

Modelagem e simulação de sistemas de compressão de gás natural por redes neurais artificiais

Hugo de Cuffa¹, Flavia Cristina Bernardini², Edwin Benito Mitacc Meza²

hccuffa@yahoo.com.br, febernardini@id.uff.br, emitacc@id.uff.br

¹MESC, Instituto de Ciência e Tecnologia – Universidade Federal Fluminense

²LABIDES, Instituto de Ciência e Tecnologia – Universidade Federal Fluminense

Rio das Ostras, Rio de Janeiro - Brasil

Resumo: Este artigo propõe um método de simulação de uma planta de compressão de gás natural de três estágios por meio de redes neurais artificiais. Utilizando dados de pressão, temperatura e vazão do gás na entrada da unidade de compressão, e rotação do compressor em operação a regime pleno, são propostos dois arranjos de redes neurais artificiais para predição de variáveis de processo (pressão, temperatura e vazão) em diversos pontos à jusante na planta. Um dos arranjos possui uma rede neural independente para cada variável estimada. O outro arranjo é constituído de uma única rede neural de diversas saídas, cada qual associada a uma variável de processo estimada. O desempenho de ambos os métodos é avaliado frente aos valores reais das variáveis, sendo estabelecido um paralelo entre os sistemas inteligentes. Neste artigo, são apresentados os parâmetros de simulação, as arquiteturas de rede, erros médios quadráticos e percentual de cada variável analisada, e gráficos de resposta à entrada do sistema.

Palavras chave: Modelagem e Simulação de Compressores, Redes Neurais Artificiais.

Abstract: This paper presents a brief description of a three-stage natural gas compression system simulation project using artificial neural networks. Using pressure, temperature and gas flow data at compression unit inlet, and compressor speed at steady state, it's proposed two neural network arrangement for process variables (pressure, temperature and flow) simulation at several downstream points on plant. One of it has a independent neural network for every evaluated process variable. The other is composed of a multiple output neural network, each output being associated to a process variable. Performance of both methods is examined regarding real process variables values, as well as a comparison between developed learning machines. This article presents simulation parameters, network architectures, mean-square and mean-percent error for all simulated variables and system input response graphs.

Keywords: Modeling and Simulation Compressors, Artificial Neural Networks.

1 Introdução

O petróleo proveniente dos reservatórios naturais submarinos é composto basicamente de óleo, gás, água, sal e particulados. Após processos de separação, o gás obtido é comprimido em vários estágios, para então ser empregado em suas finalidades. Assim, a compressão de gás natural é um processo fundamental na indústria do petróleo, presente tanto em unidades terrestres quanto marítimas. Em unidades marítimas, desempenha função na injeção de gás na coluna de produção (também conhecido como “gás lift”), essencial para movimentação do óleo extraído de reservatórios petrolíferos insurgentes, adequação da pressão de gás combustível para consumo na própria plataforma, e movimentação de gás entre unidades e o continente. Para melhor relação custo-benefício, o gás é geralmente elevado e transportado a altas pressões por meio de compressores antes de entrar nas linhas para movimentação [Hafaifa+09] [Devold+09].

Uma unidade de compressão de gás natural geralmente possui gerador de força motriz (turbina, motor à combustão ou elétrico), compressor, vasos depuradores, permutadores de calor, instrumentação (sensores de temperatura, pressão, vazão, nível, dentre outros), elementos finais de controle (válvulas e atuadores) e sistema de controle [TransCanada+14] [Devold+09]. Alterações de lógica no sistema de controle e respectivos testes frequentemente esbarram em barreiras logísticas e operacionais, além de custos, tendo em vista necessidade de embarque de profissionais, disponibilidade de máquina e possibilidade de perda de produção. O treinamento de

operadores de turbo-máquinas, incluindo turbo-compressores, também tem sido objeto de preocupação, pelos mesmos motivos. O uso de simuladores tem especial importância no sentido de que tais atividades são realizadas em planta virtual, minimizando intervenções na planta real. Assim sendo, novas estratégias de controle, além de grande diversidade de situações operacionais, podem ser testadas livremente tanto para fins de treinamento quanto para aprimoramento de desempenho do sistema de compressão.

