

IDENTIFICAÇÃO DE PADRÕES DE ESCOAMENTO MULTIFÁSICO E DETERMINAÇÃO DA PERDA DE CARGA COM O AUXÍLIO DE REDES NEURAIAS

¹Fabíola Pacheco (Unicamp), ²César Cláudio P. Cavalcante (Unicamp). ³José Ricardo P. Mendes (Unicamp), Antônio C. Bannwart (Unicamp), Adriane B. de Souza Serapião (Unesp).

¹fabiola@dep.fem.unicamp.br

²cesar@dep.fem.unicamp.br

³jricardo@dep.fem.unicamp.br

Escoamentos multifásicos são comumente encontrados na produção e transporte de óleo e gás. Neste tipo de escoamento, as fases presentes podem escoar dispostas em diferentes configurações espaciais no interior do duto, denominadas de padrões de escoamento. A identificação dos padrões de escoamento é essencial para questões que estão estritamente relacionadas ao retorno econômico do campo como, por exemplo, na medição das vazões volumétricas transportadas, determinação da queda de pressão ao longo das linhas de escoamento, gerenciamento da produção e fiscalização. Estes fatores são críticos em condições de produção offshore, onde grandes distâncias e altos custos estão envolvidos. Diversos modelos utilizados para estimativa dos gradientes de pressão ao longo das linhas de produção e transporte levam em consideração os regimes de escoamento presentes. Estes métodos consistem em correlações empíricas e modelos mecanicistas. Os métodos mecanicistas visam o desenvolvimento de soluções analíticas descritivas do escoamento a partir dos conceitos básicos da mecânica dos fluidos. Por outro lado, o desenvolvimento empírico consiste na obtenção de correlações por meio da análise de dados experimentais. Apesar dos avanços realizados nos últimos anos, ambas as metodologias ainda não fornecem resultados com a precisão e confiabilidade requeridas pela indústria. Uma abordagem não-fenomenológica para caracterização do regime de escoamento e estimativa do gradiente de pressão em escoamentos multifásicos, baseada no emprego da ferramenta de redes neurais, é apresentada neste trabalho. Duas redes neurais artificiais (RNA's) foram desenvolvidas e testadas: a primeira especializada na caracterização de padrões de escoamento multifásico para tubos verticais e a segunda especializada na estimativa do gradiente de pressão associado ao padrão de escoamento. Um conjunto contendo 120 séries de dados oriundos de ensaios experimentais de escoamento vertical ascendente de óleo pesado assistido por água foi utilizado para treinamento, validação e teste das RNA's. Valores das vazões dos fluidos, pressão absoluta, temperatura, razão gás-óleo (RGO) e BSW (*basic sediments and water*) foram utilizados como dados de entrada para as redes neurais. Os resultados das simulações das RNA's desenvolvidas foram comparados com os obtidos experimentalmente e calculados através das correlações empíricas de Beggs & Brill e Hagerdorn & Brown. As RNA's apresentaram previsões mais precisas e exatas quando comparados com as correlações empíricas. Isto foi verificado em termos de maiores valores dos coeficientes de correlação e menores desvios médios absolutos em relação aos resultados experimentais.

Redes Neurais, Escoamento Multifásico, Padrões de Escoamento, Gradiente de Pressão.

1. INTRODUÇÃO

Escoamentos multifásicos podem ser encontrados em diversas áreas de conhecimento, tais como, na indústria química, alimentícia e de petróleo. O conhecimento das propriedades relacionadas a este tipo de escoamento é fundamental para o planejamento e dimensionamento adequado de métodos e equipamentos utilizados nesses setores.

Durante as fases de produção e transporte de petróleo, gás e líquido podem ser encontrados escoando simultaneamente no interior de dutos. As fases presentes podem, portanto, estar dispostas em diversas configurações espaciais, que são denominadas de padrões de escoamento.

A identificação dos padrões de escoamento é essencial para questões que estão estritamente relacionadas ao retorno econômico do campo como, por exemplo, na medição das vazões volumétricas transportadas. Além disso, diversos modelos utilizados para estimativa dos gradientes de pressão ao longo das linhas de produção e transporte, de gás e óleo, levam em consideração os regimes de escoamento presentes.

Diversas pesquisas vêm sendo realizadas desde a década de 40 com o objetivo de desenvolver métodos para previsão dos padrões de escoamento e estimativa dos gradientes de pressão ao longo de tubulações. Em geral, duas abordagens são consideradas: os modelos mecanicistas e as correlações empíricas. Os métodos mecanicistas visam o desenvolvimento de soluções analíticas descritivas do escoamento a partir dos conceitos básicos da mecânica dos fluidos. A metodologia empírica, por outro lado, consiste na obtenção de correlações por meio da análise de dados experimentais.

