias que alimentam o modelo. O

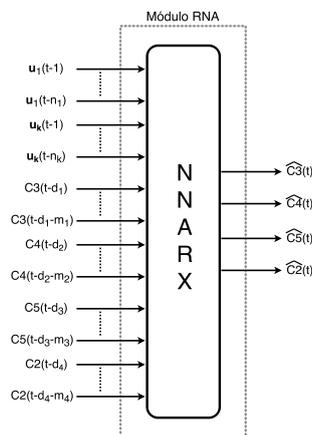


Figura 3: Diagrama esquemática da estrutura de modelagem NNARX proposta.

termo  $\mathbf{d}$  é o atraso de cada uma das realimentações. Lembrando que o esquemático da estrutura NNARX é utilizado para treinamento do modelo. Para testes do modelo, no lugar dos próprios valores de variáveis primárias coletadas do sistema para realimentação, utiliza-se os valores que estão sendo inferidos pela rede. Assim, analisa-se o potencial do sistema operar sem a necessidade de da análise da composição do produto em um intervalo curto de tempo.

### 3.4 Módulo de Correção

Existe a possibilidade das estimativas obtidas pelo sistema de inferência divergirem acentuadamente dos valores esperados. Isso deve-se ao acúmulo do erro propagado a cada nova estimativa, já que variáveis primárias estimadas são utilizadas como entrada, realimentando o sistema com seus valores passados. Por isso, propõe-se um módulo de correção.

O módulo de correção utiliza as medições das variáveis primária realizadas pelos cromatógrafos de linha do processo, quando disponíveis ou em determinado intervalo de tempo. O esquemático do módulo é mostrado abaixo:

A inferência gerada pelo módulo RNA é direcionada à saída, pois a mesma está conectada ao ponto A do esquema. No momento em que as medidas reais das variáveis primárias estiverem disponíveis pelos cromatógrafos de linha, a realimentação do sistema será feita a partir da leitura dos cromatógrafos. Para isso, a saída será conectada na posição B. Assim, corrige-se o erro acumulado com a realimentação das inferências, colocando a leitura real na saída e na realimentação. Após um instante, o sistema volta a ser conectado ao ponto A, sendo realimentado por suas próprias estimativas, e assim por diante.

Após a descrição dos módulos individualmente, pode-se apresentá-lo por completo. O diagrama esquemático simplificado ilustrado pela Figura 5:

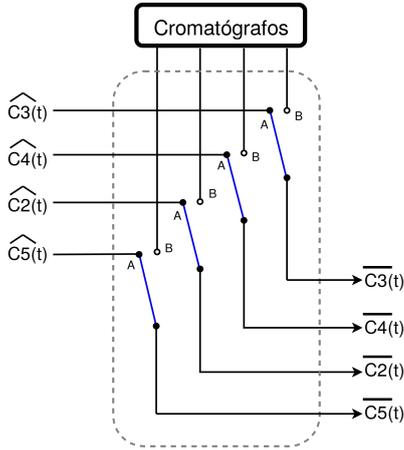


Figura 4: Diagrama esquemático do módulo de correção.

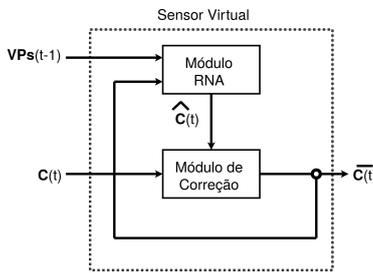


Figura 5: Esquemático do sensor virtual proposto.

Na Figura 5,  $\mathbf{VP}_s$ ,  $\mathbf{C}$ ,  $\hat{\mathbf{C}}$ ,  $\bar{\mathbf{C}}$  são vetores e correspondem, respectivamente, às variáveis de processo dos controladores da UPGN, às medições de frações molares fornecidas pelos cromatógrafos, às frações molares estimadas pela rede neural e, por fim, as variáveis primárias corrigidas ou não pelo módulo de correção.

### 3.5 Implementação

Descreve-se de forma resumida a metodologia que foi utilizada no desenvolvimento da proposta deste trabalho. Apresenta-se as etapas realizadas para implementação do sistema de inferência e, conseqüentemente, para obter resultados.