Redes neurais artificiais têm sido empregadas em problemas de regressão e séries temporais. Uma rede neural é um processador altamente paralelo constituído de unidades elementares de processamento, possuindo a capacidade de armazenar conhecimento experimental e utilizá-lo. A propriedade de generalização, presente nas redes neurais artificiais, é a habilidade de geração de saídas coerentes relativamente a entradas não conhecidas durante sua fase de treinamento. Tais características as tornam capazes de aproximar soluções em problemas complexos intratáveis [Haykin+09].

Neste artigo são propostos dois métodos de simulação por meio de redes neurais artificiais de uma planta de compressão de gás natural, composta de um elemento motriz e compressor de três estágios. Para isso, foram utilizadas variáveis de pressão, temperatura e vazão do gás em diversos pontos da planta. Em cada método, lançou-se mão de uma arquitetura de única camada para prever as diferentes variáveis do problema. Para treinamento da RNA, foi adotado o software Matlab.

2 Trabalhos relacionados

Em [Adib+13] emprega-se Máquinas de Vetor Suporte (SVMs, do inglês *Support Vector Machines*) no desenvolvimento de um modelo de estimação de variáveis de saída de uma planta de suavização de gás natural. Os resultados são comparados aos de uma rede neural artificial, adotando o mesmo conjunto de dados. O autor conclui que o estudo demonstra a aplicabilidade de SVM no problema proposto, bem como em indústrias complexas de óleo e gás. Para o problema tratado no artigo, os autores mostraram a superioridade das SVMs sobre a RNA.

Já [Wen+11] aborda a construção de um modelo de turbocompressor de velocidade variável com tratamento anti-surge, baseado na modelagem física determinística da turbina a vapor, compressor centrífugo, tubulação e válvula anti-surge. São construídos dois controladores PID (Proporcional Integral-Derivativo), um deles governando a velocidade da turbina e o outro, a válvula anti-surge. O desempenho do sistema foi avaliado em situações de perturbação na razão de compressão e vazão, individualmente, bem como em ambos simultaneamente.

Por outro lado, [Gravdahl+97] aborda a modelagem de um sistema de compressão de velocidade variável, incluindo compressor, válvula anti-surge e controle associado. O compressor é modelado por perdas de energia por incidência e fricção. É desenvolvido uma lei de controle anti-surge e um controle PI (Proporcional Integral) de velocidade. É provada estabilidade exponencial semi-global do modelo com os controles propostos por meio do teorema de Lyapunovs [Murray+08]. Os autores concluem, pelas simulações, que o compressor pode operar estavelmente e alcançar a velocidade desejada desde a região instável até a direita da linha de surge (região estável) no mapa do compressor. O sistema de compressão, no entanto, é de único estágio, e a válvula anti-surge é de acoplamento próximo, atuando por restrição da vazão na descarga da máquina, não realizando reciclo de gás.

Em [Figueiredo+13] foram empregados redes neurais artificiais (RNA) para previsão de produtos gerados de destilação de óleo, sendo utilizado o método de retropropagação para treinamento da RNA. Os resultados foram comparados com os obtidos pelo método de regressão múltipla.

Já em [Chen+12] foi empregado uma rede neural artificial retropropagada para construir um modelo com objetivo de teste e previsão de performance de um compressor. Utilizou-se dados coletados online do CLP (Controlador Lógico Programável) de controle da máquina para treinamento do método, lançando-se mão do algoritmo de Levenberg-Marquardt, executado no software Alyuda NeuroIntelligence.

Finalmente, em [Ghorbanian+09] abordam predição do mapa de performance de compressores utilizando diferentes tipos de redes neurais artificiais (GRNN – *General Regression Neural Network*; RBFN – *Radial Basis Function Network*; e MLP – *Multilayer Perceptron Network*). O autor conclui seus resultados em função dos

três métodos testados. O mapa de performance de um compressor mostra seu comportamento de razão de compressão (pressão na descarga / pressão na sucção) em função da vazão de gás.

A pesquisa bibliográfica revela existência de estudos relacionados, mas não idênticos ao proposto, divergindo no método matemático utilizado, nas variáveis analisadas, no tipo de compressor ou planta industrial simulada, havendo, portanto, espaço para a pesquisa aqui apresentada.