Apesar dos avanços realizados em ambas as metodologias citadas, os resultados obtidos ainda não fornecem a precisão e confiabilidade requeridas pela indústria.

Mesmo sendo uma tecnologia relativamente recente, a utilização de redes neurais artificiais (RNA's) tem sido bem sucedida na solução de problemas complexos, despertando, assim, o interesse da indústria de petróleo. As RNA's possuem a capacidade de aprendizado e generalização, mesmo dispondo de dados poucos precisos. Portanto, as RNA's são amplamente aplicáveis em problemas que requerem a identificação de padrões e estimativa de valores.

Este trabalho tem por finalidade apresentar a modelagem de duas redes neurais artificiais utilizadas para a previsão dos padrões de escoamento e estimativa dos gradientes de pressão. Um conjunto contendo 120 séries de dados experimentais, incluindo vazões das fases escoando, pressão absoluta, temperatura, razão gás-óleo (RGO) e BSW (*basic sediments and water*), foi utilizado para treinar, validar e testar as redes neurais desenvolvidas.

Os resultados obtidos das simulações das RNA's foram comparados com algumas das correlações empíricas mais utilizadas na indústria. Essa análise indicou que as RNA's possuem uma melhor capacidade de estimativa dos padrões de escoamento e da perda de carga sendo, portanto, uma ferramenta viável para esse tipo de aplicação.

2. REVISÃO DA LITERATURA

2.1 Propriedades do Escoamento Multifásico

Durante a produção e o transporte de petróleo, o escoamento bifásico é freqüentemente observado no interior da coluna de produção e nas tubulações de escoamento, ocorrendo em trechos horizontais, inclinados ou verticais. Devido ao caráter complexo do escoamento multifásico diversas metodologias foram desenvolvidas com a finalidade de identificar os padrões de escoamento e estimar o gradiente de pressão. O conhecimento dessas propriedades é essencial para o dimensionamento dos dutos e dos equipamentos de produção.

Segundo Tackacs (2001) as principais correlações utilizadas na indústria de petróleo são: Hagedorn & Brown, Beggs e Brill, Aziz e Govier e Mukherjee e Brill. Neste trabalho as correlações de Beggs & Brill, Hagedorn & Brown foram utilizadas como referência para comparação com os resultados obtidos pelas redes neurais artificiais.

Beggs & Brill (1973) desenvolveram uma correlação empírica para cálculo do gradiente de pressão ao longo de tubulações orientadas sob qualquer inclinação. Eles utilizaram ar e água para simular o escoamento bifásico no interior de dutos de acrílico com 2,54 e 3,81 centímetros de diâmetro. Medições do *holdup* de líquido (fração volumétrica de uma seção do duto ocupada pela fase líquida) e do gradiente de pressão foram realizadas para inclinações da tubulação variando desde a horizontal até a vertical.

Hagedorn & Brown (1965) elaboraram uma correlação para cálculo do gradiente de pressão em escoamentos verticais a partir de dados originados de um poço experimental com 500 m de profundidade. Neste trabalho, o *holdup* de líquido é utilizado apenas como um parâmetro de ajuste entre o gradiente de pressão mensurado e o gradiente de pressão calculado. Dessa forma, seu valor não representa uma medida da fração do duto ocupado pelo líquido.

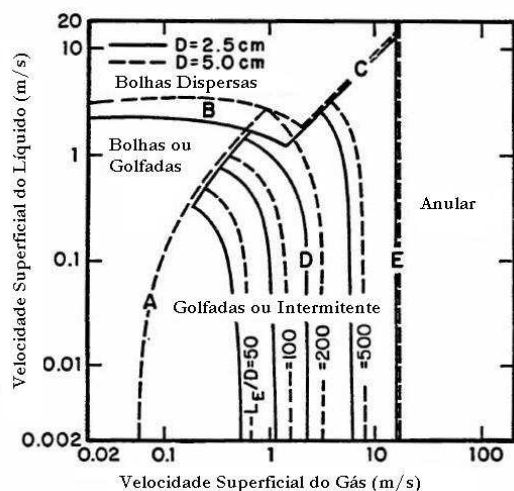


Figura 1. Mapa de Taitel & Dukler para Escoamento Vertical Ascendente




Figura 2. Padrões de Escoamento Verticais Segundo Taitel & Dukler

Taitel & Dukler (1976) apresentaram um excelente modelo mecanicista para previsão da transição entre os regimes de escoamento em tubulações verticais. Eles realizaram um balanço da quantidade de movimento de cada um das fases escoando no interior do duto para avaliar os mecanismos de transição entre os padrões de escoamento. Com base nos resultados obtidos, foi elaborado um mapa de escoamento delimitando as faixas de valores de vazão onde cada regime de fluxo é observado, conforme mostrado na Figura 1. A Figura 2 apresenta os padrões de escoamento observados nesse trabalho.