1. **Coleta de Dados:** Na etapa de coleta de dados, obtêm-se todos os dados necessários para treinamento e validação da rede neural do modelo proposto. Para que isso seja possível, aplica-se sinais PRS aos *setpoints* dos controladores do sistema simulado, listados na Tabela 2. Coleta-se três conjuntos de dados que abrangem adequadamente a faixa de operação da planta.
2. **Estrutura de inferência RNA:** Uma vez que os dados foram coletados, realiza-se a análise para diversas configurações de estruturas neurais. Treina-se a rede neural de acordo com a configuração em avaliação:

estruturas de inferência de segunda ordem com diversos valores de neurônios na camada oculta. Dessa forma, pretende-se observar como a arquitetura da rede pode influenciar na sua capacidade de inferir os resultados. Depois de realizada a validação das estruturas, a melhor é escolhida para compor o sistema de inferência. A comparação entre as estruturas pode ser realizada analisando-se a complexidade da rede neural e a capacidade de inferência ótima da fração molar dos componentes do GLP. Neste trabalho, essa análise pode é feita pelo erro médio quadrático da inferência.

3. **Aplicação no sistema:** Inicialmente, verifica-se o comportamento do sistema sem a presença do módulo de correção. A ideia é verificar até que momento as medições fornecidas pelo modelo são válidas para o propósito do trabalho. Após isso, utiliza-se o módulo de correção, testando-se diferentes períodos de atuação do módulo.

## 4 RESULTADOS

### 4.1 Treinamento e Validação das RNAs de inferência

Para treinamento das redes neurais que compõe o *soft sensor*, utilizou-se o *nntool*, o *toolbox* de redes neurais artificiais do *software* MATLAB. As redes foram treinadas utilizando-se o algoritmo de treinamento: gradiente conjugado escalonado, e aplicando-se a validação cruzada e parada antecipada. De acordo com (Demuth et al., 2009), o algoritmo de gradiente conjugado escalonado funciona de forma eficiente em conjunto com a validação cruzada, justificando-se assim, sua escolha.

Fixou-se a ordem do modelo em 2 e realizou-se vários treinamentos para diversos valores de neurônios na(s) camada(s) oculta(s). Logo depois de cada treinamento, submeteu-se as redes neurais obtidas à 2 conjuntos de dados de validação, objetivando-se analisar sua capacidade de generalização. Assim, apresenta-se a Tabela 3 com as estatísticas de treinamento e validação.  $nNN$  é o número de de redes neurais,  $nTrein$  é o número de treinamentos,  $nVal$  é o número de validações,  $T_t$  representa o total de treinamentos, assim como  $T_v$  o total de validações.

Tabela 3: Estatísticas de treinamentos e validações.

Ordem	$nNN$	$nTrein$	$nVal$	$T_t$	$T_v$
2	5	8	2	40	80

## 4.2 Análise das Estruturas Neurais

Apresenta-se os resultados obtidos de cada uma das estruturas de acordo com suas respectivas ordens e número de neurônios. O objetivo é analisar que estrutura obteve melhor desempenho de acordo com o seu EMQ. Assim, torna-se possível selecionar a melhor estrutura e indicá-la a compor o sistema de inferência.

Tabela 4: Estatísticas de validações do sensor virtual - parte 1.

$N_{HL}$	$N_{NE}$	C3	C4
1	16	$1.50e^{-4}$	$2.18e^{-4}$
1	32	$1.57e^{-4}$	$2.32e^{-4}$
1	48	$1.53e^{-4}$	$2.47e^{-4}$
2	32,16	$7.45e^{-5}$	$8.25e^{-5}$
2	32,48	$1.01e^{-4}$	$9.98e^{-5}$

Tabela 5: Estatísticas de validações do sensor virtual - parte 2.

$N_{HL}$	$N_{NE}$	C2	C5
1	16	$3.06e^{-4}$	$1.98e^{-4}$
1	32	$3.43e^{-4}$	$2.18e^{-4}$
1	48	$3.11e^{-4}$	$2.56e^{-4}$
2	32,16	$6.92e^{-5}$	$3.08e^{-5}$
2	32,48	$8.58e^{-5}$	$9.78e^{-5}$

Nas Tabelas 4 e 5, têm-se a média dos EMQs obtidos a partir das duas validações que se aplicou as melhores redes. O termo  $N_{HL}$  representa o número de camadas ocultas da rede,  $N_{NE}$  representa o número de neurônios da(s) camada(s) oculta(s). Assim, observa-se que a rede formada por duas camadas ocultas com 32 e 16 neurônios, respectivamente, mostrou os melhores resultados. Portanto, escolhe-se esta rede para formar o *soft sensor*.