3 O problema de compressão em três estágios

A unidade de compressão em estudo é composta de um compressor centrífugo de três estágios em série, separados por permutadores de calor, válvulas de reciclo, válvulas de retenção (do inglês *check valves*), vasos depuradores e torre de glicol. Uma turbina, acoplada a uma caixa multiplicadora, movimenta o conjunto. O sistema como um todo é complexo, composto de inúmeras partes, apresentando interdependência entre os elementos constituintes. A Figura 1 ilustra tal planta de compressão.

A corrente de gás natural entra na unidade e passa por três estágios de compressão, até sua saída. Em cada estágio de compressão, o gás passa por vaso depurador, compressor e permutador. Cada estágio eleva a pressão do gás em determinada quantidade, obtendo-se, na saída da unidade, a pressão final desejada para os objetivos a que se destina o gás.

O vaso depurador e a torre de glicol retém líquidos condensados, para que não sejam carreados ao compressor, visto que o danifica. O compressor tem por objetivo elevar a pressão do gás, segundo uma relação (pressão na descarga / pressão na sucção) característica do compressor, também elevando sua temperatura como consequência da compressão. A refrigeração do gás, realizada pelo permutador, impede que sua temperatura se eleve indefinidamente pelas sucessivas compressões, mantendo-a dentro de limites aceitáveis pelos elementos da planta, além de aumentar a eficiência do processo de compressão, visto que, quanto menor a temperatura na sucção do compressor, menor será a energia necessária para elevar o gás a uma dada pressão e temperatura finais. A malha de reciclo permite a recirculação parcial ou total do gás, de modo a manter a relação de compressão dentro de limites operacionais do compressor. Válvulas de retenção impedem fluxo reverso do gás entre estágios [TransCanada+14] [Devold+09].

Uma malha de instrumentação em campo, conectada a um CLP (Controlador Lógico Programável), monitora a instalação em tempo real, sendo adquiridas e historiadas informações de pressão, temperatura e vazão em diversos pontos, além da rotação da turbina. A Tabela 1 enuncia os pontos associados a cada instrumento no sistema.

Como pode ser observado na Figura 1, o gás entra na planta, passa por seus elementos, até sua saída da unidade de compressão. Porquanto a velocidade do gás ser finita, há um tempo de resposta do sistema, diferente para cada ponto instrumentado, desde a entrada do gás no sistema até sua chegada a tal ponto, sendo esse tempo de difícil determinação em razão da elevada oscilação de vazão do gás, atuação de válvulas de purga e de reciclo.

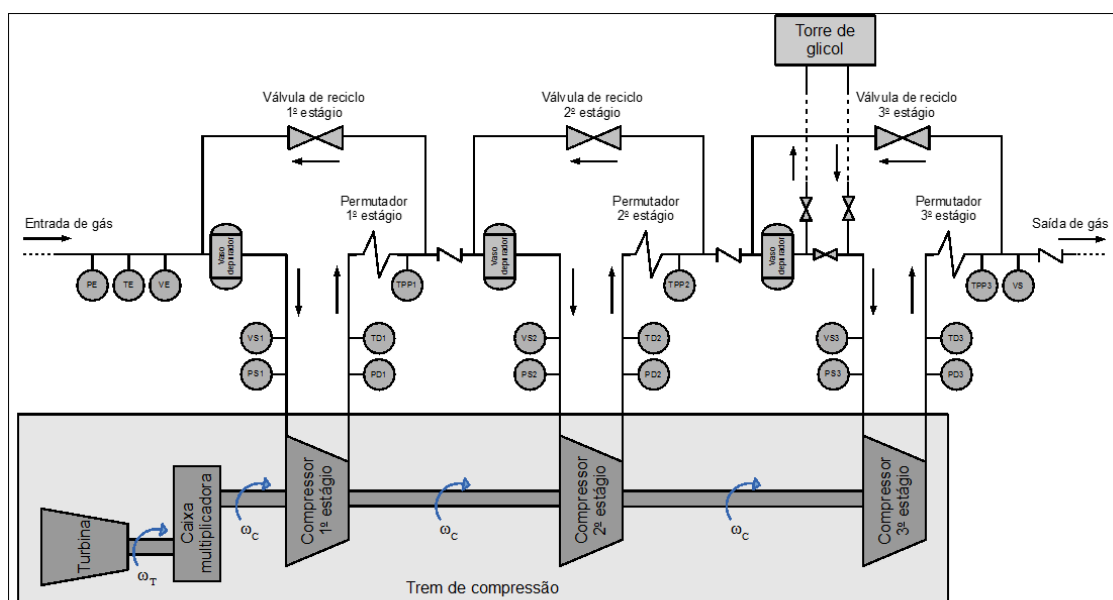


Figura 1: Planta de compressão de gás natural em estudo.