Apesar da grande quantidade das correlações existentes, a previsão dos resultados não é obtida com a acurácia desejada, segundo Aggour et Al (1994) e Rao (1998); um dos motivos é o caráter estatístico das correlações, que são expressões globais, possuindo limitadas considerações físicas, e, portanto podem se tornar restritas na tentativa de prever situações reais de campo. Devido a sua capacidade de aprendizado e generalização as RNA's podem ser aplicadas na extração dessas considerações físicas, podendo proporcionar melhores resultados.

2.2 Aplicações de Redes Neurais Artificiais em Escoamentos Multifásicos

As redes neurais artificiais (RNA's) são sistemas computacionais formados pela integração de inúmeros elementos de processamento, os neurônios, interconectados e atuando em paralelo. Apesar da simplicidade funcional e estrutural, as RNA's possuem diversas habilidades, tais como, a facilidade no reconhecimento de padrões em um conjunto de dados.

O uso de RNAs na indústria de petróleo é recente, e seu potencial não foi completamente explorado. Apesar disso, muitos pesquisadores têm aplicado redes neurais artificiais para resolver vários problemas associados ao escoamento multifásico.

Bilgesu et Al (1995) publicaram dois trabalhos onde utilizaram redes neurais para a identificação dos padrões de escoamentos e estimativas do *holdup* de líquido e da pressão de fluxo no fundo do poço (BHP). Uma nova metodologia, denominada de *Virtual Measurements in Pipes* (VMP), foi desenvolvida com a finalidade de fornecer previsões das propriedades do escoamento multifásico. Os resultados obtidos através das simulações das redes neurais foram comparados com dados laboratoriais, de campo e com correlações empíricas. As redes neurais mostraram boa concordância com os valores experimentais e de campo e, quando comparadas com as correlações, obtiveram melhores desempenhos.

Crivelaro & Seleglim (1999) apresentaram um trabalho onde utilizavam redes neurais artificiais associadas a uma sonda de visualização direta para caracterização dos padrões de escoamento horizontais. Ar e água foram usados como fluidos de teste. Os resultados demonstraram desempenho satisfatório do sistema desenvolvido.

Ishii, Mi e Tsoukalas (2000) desenvolveram uma metodologia para previsão em tempo real dos padrões de escoamento em escoamentos verticais baseada em redes neurais. Valores estatísticos da impedância do fluxo bifásico foram usados como entradas para o sistema. Resultados obtidos da correlação de Mishima & Ishii foram utilizados como referência para o treinamento das redes. Os resultados obtidos demonstraram a aplicabilidade de redes neurais para a previsão dos padrões de escoamento verticais.

3. METODOLOGIA

3.1 Aquisições dos Dados Experimentais

Os dados utilizados para elaboração deste trabalho foram cedidos gentilmente por Bannwart et Al (2005). Eles desenvolveram um trabalho experimental para análise do escoamento trifásico de óleo pesado assistido com água em escoamentos verticais ascendentes. Os ensaios foram realizados na Faculdade de Engenharia Mecânica da Universidade Estadual de Campinas (UNICAMP). A Figura 3 apresenta o aparato utilizado nessa pesquisa.

A fase líquida foi constituída de uma emulsão de água em óleo com viscosidade de 5,040 mPa.s e densidade de 971 Kg/m³. Ar comprimido foi utilizado para simulação do escoamento da fase gasosa. Os fluidos foram misturados com o auxílio de misturador e bombeados através de um longo duto vertical de vidro com 2,84 cm de diâmetro. Os padrões de escoamento foram identificados por meio de visualização. Instrumentação para medição das vazões dos fluidos injetados e do diferencial de pressão ao longo do escoamento foi instalada no aparato.

Cento e vinte condições de escoamento foram testadas durante os ensaios experimentais. A região sombreada na Figura 4 representa a faixa de valores de velocidades superficiais (ou vazões) de líquido e gás abrangidas no experimento. Dados dos padrões de escoamento, pressões absolutas, temperaturas, gradientes de pressão, razões gás-óleo (RGO) e BSW (basic sediments and water) foram obtidos.

