

**UFRRJ**  
**INSTITUTO DE TECNOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA**  
**TECNOLOGIA QUÍMICA**

**DISSERTAÇÃO**

**DESENVOLVIMENTO DE UM SENSOR VIRTUAL PARA  
ESTIMATIVA DA VISCOSIDADE APARENTE DE FLUIDOS DE  
PERFURAÇÃO À BASE DE ÁGUA**

**VITOR DIEGO DA SILVA BISPO**

**2014**



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA  
TECNOLOGIA QUÍMICA**

**DESENVOLVIMENTO DE UM SENSOR VIRTUAL PARA  
ESTIMATIVA DA VISCOSIDADE APARENTE DE FLUIDOS DE  
PERFURAÇÃO À BASE DE ÁGUA**

**VITOR DIEGO DA SILVA BISPO**

*Sob a Orientação dos Professores*

**Luiz Augusto da Cruz Meleiro**

*e*

**Luís Américo Calçada**

Dissertação submetida como requisito parcial para a obtenção de **Mestre em Ciências**, no Curso de Pós-Graduação em Engenharia Química, Área de Concentração em Tecnologia Química.

Seropédica, RJ.  
Fevereiro de 2014

622.3381

B622d

T

Bispo, Vitor Diego da Silva, 1989-

Desenvolvimento de um sensor virtual para estimativa da viscosidade aparente de fluidos de perfuração à base de água / Vitor Diego da Silva Bispo. - 2014.

xii, 58 f.: il.

Orientador: Luiz Augusto da Cruz Meleiro.

Dissertação (mestrado) - Universidade Federal Rural do Rio de Janeiro, Curso de Pós-Graduação em Engenharia Química, 2014.

Bibliografia: f. 48-51.

1. Lamas de perfuração - Teses. 2. Lamas de perfuração - Viscosidade - Teses. 3. Redes neurais (Computação) - Teses. 4. Engenharia química - Teses. I. Meleiro, Luiz Augusto da Cruz, 1965-. II. Universidade Federal Rural do Rio de Janeiro. Curso de Pós-Graduação em Engenharia Química. III. Título.

**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO  
INSTITUTO DE TECNOLOGIA  
CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA**

**VITOR DIEGO DA SILVA BISPO**

Dissertação submetida como requisito parcial para a obtenção do grau de **Mestre em Ciências**, no Curso de Pós-Graduação em Engenharia Química, área de Concentração em Tecnologia Química.

DISSERTAÇÃO APROVADA EM ...../...../.....

---

Luiz Augusto da Cruz Meleiro, D.Sc. DEQ/UFRRJ  
(Orientador)

---

Maurício Bezerra de Souza Jr., D.Sc., EQ/UFRRJ

---

Anderson Wilson da Silva Henriques, D.Sc. IFRJ

---

Cláudia Miriam Scheid, D.Sc. DEQ/UFRRJ

## **AGRADECIMENTOS**

Agradeço a meus pais, Natalicia da Silva Bispo e José Reginaldo Bispo, por todo suporte, paciência e carinho dado para o sucesso deste trabalho.

Ao professor e orientador, Luiz Augusto da Cruz Meleiro, pela oportunidade de desenvolver este trabalho, pela dedicação, estímulo e excelente orientação.

Aos professores Luís Américo Calçada e Cláudia Míriam Scheid, pelas contribuições ao longo de todo trabalho.

À minha namorada, Paula do Nascimento Goulart, pelo companheirismo, atenção e compreensão nos momentos mais difíceis.

Aos colegas do Laboratório de Escoamento de Fluidos, Luis, Euan, Sérgio, Deividson, Núbia, Andréia e Olívio.

À Universidade Federal Rural do Rio de Janeiro, pelo conhecimento adquirido ao longo destes últimos sete anos.

## RESUMO

**BISPO, Vitor Diego da Silva. Desenvolvimento de um sensor virtual para estimativa da viscosidade aparente de fluidos de perfuração à base de água.** 2014. 75p Dissertação (Mestrado em Engenharia Química, Tecnologia Química). Instituto de Tecnologia, Departamento de Engenharia Química, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2014.