Medições de vazão, representadas pelas variáveis VS1, VS2, VS3 e VS, são realizadas sobre a pressão diferencial em placas de orifício, justificando o uso de grandeza física de pressão (kPa e bar) neste tipo de medição. Cálculos envolvendo a pressão diferencial medida e outras propriedades do gás levam à vazão volumétrica e mássica, não abordados neste artigo.

Dados operacionais dos pontos instrumentados foram levantados, a partir de um banco de dados, com o sistema operando em regime pleno (do inglês *steady state*), por um período contínuo de tempo, a uma taxa de amostragem de uma amostra/segundo, caracterizando uma análise de série temporal. Na sequência, foram passados para treinamento de redes neurais artificiais, onde a pressão (PE), temperatura (TE) e vazão (VE) do gás na entrada da unidade de compressão, e rotação do elemento motriz (ωT), foram configuradas como entradas, e demais variáveis configuradas como saídas, obtendo-se, portanto, um sistema simulador que, para dadas características da corrente do gás de entrada, estima as demais variáveis da planta de processo.

Tabela 1: Variáveis abordadas na pesquisa.

Variável	Descrição	Unidade física
PE	Pressão do gás de processo na entrada da unidade de compressão	bar
TE	Temperatura do gás de processo na entrada da unidade de compressão	°C
VE	Vazão do gás de processo na entrada da unidade de compressão	Sm ³ /h
ωT	Rotação da turbina de potência (elemento motriz do compressor)	rpm
PS1	Pressão do gás de processo na sucção do compressor, 1º estágio	bar
PS2	Pressão do gás de processo na sucção do compressor, 2º estágio	bar
PS3	Pressão do gás de processo na sucção do compressor, 3º estágio	bar
PD1	Pressão do gás de processo na	bar

	descarga do compressor, 1º estágio	
PD2	Pressão do gás de processo na descarga do compressor, 2º estágio	bar
PD3	Pressão do gás de processo na descarga do compressor, 3º estágio	bar
TD1	Temperatura do gás de processo na descarga do compressor, 1º estágio	°C
TD2	Temperatura do gás de processo na descarga do compressor, 2º estágio	°C
TD3	Temperatura do gás de processo na descarga do compressor, 3º estágio	°C
TPP1	Temperatura do gás de processo, pós-permutador, 1º estágio	°C
TPP2	Temperatura do gás de processo, pós-permutador, 2º estágio	°C
TPP3	Temperatura do gás de processo, pós-permutador, 3º estágio	°C
VS1	Vazão do gás de processo na sucção do compressor, 1º estágio	kPa
VS2	Vazão do gás de processo na sucção do compressor, 2º estágio	kPa
VS3	Vazão do gás de processo na sucção do compressor, 3º estágio	kPa
VS	Vazão do gás de processo na saída da unidade de compressão	bar

4 Modelagem por RNA e experimentos realizados

Redes totalmente conectadas de várias saídas são interessantes no que concerne à relação entre as variáveis simuladas, o que é condizente com a organização física do sistema. Duas arquiteturas neurais foram montadas para simulação da planta de compressão, sendo comparadas. Na Figura 2, uma rede neural é utilizada para cada variável simulada, sendo, portanto, cada uma independente das demais. Na Figura 3, uma única rede neural de várias saídas foi empregada para simular o problema. O mesmo padrão de conjunto de dados de entrada (PE, TE, VE, ωT), com histórico de $t-n$ a $t-1$, é aplicado aos sistemas de aprendizado de máquina.