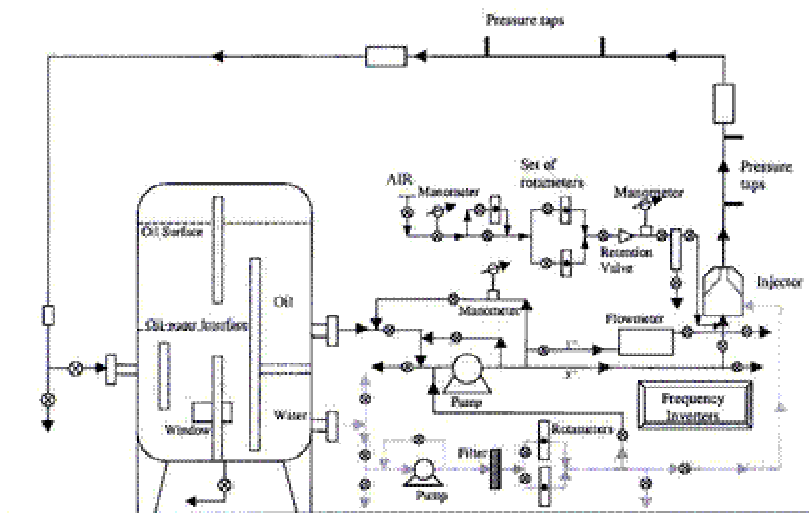


Figura 3. Aparato Experimental Utilizado para Aquisição dos Dados Experimentais.

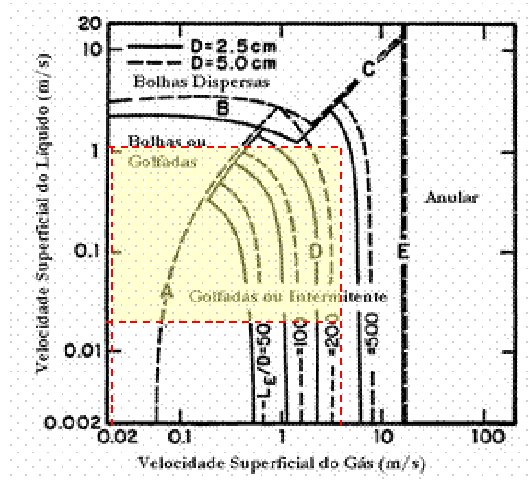


Figura 4. Faixa de Velocidades Superficiais do Experimento.

3.2 Classificações dos Padrões de Escoamento

Os padrões de escoamento observados durante os ensaios experimentais foram classificados como bolhas, bolhas dispersas ou golfadas. Transições entre os padrões bolhas e golfada e entre bolhas e bolhas dispersas também foram verificadas.

Dessa forma, visando facilitar a identificação dos regimes de escoamento pelas redes neurais desenvolvidas, foi proposta a codificação dos mesmos em forma de tríades de números binários, conforme apresentado na Tabela 1.

Tabela 1. Codificação dos Padrões de Escoamento.

Padrões de Escoamento	Codificação		
Bolhas	1	0	0
Golfada	0	1	0
Bolhas Dispersas	0	0	1
Bolhas - Golfada (Transição)	1	1	0
Bolhas - Bolhas Dispersas (Transição)	1	0	1

3.3 Desenvolvimento das Redes Neurais

3.3.1 Pré-processamento dos Dados

O conjunto de dados foi aleatoriamente dividido em subconjuntos de treinamento, validação e teste. O subconjunto de treinamento foi usado para ajustar os pesos das redes; o subconjunto de validação foi usado para

garantir a capacidade de generalização das redes desenvolvida durante a fase de treinamento e o subconjunto de teste teve por finalidade examinar o desempenho final da rede.

Com a finalidade de demonstrar a robustez das redes neurais desenvolvidas, duas distribuições do conjunto de dados foram adotadas. Na primeira distribuição (Distribuição #1) foram utilizados 60, 30 e 30 séries de dados para treinamento, validação e teste das redes neurais, respectivamente. Da mesma maneira, a segunda distribuição dos dados (Distribuição #2) consistiu em 50, 20 e 50 séries de dados para treinamento, validação e teste. Portanto, espera-se que as duas redes neurais desenvolvidas apresentem resultados satisfatórios para as duas distribuições do conjunto de dados utilizados.

3.3.2 As Redes Neurais Artificiais

Duas RNA's foram desenvolvidas neste trabalho. A primeira rede, denominada de "Padrão", foi projetada com a finalidade de identificar os padrões de escoamento em fluxo vertical ascendente. A segunda rede, chamada de "Gradiente", foi desenvolvida para cálculo do gradiente de pressão associado ao padrão de escoamento identificado na primeira rede.

As redes neurais foram projetadas utilizando o *toolbox Neural Network (NNtool)* do software comercial MatLab®. A topologia Perceptron Multicamada Feedforward foi adotada na construção de ambas as RNA's, devido à sua capacidade de representação de mapas funcionais não-lineares entre as entradas e saídas. As redes neurais foram treinadas utilizando o paradigma *Backpropagation*.

Ambas as redes foram projetadas com três camadas (01 de entrada, 01 intermediária e 01 de saída), sendo que o número de neurônios da camada intermediária foi variado, durante o treinamento, de forma sistemática para cada um dos casos. Os valores resultantes do treinamento de cada uma das redes foram analisados estatisticamente e as melhores configurações de cada uma das RNA's foram selecionadas para a realização das simulações (testes). A seguir é descrito o procedimento de estruturação das redes "Padrão" e "Gradiente".