A exploração de petróleo em campos marítimos localizados em águas profundas e ultraprofundas vem sendo um dos desafios na produção de petróleo. Para viabilizar a exploração, inúmeras pesquisas estão agregando tecnologia aos fluidos de perfuração de modo que atendam às necessidades exigidas em campo. Dessa forma, a compreensão e o monitoramento das propriedades do fluido são de vital importância para a exploração e produção de petróleo. O objetivo deste trabalho foi desenvolver um sensor virtual para estimar uma das propriedades reológicas de fluidos de perfuração à base de água, a viscosidade aparente. Este sensor foi baseado no modelo de redes neuronais artificiais com estrutura do tipo perceptron multi-camadas (Multi-Layer Perceptron – MLP). A etapa inicial do trabalho consistiu em averiguar a influência dos aditivos na viscosidade aparente do fluido de perfuração. Para isso, foi realizado um planejamento fatorial completo a três níveis e com três réplicas no ponto central, onde os aditivos empregados foram goma xantana, bentonita e barita. Uma vez que a temperatura do fluido de perfuração que retorna do poço para a superfície é diferente daquela injetada na coluna de perfuração, esta variável também foi considerada no planejamento a fim de avaliar sua influência na viscosidade do fluido de perfuração. A partir deste planejamento, foram formulados 84 fluidos de perfuração à base água, nos quais a viscosidade aparente foi determinada em um viscosímetro (Fann 35A) a 300 rpm e em diferentes temperaturas. A partir da análise estatística dos resultados, verificou-se que todas as variáveis consideradas influenciavam a viscosidade aparente e, através do teste de análise de variância (ANOVA), foi possível obter um modelo de regressão que leva em consideração os efeitos cruzados de cada componente sobre a variável de resposta. A rede neuronal utilizada neste trabalho é do tipo MLP, contendo funções de ativação hiperbólica nos neurônios da camada intermediária e linear no neurônio da camada de saída. Para o treinamento e validação da rede neuronal foram utilizados 750 e 267 dados experimentais, respectivamente, que foram obtidos variando-se a temperatura entre 20°C e 60°C em cada um dos 84 fluidos formulados na etapa de planejamento de experimentos. Foram realizadas diversas simulações durante a etapa de aprendizagem da rede neuronal variando-se o número de neurônios da camada intermediária com objetivo de obter a melhor arquitetura. Verificou-se que a rede com 6 neurônios na camada escondida apresentou a melhor capacidade de generalização e, portanto, as melhores previsões. A capacidade de previsão da rede neuronal selecionada foi comparada com a do modelo de regressão estatístico através do erro quadrático médio e do teste de inspeção visual. Verificou-se que o desempenho do modelo neuronal foi superior, tendo apresentado erros de previsão significativamente menores.

**Palavras chave:** redes neuronais, temperatura, viscosidade aparente.

## ABSTRACT

**BISPO, Vitor Diego da Silva. Development of a soft sensor to estimate the apparent viscosity of water based drilling fluids.** 2014. 75p Dissertation (Master in Chemical Engineering, Chemical Technology). Instituto de Tecnologia, Departamento de Engenharia Química, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2014.

Oil exploration in offshore fields located in deep and ultra deep waters have been one of the challenges in oil production. To facilitate the operation, numerous studies are adding technology to the drilling fluid in order to meet the needs required during drilling of the geological formation. Thus, understanding and monitoring of the fluid properties are of vital importance for the exploration and production of oil. The objective of this work was to develop a soft sensor to estimate a rheological property of water based drilling fluids: the apparent viscosity. This sensor was based on the artificial neural network model with structure of multi-layer perceptron type. The initial stage of this work consisted in investigating the influence the additives in apparent viscosity in drilling fluid. For this purpose, full factorial design at three levels and with three replicates at the center point was carried, where the additives used were xantan gum, bentonite and barite. Once the temperature of the drilling fluid returning from the well to the surface is different from that injected into the drill string this variable was also considered in the planning in order to assess their influence on viscosity. Through this planning 84 water based drilling fluids were formulated; in which the apparent viscosity was determined in a viscometer (Fann 35A) at 300 RPM speed and at different temperatures. From the statistical analysis of results, it was found that all the variables considered had influence on apparent viscosity, and through the ANOVA test, analysis of variance, it was possible to obtain a regression model that takes into account the cross effects of each component in the response variable. The neural network used in this work is the type MLP, containing hyperbolic activation functions in neurons in the hidden layer and a linear output neuron. A total of it 750 and 267 experimental data were used for training and validating the neural network respectively, which were obtained by varying the temperature between 20°C and 60°C in each of the formulated 84 fluids in the planning stage of experiments. Several simulations were performed during the learning stage of the neural network by varying the number of neurons in the hidden layer in order to obtain the best architecture. It was found that the network with 6 neurons in the hidden layer had the best generalization ability and, therefore, the best predictions. The predictive ability of the selected neural network was compared to the statistical regression model using the mean square error and visual inspection test. It was found that the performance of the neural model was higher, presenting significantly lower prediction errors.