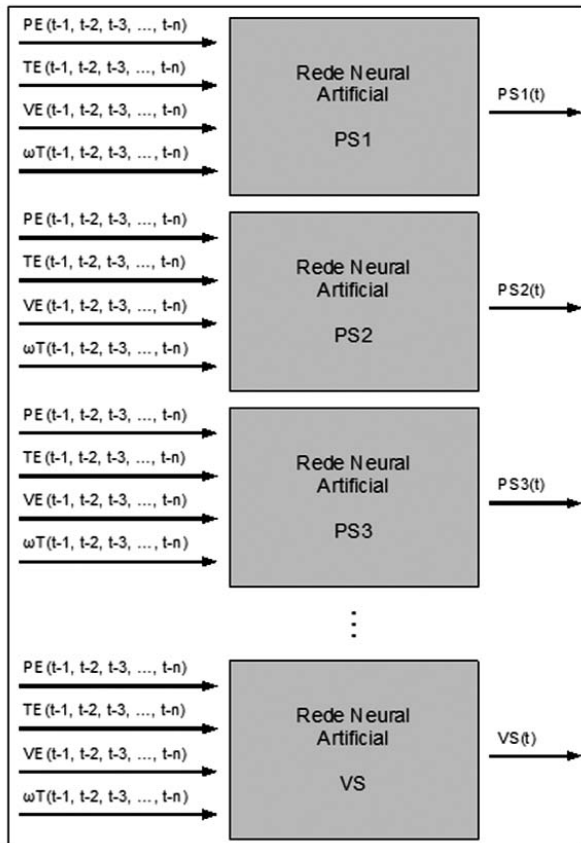


Figura 2: Arquitetura neural individual.




Figura 3: Arquitetura neural coletiva.

Duas bases de dados foram tomadas no estudo. A primeira, abrangendo 80.000s (aproximadamente 22h) de operação da planta de compressão, foi utilizada para treinamento e validação pelo software matemático. A segunda, abrangendo 43.200s (12h) de operação da planta de compressão, foi empregada exclusivamente para testes, obtendo-se o erro real.

Os ensaios foram conduzidos com software matemático Matlab R2013a 64 bits. Fruiu-se dos seguintes parâmetros de normalização de dados, disponíveis no software matemático:

- mapminmax - Escalonamento de valor de entradas e objetivo de modo que permaneçam na faixa [-1,1];
- removeconstantrows - Remove linhas com valores constantes;
- Normalização de erro tipo 'standard' - Escalona o erro no processo de treinamento, de modo que permaneça na faixa [-2,2].

As redes foram configuradas como a seguir: Rede neural tipo timedelaynet; uma camada intermediária contendo 20 neurônios e função de transferência sigmóide simétrica; uma camada de saída com 1 neurônio por variável simulada e função de transferência linear; algoritmo de treinamento por retropropagação Levenberg-Marquardt; e histórico de 15s ($n = 15$) para cada variável de entrada, o maior possível no computador adotado, com a configuração neural usada.




Figura 4: Rede neural individual implementada no software.




Figura 5 - Rede neural coletiva implementada no software.

A Figura 4 e a Figura 5 apresentam as arquiteturas resultantes, após codificação no software. Observa-se que na arquitetura neural individual, cada rede tem 1 neurônio na camada de saída, e na arquitetura coletiva, a rede possui 16 neurônios em tal camada.

Os resultados numéricos do erro obtido quando é submetido o vetor de testes às redes treinadas são resumidos a seguir. A Tabela 2 compara o erro médio percentual entre os métodos abordados, e a Tabela 3, o erro médio quadrático.

Tabela 2: Erro médio percentual obtido com vetor de testes.

	Arquitetura individual	Arquitetura coletiva
PS1	1,3672	1,7266
PS2	1,0334	1,0944
PS3	0,9473	0,6317
PD1	1,2745	1,0426
PD2	1,3362	0,6830
PD3	0,4113	0,2897
TD1	0,9255	0,9698
TD2	1,8185	1,5466
TD3	0,9035	1,3226
TPP1	1,2224	1,2987
TPP2	4,2888	2,8328
TPP3	1,2361	1,2998
VS1	2,3901	2,6880
VS2	5,3777	5,6635
VS3	6,9314	8,3027
VS	10,2904	16,8161

Tabela 3: Erro médio quadrático obtido com vetor de testes.