Na rede neural "Padrão", a função *sigmóide logística*, Equação (1), foi utilizada para ativação dos neurônios tanto na camada intermediária como na de saída.

$$\text{Logsig}(n) = \frac{1}{1 + e^{-n}} \quad (1)$$

e

$$n = \sum w \cdot x \quad (2)$$

onde w é peso da conexão e x é o valor de entrada do neurônio. A camada de entrada foi constituída de cinco neurônios, que representam as vazões de óleo, água e gás e os valores de BSW e RGO. A camada de saída contém três neurônios, correspondentes à tríade de codificação associada ao padrão de escoamento. Por fim, na camada intermediária, o número de neurônios foi variado entre 25 e 125, com o intuito de encontrar a configuração que fornecesse os melhores resultados. A Figura 5 apresenta um esquema da estrutura da rede neural "Padrão".




Figura 5. Esquema da Estrutura da Rede Neural "Padrão"

Os valores de vazões de óleo, água e ar, RGO, BSW, pressão absoluta, temperatura e a tríade referente aos padrões de escoamento foram utilizados como dados de entrada para a rede neural "Gradiente". Portanto a camada de entrada desta rede é composta por dez neurônios, no total. Da mesma forma que na rede "Padrão", o número de neurônios da camada intermediária da rede "Gradiente" foi variado, entre 10 e 50. A camada de saída desta RNA possui apenas um neurônio, que retorna o valor do gradiente de pressão.

As funções de transferência *tangente hiperbólica sigmóide*, Equação (3), e *Linear*, Equação (4), foram utilizadas para ativação das camadas intermediária e de saída da rede "Gradiente", respectivamente.

$$\text{Tansig}(n) = \frac{2}{1 + e^{-2n}} - 1 \quad (3)$$

$$f(x) = x \tag{4}$$

O valor de n é o mesmo fornecido pela Equação (2). A Figura 6 mostra uma representação da estrutura da rede neural “Gradiente”.




Figura 6. Esquema da Estrutura da Rede Neural “Gradiente”

As configurações das redes neurais “Padrão” e “Gradiente” que apresentaram melhores desempenhos, durante a fase de treinamento, para ambas as distribuições adotadas do conjunto de dados, foram selecionadas para a realização dos testes. Nesta etapa, as redes neurais foram simuladas com os dois subconjuntos de testes (contendo 30 e 50 séries de dados) e os resultados obtidos foram comparados com os dados obtidos experimentalmente.

3.4 Cálculo do Gradiente de Pressão Através das Correlações Empíricas

As correlações de Beggs & Brill e de Hagedorn & Brown foram utilizadas para o cálculo dos gradientes de pressão utilizando os dois subconjuntos de teste, com 30 e 50 séries de dados. Os resultados obtidos foram comparados com os valores encontrados experimentalmente e com os obtidos das simulações das redes neurais.

4. RESULTADOS E DISCUSSÃO

4.1 Configurações das Redes Neurais

Durante a fase de treinamento das redes neurais “Padrão” e “Gradiente”, o número de neurônios da camada intermediária, em ambas as redes, foi variado visando à obtenção de configurações que fornecessem os melhores desempenhos.

Configurações da rede neural “Padrão” contendo 25, 50, 75, 100 e 125 neurônios na camada intermediária foram examinadas para as distribuições #1 e #2 do conjunto de dados. A Figura 7 mostra o gráfico comparativo da porcentagem de acertos dos padrões de escoamento durante o treinamento, em cada distribuição, para cada uma das configurações.




Figura 7. Porcentagem de Acertos do Padrão de Escoamento para Cada Configuração da Rede “Padrão”

Pode-se observar dos resultados obtidos na Figura 7, que a configuração da rede neural “Padrão” com 25 neurônios na camada intermediária apresentou a maior porcentagem de acertos do padrão de escoamento para as distribuições #1 (94% de acerto) e #2 (88% de acerto). Esta rede forneceu um erro absoluto máximo, durante o treinamento, de $9,64 \cdot 10^{-7}$ com apenas 132 épocas. Portanto, esta configuração foi a selecionada para a realização dos testes (simulações).

Configurações da rede neural “Gradiente” com 10, 20, 30, 40 e 50 neurônios na camada intermediária foram analisadas. A soma dos quadrados dos erros absolutos (SSE) foi utilizada como critério de performance para o treinamento desta rede.

A seleção da configuração com melhor desempenho considerou duas propriedades estatísticas: o desvio absoluto médio (DAM) dos resultados do treinamento em relação ao valor esperado e o coeficiente de correlação dos mesmos (R^2) com os dados experimentais. A Tabela 2 apresenta os valores obtidos para os desvios absolutos médios e coeficientes de correlação para cada configuração da rede “Gradiente”, nas duas distribuições estudadas durante o treinamento.