Aplicou-se o *soft sensor* a planta simulada, em tempo real, e inferiu-se os valores dos componentes do GLP durante um intervalo de 10 horas, observando-se 600 amostras.

Na Figura 6, gráfico (a) representa a fração molar de propano, (b) de butano, (c) de etano e, por fim, (d) de pentano. Já os gráficos (e), (f), (g) e (h) são os erros percentuais de (a), (b), (c) e (d) respectivamente. A partir de 250 minutos de operação, as inferências divergem dos valores reais de forma mais significativa. Esse fato é esperado uma vez que a realimentação do *soft sensor* se dá pelas suas próprias estimativas, fazendo com que o erro gerado em cada iteração seja acumulado. Para mitigar o problema, usa-se o módulo de correção.

Agora aplica-se o módulo de correção para corrigir as saídas a cada 120min (Figura 7) e

60min (Figura 8), respectivamente. Vale lembrar que os cromatógrafos de linha só poderão fornecer valores das frações molares a cada 56 minutos no processo real. Isso torna a aplicabilidade do módulo de correção possível para os dois intervalos de tempo escolhidos para teste.

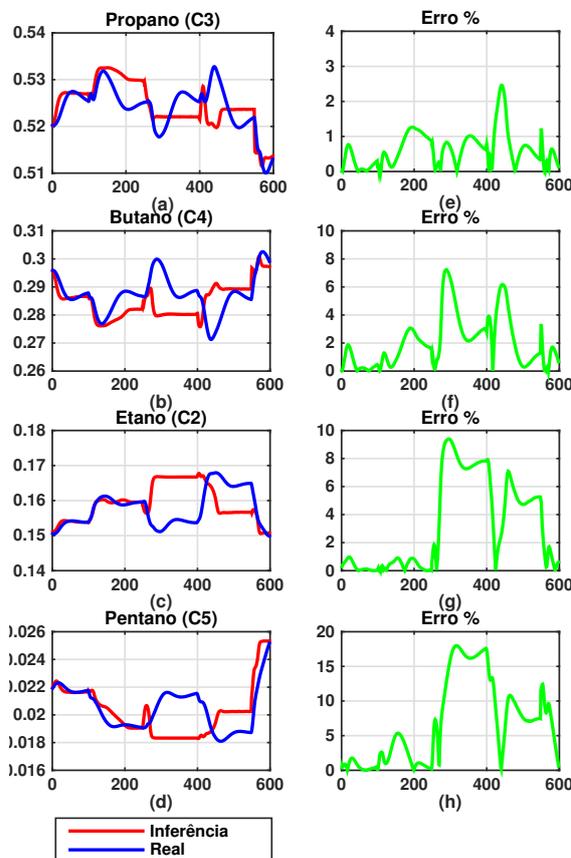


Figura 6: Gráficos dos valores das variáveis primárias SEM módulo de correção.

De acordo com os resultados, a inferência de propano (C3) sem o módulo de correção apresentou erro percentual médio de 0.6322%. Com a aplicação do módulo de correção com maior intervalo de tempo, isto é, 120 minutos, esse erro foi de 0.4774%. Por fim, para o menor intervalo de correção o erro percentual médio foi de 0.3879%.

Com relação as inferências do butano (C4), o erro médio percentual foi de 2.0432% sem a utilização do módulo de correção. Aplicando-se o módulo de correção com intervalo de realimentação igual a 120 minutos, esse erro caiu para o valor de 1.2238% e com intervalo de realimentação igual a 60 minutos, o erro foi de 0.8236%.

Para a inferência do etano (C2), impureza presente no GLP, o erro médio percentual obtido foi de 3.3379%. Ativando-se o módulo de correção para o maior intervalo de realimentação, ou seja, 120 minutos, esse erro foi reduzido para 1.1195%. Com o menor intervalo de correção aplicado, o

erro médio percentual foi de 0.6349%.