	Arquitetura individual	Arquitetura coletiva
PS1	0,0124	0,0198
PS2	0,0971	0,0747
PS3	0,8392	0,3445
PD1	0,1729	0,0761
PD2	1,7276	0,4615
PD3	1,4795	0,5285
TD1	2,5581	2,3593
TD2	7,0731	5,3754
TD3	2,8239	6,5404
TPP1	0,2496	0,2407
TPP2	1,5273	0,7885
TPP3	0,7795	0,9425
VS1	0,0709	0,0661
VS2	2,3136	2,3832
VS3	9,8530	13,7185
VS	0,0009	0,0018

Esclarece-se abaixo o cálculo do erro, onde T é o tempo total do conjunto de dados, em segundos:

$$\text{Erro médio percentual} = \frac{1}{T} \sum_{t=1}^T \left(100 * \left| \frac{\text{Valor simulado}_t - \text{Valor objetivo}_t}{\text{Valor objetivo}_t} \right| \right)$$

$$\text{Erro médio quadrático} = \frac{1}{T} \sum_{t=1}^T (\text{Valor simulado}_t - \text{Valor objetivo}_t)^2$$

Uma análise gráfica do resultado de simulação dos modelos também é importante à comparação de desempenho entre eles, bem como de sua fidelidade ao processo real. As Figuras 6 a 21 apresentam alguns resultados, sendo as variáveis reais representadas pelos gráficos em azul, e as variáveis simuladas pelos gráficos em verde, cuja discussão é feita na seção seguinte. Os gráficos de todas as variáveis, para ambos os métodos, podem ser encontrados no site (copiar e colar no navegador):

https://drive.google.com/file/d/0B_RCK_qyMGHbLWMxWUNQSWc4SzA/view?usp=sharing




Figura 6: PD1 - Arquitetura neural individual.




Figura 7: PD1 - Arquitetura neural coletiva.




Figura 8: PD2 - Arquitetura neural individual.




Figura 9: PD2 - Arquitetura neural coletiva.




Figura 10: TD1 - Arquitetura neural individual.




Figura 11: TD1 - Arquitectura neural colectiva.




Figura 15: TPP1 - Arquitectura neural colectiva.




Figura 12: TD2 - Arquitectura neural individual.




Figura 16: TPP2 - Arquitectura neural individual.




Figura 13: TD2 - Arquitectura neural colectiva.




Figura 17: TPP2 - Arquitectura neural colectiva.




Figura 14: TPP1 - Arquitectura neural individual.




Figura 18: VS2 - Arquitectura neural individual.




Figura 19: VS2 - Arquitetura neural coletiva.




Figura 20: VS - Arquitetura neural individual.




Figura 21: VS - Arquitetura neural coletiva.

5 Análise dos resultados

A grandeza física de vazão, pelo menos nesta pesquisa, mostrou erro percentual médio maior frente às demais. O sistema neural, entretanto, foi capaz de simular bem o comportamento das variáveis reais de vazão do processo. Houve um bom casamento entre os gráficos das variáveis real e simulada para VS1, VS2, VS3 e VS.

Os resultados associados à temperatura obtiveram melhores índices numéricos de erro percentual em relação à vazão, embora há menos correspondência entre as oscilações observadas nas variáveis reais e simuladas. Em especial, em TD2, TPP1 e TPP2 existem componentes de alta frequência nas variáveis simuladas, ausentes nas variáveis reais.

Das três grandezas físicas simuladas, os melhores resultados foram os de pressão, tendo os menores erros percentuais e melhor correspondência entre os gráficos real e simulado.

De maneira geral, repara-se em todos os gráficos gerados pelas redes neurais a existência de pelo menos um *outlier*, sem o concurso da variável real.

Pelos valores de erro tabelados, repara-se que a arquitetura neural individual se mostra mais precisa na predição das variáveis de vazão. A análise gráfica, no entanto, revela boa coerência entre variáveis real e simulada para ambos os métodos. De forma geral, parece não haver uma clara superioridade de uma arquitetura sobre a outra para o problema tratado.

Testes indicaram que a precisão dos resultados aumenta com o histórico de dados processado pela rede neural, em detrimento da maior demanda computacional para seu treinamento. O valor utilizado, $n = 15s$, proporcionou picos de 53GB de memória consumida durante o treinamento da rede neural coletiva, não sendo possível ultrapassá-lo no computador utilizado.

6 Conclusões e trabalhos futuros

Os resultados indicam que as redes neurais artificiais têm potencial de reprodução do comportamento de variáveis de plantas de compressão de gás natural, podendo ser uma alternativa aos métodos determinísticos em diversas ocasiões.