Tabela 2. Valores do Desvio Absoluto Médio (DAM) e do Coeficiente de Correlação (R^2) em cada Configuração da Rede Neural “Gradiente”

		Nº de Neurônios na Camada Intermediária				
		10	20	30	40	50
Distribuição #1	Desvio Absoluto Médio (DAM)	662.8	417.9	668.8	466.6	686.4
	Coeficiente de Correlação (R^2)	0.873	0.942	0.898	0.941	0.889
Distribuição #2	Desvio Absoluto Médio (DAM)	576.2	876.4	739	713.5	918.3
	Coeficiente de Correlação (R^2)	0.892	0.748	0.869	0.887	0.784
Valores Médios	Desvio Absoluto Médio (DAM)	619.5	647.2	703.9	590.0	802.4
	Coeficiente de Correlação (R^2)	0.883	0.845	0.884	0.914	0.837

Conforme pode ser observado na Tabela 2, a configuração da rede “Gradiente” possuindo 40 neurônios na camada intermediária foi a que apresentou melhor desempenho, quando analisadas as duas distribuições do conjunto de dados. Isto é evidenciado pelo fato de que esta configuração apresentou maior valor médio do coeficiente de correlação ($R^2 = 0.914$) e menor valor médio do desvio absoluto médio (DAM = 590. Pa/m). Desta forma, a rede neural “Gradiente” contendo 40 neurônios na camada intermediária foi selecionada para a realização dos testes.

4.2 Padrões de Escoamento

A rede neural “Padrão” selecionada (configuração com 25 neurônios na camada intermediária) foi simulada utilizando-se os subconjuntos de teste contendo 30 e 50 séries de dados. Os resultados obtidos são mostrados na Figura 8.

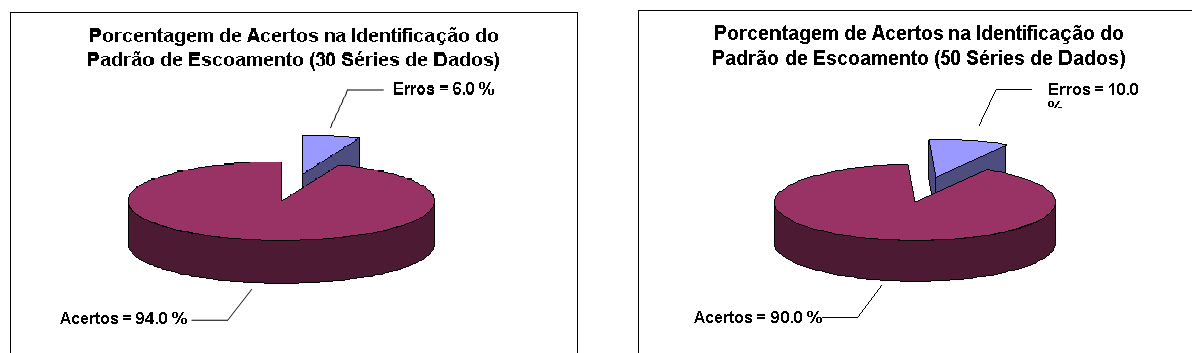


Figura 8. Resultados da Simulação da Rede Neural “Padrão”

Para o subconjunto contendo 30 séries de dados, a rede neural “Padrão” apresentou 94.0 % de acertos na identificação do padrão de escoamento durante a fase de treinamento e 94.0 % de acertos na identificação durante a fase de teste, quando comparada com os regimes de escoamento verificados experimentalmente. Na simulação com 50 séries de dados, o desempenho dessa rede foi de 88.0 % de acertos para a fase de treinamento e 90.0 % de acertos para a fase de teste. A partir destes resultados verificou-se que a rede projetada desenvolveu capacidade de generalização na identificação de padrões, além de mostrar desempenho satisfatório na caracterização dos regimes de escoamento verticais.

4.3 Gradiente de Pressão

A rede neural “Gradiente” foi inicialmente treinada utilizando os dados de padrão de escoamento obtidos experimentalmente, para que não houvesse a propagação do erro resultante da rede “Padrão”. Posteriormente, durante a fase de teste, as redes neurais “Padrão” e “Gradiente” foram interconectadas e simuladas para fornecer os valores dos gradientes de pressão. Desta forma, os resultados obtidos da simulação da rede “Padrão” foram utilizados como valores de entrada para a rede “Gradiente”.

Os dois subconjuntos de dados de testes foram usados na simulação da rede “Gradiente”. Os valores dos gradientes de pressão calculados pela rede neural são mostrados da Figura 9 à Figura 12. Também são apresentados os valores dos gradientes de pressão medidos experimentalmente e estimados através das correlações de Beggs & Brill (Figuras 9 e 11) e de Hagedorn & Brown (Figuras 10 e 12).