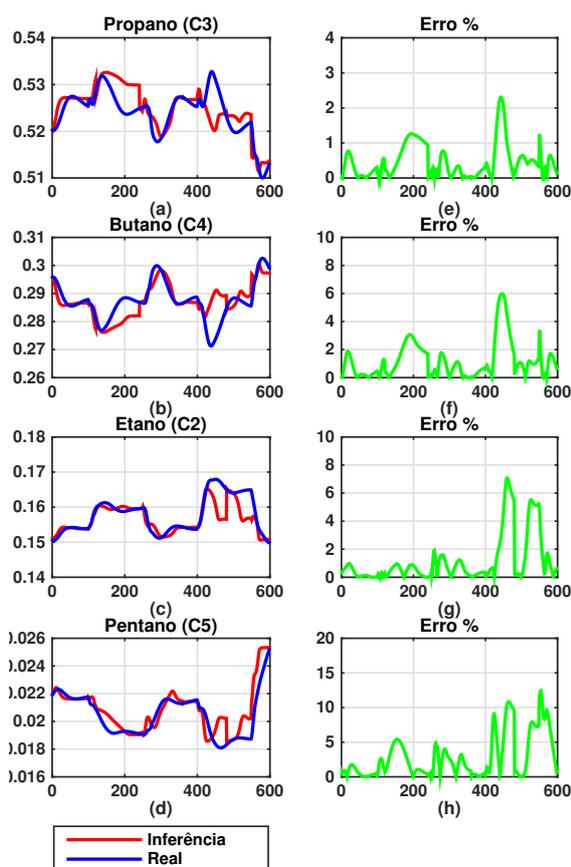


Figura 7: Gráficos dos valores das variáveis primárias COM módulo de correção aplicado a cada 120min.

Por fim, para inferência de pentano (C5), outra impureza do GLP, o erro médio percentual calculado foi de 6.5443% sem a utilização do módulo de correção. Agora, com o módulo ativado para realimentar o sistema a cada 120 minutos, o erro obtido foi de 3.0525% e com realimentação a cada 60 minutos, o erro percentual médio foi de 2.0120%.

Observa-se que ao utilizar-se o tempo mínimo de realimentação, isto é, 60 minutos, para corrigir as estimativas do *soft sensor*, obteve-se as melhores inferências com menores erros percentuais médios. Também pode-se afirmar que mesmo com o tempo máximo, ou seja, 120 minutos para realimentar os sensores, os resultados são bons, já que as estimativas não divergiram dos valores esperados. Além disso, conseguiu-se diminuir o erro médio percentual com relação a os erros obtidos sem a utilização do módulo de correção. Como o cromatógrafo de linha fornece valores a cada 56 minutos, se realimentarmos o sistema a cada 120 minutos, poderia-se reduzir a quantidade de leituras dos cromatógrafos pela metade. Caso queira-se as inferências mais próximas possíveis dos valores

reais, realimenta-se o sistema a cada 60 minutos.

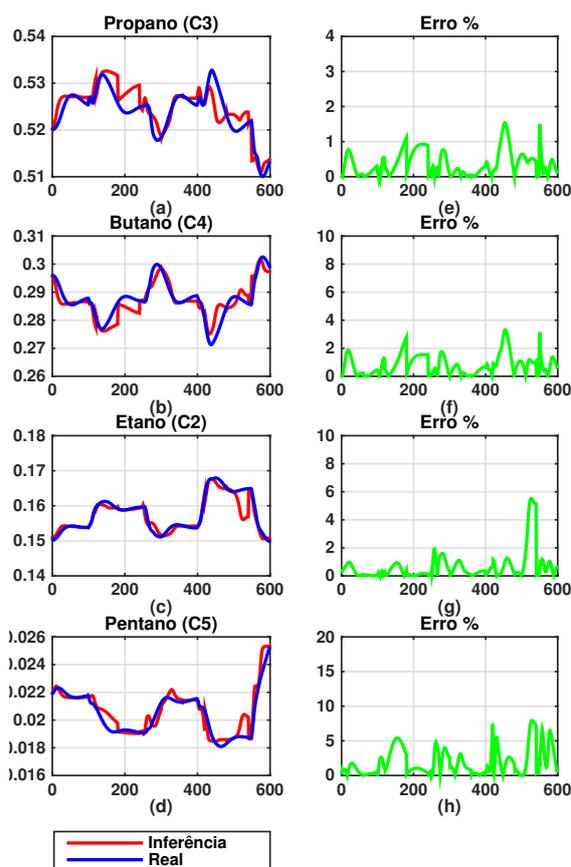


Figura 8: Gráficos dos valores das variáveis primárias COM módulo de correção aplicado a cada 60min.