Não se deve perder de vista que este texto mostra somente um pequeno extrato de uma vasta gama de configurações possíveis de um método de inteligência artificial e, por assim dizer, está longe de virar sua última página.

Variáveis específicas do sistema de reciclo, como vazão de reciclo e posição de válvulas de reciclo, bem como vazão de purga e posição de válvulas de purga, não estavam disponíveis na base de dados usada, e certamente agregariam precisão aos resultados, porquanto influenciarem as variáveis de processo abordadas. Uma base de dados mais completa é, deste modo, uma oportunidade de aprimoramento.

A inclusão de estados atual e anteriores de variáveis de processo na predição de seu próximo estado também é interessante, sobretudo no contexto de partida e parada da planta de compressão. Modelos recorrentes possuem um grande repertório de configurações arquiteturais e propriedades que os tornam os mais poderosos em termos computacionais [Haykin+09]. Insta, assim, sua aplicação nesta predição não-linear.

A pesquisa ora divulgada trata do sistema de compressão em regime permanente. Cenários de partida e parada do conjunto também são importantes no tema em questão.

Por fim, salienta-se que em uma planta de compressão de gás natural como a discutida, há uma relação complexa de interdependência entre as variáveis analisadas. Uma variável não depende somente de outras à montante na corrente do gás, mas também de variáveis à jusante. Esta é mais uma limitação do modelo desenvolvido e que pode ser aperfeiçoado em trabalhos futuros.

Referências bibliográficas

- [Hafaifa+09] Hafaifa, A. Laaouad, F. Guemana, M. A. *New Engineering Method for Fuzzy Reliability Analysis of Surge Control in Centrifugal Compressor*. American Journal of Engineering and Applied Sciences 2, 2009, 676-682 ps.
- [Devold+09] Devold, H. *Oil and gas production handbook*. ABB Oil and Gas, 2009, <http://www.saudienergy.net/PDF/Intro%20Oil.pdf>, 15-16ps, 21ps, 33-35ps, 38ps, 41-52ps.
- [TransCanada+14] TransCanada. *The basics of a compressor station*. 2014, [https://www.prince-rupert-natural-gas-transmission-compressor-station-basics-factsheet-transcanada.pdf](https://www.prince-rupertgas.com/wp-content/uploads/2014/04/prince-rupert-natural-gas-transmission-compressor-station-basics-factsheet-transcanada.pdf).
- [Haykin+09] Haykin, S. *Neural Networks and Learning Machines*. Pearson Education, 2009, 2ps, 791 ps.
- [Adib+13] Adib, H. Sharifi, F. Mehranbod, N. Kazerooni, N. M. Koolivand, M. *Support Vector Machine based modeling of an industrial natural gas sweetening plant*. Journal of Natural Gas Science and Engineering 14, 2013, 121-131 ps.
- [Wen+11] Wen, L. Gao, L. Dai, Y. *Research on System Modeling and Control of Turbine-driven Centrifugal Compressor*. 6th IEEE Conference on Industrial Electronics and Applications, 2011, 2090-2095 ps.
- [Figueiredo+13] Figueiredo, C. J. J. Silva, M. H. L. Moreira, F. C. *Aplicação de Redes Neurais Artificiais em Processo de Destilação de Óleo Essencial*. ENGEVISTA, V. 15, n. 1, 2013, 36-42 ps.
- [Gravdahl+97] Gravdahl, J. T. Egeland, O. *Speed and surge control for a low order centrifugal compressor model*. Proceedings of the 6th IEEE International Conference on Control Applications, 1997, 344-349 ps.
- [Murray+08] Murray, R. M. Astrom, K. J. *Feedback Systems*. Princeton University Press, 2008, 102-118ps.
- [Chen+12] Chen, P. C. Chang, H. T. Hsu, A. *A Study of Using Artificial Neural Network in a Non-linear Centrifugal Compressor System*. International Journal on Computer Science and Engineering, Vol. 4, No. 12, 2012, 1890-1896 ps.
- [Ghorbanian+09] Ghorbanian, K. Gholamrezaei, M. *An artificial neural network approach to compressor performance prediction*. Applied Energy 86, 2009, 1210-1221 ps.