Figura 9. Valores do Gradiente de Pressão (Experimental, Beggs & Brill e Rede Neural “Gradiente”)

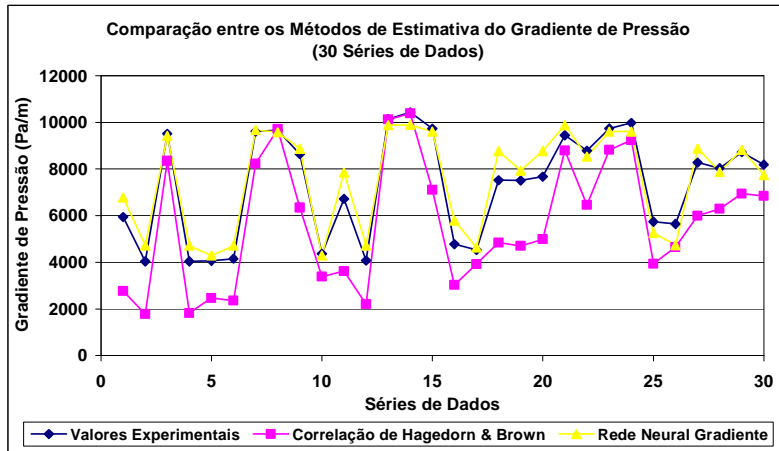


Figura 10. Valores do Gradiente de Pressão (Experimental, Hagedorn & Brown e Rede Neural “Gradiente”)




Figura 11. Valores do Gradiente de Pressão (Experimental, Beggs & Brill e Rede Neural “Gradiente”)




Figura 12. Valores do Gradiente de Pressão (Experimental, Hagedorn & Brown e Rede Neural “Gradiente”)

A análise dos gráficos mostra visualmente o excelente correlacionamento dos resultados fornecidos pela rede “Gradiente” com os obtidos através das medições experimentais, comportamento verificado para os dois subconjuntos de teste examinados. Além disso, quando comparada com as correlações de Beggs & Brill e de Hagedorn & Brown, a rede “Gradiente” apresentou melhor desempenho na previsão dos gradientes de pressão. Isto pode ser verificado através da análise dos desvios absolutos médios (DAM), mostrados na Tabela 3.

Tabela 3. Comparação entre os Métodos de Estimativa do Gradiente de Pressão

		Métodos de Estimativa do Gradiente de Pressão		
		Beggs & Brill	Hagedorn & Brown	Rede Neural "Gradiente"
Subconjunto #1 (30 Séries de Dados)	Desvio Absoluto Médio (DAM)	1530.6	1654.8	466.6
Subconjunto #2 (50 Séries de Dados)	Desvio Absoluto Médio (DAM)	1636.14	1660.4	713.5

Pode-se perceber que a rede neural foi o método que forneceu menores desvios médios em relação aos valores experimentais, fornecendo, assim, as melhores estimativas do gradiente de pressão.

5. CONCLUSÃO

Este trabalho apresentou uma metodologia para o desenvolvimento de duas redes neurais: uma utilizada para identificação dos padrões de escoamento bifásicos e outra para estimativa do gradiente de pressão em escoamento vertical ascendente.

No desenvolvimento das redes neurais, o número de neurônios na camada intermediária foi variado visando à obtenção das configurações que fornecessem melhores desempenhos. Além disso, duas distribuições do conjunto de dados foram utilizadas para verificar a capacidade de aprendizagem e generalização das redes desenvolvidas. Como era esperado, verificou-se que uma maior quantidade de dados de treinamento aumenta a performance da rede. Na rede neural treinada com 60 séries de dados o erro percentual médio foi de 10% em relação aos valores experimentais, enquanto que, para a rede treinada com 50 séries de dados, o erro percentual médio foi de 13%.

Para a rede neural “Padrão”, a configuração que apresentou melhor performance foi obtida com 25 neurônios na camada intermediária e na rede “Gradiente” o melhor desempenho foi obtido com 40 neurônios.

Dois subconjuntos de testes, contendo 30 e 50 séries de dados, foram usados para simulação das redes neurais selecionadas. A rede “Padrão” apresentou excelente capacidade de identificação dos padrões de escoamento, obtendo desempenhos de 94 % e 90 % de acertos para os subconjuntos de 30 e 50 series de dados, respectivamente. Esses resultados foram usados como dados de entrada para a rede “Gradiente”.

A rede neural “Gradiente” foi simulada para estimativa dos gradientes de pressão. Os resultados foram comparados com os valores medidos experimentalmente e calculados através das correlações de Beggs & Brill e Hagedorn & Brown.