## 5 Conclusões

Neste trabalho, focou-se em implementar um *soft sensor* baseado em redes neurais artificiais que fosse capaz de inferir as frações molares dos componentes do GLP.

De acordo com os resultados expostos, pode-se concluir que é possível obter um *soft sensor* eficiente. Estimou-se frações molares de C3, C4, C2 e C5 com boa aproximação dos valores reais esperados. Na melhor configuração de rede indicada, os EMQs relativos as frações molares desses componentes foram de  $3.44e^{-5}$ ,  $8.25e^{-5}$ ,  $2.92e^{-5}$ ,  $3.08e^{-6}$ , com EMQs percentuais de: 0.8%, 2.56%, 2.95% e 6.43%, para C3, C4, C2 e C5, respectivamente. Aplicando-se a melhor estrutura obtida para inferência de C3, C4, C2 e C5 na planta simulada, em tempo real, mostrou-se resultados sem a aplicação do módulo de correção e com ele pra intervalos de tempo variados. Com realimentações realizadas a cada 120 minutos, a inferência não divergiu dos valores reais. Já melhor caso, com realimentações a cada 60 minutos, é realizável uma vez que o cromatógrafo de linha disponibiliza os

valores das frações molares a cada 56 minutos. Assim, atestou-se a aplicabilidade e eficiência do *soft sensor* no processamento do gás natural, mais especificamente, para monitoramento da qualidade do GLP estimando a fração molar dos seus componentes minuto a minuto.

### Referências

- Aguirre, L. A. (2004). *Introdução à identificação de sistemas: técnicas lineares e não lineares aplicadas a sistemas reais*, 2 edn, Editora UFMG, Belo Horizonte/MG, Brasil.
- Bolf, N., Ivandic, M. and Galinec, G. (2008). Soft sensors for crude distillation unit product properties estimation and control, *16th Mediterranean Conference on Control and Automation*, IEEE, pp. 1804–1810.
- Cao, J., Zhou, B. and Li, Y. (2010). Soft sensor for on-line estimation of gelatin concentration, IEEE, pp. 406–411.
- Demuth, H., Beale, M. and Hagan, M. (2009). *Neural Network Toolbox 6 User's Guide*, Mathworks, Natick/MA, EUA.
- Fortuna, L., Graziani, S. and Xibilia, M. G. (2005). Soft sensors for product quality monitoring in debutanizer distillation columns, *Control Engineering Practice*, pp. 499–508.
- Haykin, S. (2001). *Redes Neurais: Princípios e Prática*, 2 edn, Bookman, Porto Alegre/RS - Brasil.
- Hongmei, R., Xuemin, T. and Lianfang, C. (2015). A new soft sensor method for dynamic processes based on dynamic orthogonal forward regression, *27th Chinese Control and Decision Conference*, IEEE, pp. 536–541.
- Linhares, L. L. S. (2010). *Sistema híbrido de inferência baseado em análise de componentes principais e redes neurais artificiais aplicado a plantas de processamento de gás natural*, Master's thesis, Universidade Federal do Rio Grande do Norte, PPgEEC, Natal/RN - Brasil.
- Norgaard, M., Ravn, O., Poulsen, N. K. and Hansen, L. K. (2001). *Neural Network for modelling and control of dynamic systems*, Springer-Verlag London Limited, Londres - Inglaterra.
- Rani, A., Singh, V. and Gupta, J. (2013). Development of soft sensor for neural network based control of distillation column, pp. 438–449.
- Warne, K., Prasad, G., Rezvani, S. and Maguire, L. (2004a). Statistical and computational techniques for inferencial model development: a comparative evaluation and a novel proposition for fusion, *Engineering Applications of Artificial Intelligence* 17(8), pp. 871–875.
- Zamprogna, E., Barolo, M. and Seborg, D. (2005). Optimal selection of soft sensor inputs for batch distillation columns using principal component analysis, *Journal of Process Control*, pp. 39–52.