A rede neural demonstrou melhor desempenho na estimativa dos gradientes de pressão do que as correlações empíricas, o que pode ser comprovado pelos menores desvios absolutos médios obtidos. Também, quando comparada com os valores experimentais, a rede “Gradiente” apresentou resultados satisfatórios.

6. REFERÊNCIAS

- Aggour, M. A. B., Ayoub, M. A. B., Osman, E. A. A., Artificial neural network model for predicting bottomhole flowing pressure in vertical multiphase flow, In: **SPE Middle East Oil and Gas Show and Conference**, 2005, pp. 1187-1197.
- Alexander, I. and Morton, H. **An Introduction to Neural Computing**. Londres: Chapman & Hall, 1990.
- Bannwart, A. C., Carvalho, C. H. M., Oliveira, A. P., Vieira, F. F., Water-Assisted Flow of Heavy Oil and Gas in a Vertical Pipe, In: **SPE/PS-CIM/CHOA International Thermal Operations and Heavy Oil Symposium**, Calgary, Canadá, 2005.
- Barnea, D., Dukler, A. E., and Taitel, Y., Modeling Flow Pattern Transitions for Steady Upward Gas-Liquid Flow in Vertical Tubes, **AIChE Journal**, vol. 26, pp. 345-354, 1980.
- Beggs, H. D. and Brill, J. P., Study of Two-phase Flow in Inclined Pipes, **Journal of Petroleum Technology**, Maio de 1973, pp. 607-617.
- Bilgesu, H.1., Mohaghegh, S., Ternyik, J., Virtual Measurements in Pipes: Part 2- Liquid Holdup and Flow Pattern Correlations, In: **SPE Eastern Regional Conference and Exhibition**, 1995, Morgantown, USA, pp. 17-21.
- Brown, K. E. and Hagedorn, A. R., Experimental Study of Pressure Gradients Occumng During Continuous Two-Phase Flow in Small-Diameter Vertical Conduits, **Journal of Petroleum Technology**, Abril de 1965, pp. 475-484.
- Crivelaro, O. K. and Selegim, P. J., Identificação de regimes de escoamento bifásico horizontal com auxílio de redes neurais, In: **Proceedings of the XV Congresso Brasileiro de Engenharia Mecânica**, 1999, Águas de Lindóia, Brazil, pp. 22-26.
- Ishii, M., Mi, Y., Tsoukalas, L. H., Flow Regime Identification Methodology With Neural networks and Two-phase Flow Models, **Nuclear Engineering and Design**, vol. 204, pp. 87-100, 2001.
- Rao, B., Multiphase Flow Models Range of Applicability, **Coiled Tubing Engineering Services Publication** vol. 18, Maio de 1998.
- Tackacs, G., Considerations on the Selection of an Optimum Vertical Multiphase Pressure Drop Prediction Model for Oil Wells, In: **SPE Production and Operations Symposium**, Oklahoma, EUA, March 2001.

IDENTIFICATION OF MULTIPHASE FLOW PATTERNS AND DETERMINATION OF PRESSURE DROP WITH THE AID OF NEURAL NETWORKS

Multiphase flows are frequently found in the oil and gas production and transportation. In this kind of flux, the phases may flow on different distributions inside the pipe, named flow patterns. The identification of flow patterns is essential for questions related to the field profits as, for example, to measure the volumetric flow rates of the carried fluids, to determine the pressure gradient throughout the flowlines, the production management and fiscalization. These aspects are critical on offshore production conditions, where extensive distances and high costs are involved. Several models, used to estimate the pressure gradient along the production and transportation flowlines, lead in consideration the flow patterns. These models are empirical correlations and mechaniscist models. The mechaniscist methods aim to develop analytical solutions to describe the flow behavior from the basic concepts of fluid mechanics. On the other hand, the empirical methodology consist in to find correlations from statistical analysis of the experimental data. Despite of advances in the last years, the both methodologies don't provide the precision and accuracy required by the industry yet. This paper presents a non-phenomenological methodology to the flow pattern characterization and the pressure gradient estimative using the artificial neural networks tool. Two artificial neural networks (ANNs) had been developed and tested: the first is focused in the vertical flow patterns classification and the other is specialized in the estimative of the pressure gradient associated with the flow pattern. A set of 120 experimental data series of heavy oil upward flow assisted by water was used to train, validate and test the ANNs. Values fluids flow rates, absolute pressure, temperature, gas-oil rate (GOR) and BSW (basic sediments and water) were used as inputs of ANNs. The results of ANNs simulations were compared with both: empirical correlations results (Beggs & Brill and Hagedorn & Brown) and experimental data. The neural network results showed to be more precise and accurate than that ones obtained from empirical correlations. This was verified based on the lower absolute average error and the higher correlation coefficient values of the set of data.

Neural Networks, Multiphase Flow, Flow Pattern, Pressure drop.

Os autores são os únicos responsáveis pelo conteúdo deste artigo.