**Keywords:** neural networks, temperature, apparent viscosity.

## LISTA DE QUADROS

<b>Quadro 1.</b> Especificações do viscosímetro FANN 35A.....	21
<b>Quadro 2.</b> Teste de hipótese de Kolmogorov-Smirnov.....	25
<b>Quadro 3.</b> Teste de hipótese de normalidade com correção de Lilliefors.....	26
<b>Quadro 4.</b> Teste de hipótese do teste de Wilcoxon do posto sinalizado. ....	27
<b>Quadro 5.</b> Resultados obtidos para os fluidos contendo goma xantana e bentonita fixados no nível central. ....	46

## LISTA DE TABELAS

<b>Tabela 1.</b> Funções desempenhadas por aditivos na perfuração. ....	6
<b>Tabela 2.</b> Diferentes equações para predição da viscosidade efetiva. ....	13
<b>Tabela 3.</b> Componentes dos fluidos de perfuração à base de água. ....	18
<b>Tabela 4.</b> Níveis utilizados nos planejamentos experimentais. ....	19
<b>Tabela 5.</b> Planejamento inicial contendo 30 experimentos. ....	19
<b>Tabela 6.</b> Quadro da análise de variância. ....	25
<b>Tabela 7.</b> Malha experimental com apenas variação da concentração de sólidos. ....	31
<b>Tabela 8.</b> Parâmetros do modelo de Herschell-Buckley. ....	33
<b>Tabela 9.</b> Resultados do teste de análise de variância. ....	33
<b>Tabela 10.</b> Coeficientes de regressão para o modelo do planejamento preliminar. ....	34
<b>Tabela 11.</b> Coeficientes de regressão do modelo estatístico. ....	36
<b>Tabela 12.</b> Fração volumétrica de sólidos e viscosidade aparente dos fluidos a 40 °C. ....	42
<b>Tabela 13.</b> Parâmetros do modelo de Herschell-Buckley. ....	54
<b>Tabela 14.</b> Ângulo de deflexão em diferentes velocidades de rotação. ....	55
<b>Tabela 15.</b> Dados obtidos no planejamento com a temperatura controlada (continua). ....	58

## LISTA DE FIGURAS

<b>Figura 1.</b> Representação esquemática da circulação dos fluidos.....	1
<b>Figura 2.</b> Classificação dos fluidos de acordo com o comportamento reológico.....	7
<b>Figura 3.</b> Curva de fluxo de um fluido de Bingham.....	8
<b>Figura 4.</b> a) Curvas de fluxo e b) curvas de viscosidades de fluidos Newtonianos e independentes do tempo. ....	9
<b>Figura 5.</b> a) Viscosímetro FANN 50C e b) viscosímetro FANN 35A. ....	10
<b>Figura 6.</b> Representação esquemática de um neurônio. ....	15
<b>Figura 7.</b> <i>Perceptron</i> multicamadas do tipo <i>feedforward</i> . ....	15
<b>Figura 8.</b> a) Agitador Hamilton Beach <sup>®</sup> , b) Banho térmico, c) copo encamisado e d) viscosímetro Fann 35A. ....	18
<b>Figura 9.</b> Ilustração gráfica do conceito de intervalo de confiança.....	23
<b>Figura 10.</b> Ilustração do ajuste do teste Kolmogorov-Smirnov.....	26
<b>Figura 11.</b> Exemplo de rede <i>feedforward</i> de camadas múltiplas. ....	28
<b>Figura 12.</b> Fluxo de processamento do algoritmo <i>backpropagation</i> . ....	29
<b>Figura 13.</b> Curva de fluxo dos fluidos de perfuração. ....	32
<b>Figura 14.</b> Superfície de contorno para o nível mínimo de bentonita. ....	34
<b>Figura 15.</b> Gráfico das médias marginais. ....	35
<b>Figura 16.</b> Parâmetros significativos do modelo de regressão. ....	36
<b>Figura 17.</b> Ajuste do modelo estatístico aos dados experimentais. ....	37
<b>Figura 18.</b> Ajuste dos dados pelo gráfico de probabilidade normal. ....	38
<b>Figura 19.</b> Gráfico de caixa para a mediana. ....	39
<b>Figura 20.</b> Erro quadrático médio pelo número de neurônios. ....	40
<b>Figura 21.</b> Distribuição dos dados de treinamento e validação. ....	40
<b>Figura 22.</b> Predição dos dados de validação com a rede com 6 neurônios. ....	41
<b>Figura 23.</b> Erros relativos da rede neuronal.....	41
<b>Figura 24.</b> Ajuste para a determinação da fração volumétrica máxima de sólidos. ....	42
<b>Figura 25.</b> Ajuste para a determinação dos parâmetros do modelo de Liu. ....	43
<b>Figura 26.</b> Predição da viscosidade aparente pelo modelo de Liu. ....	43
<b>Figura 27.</b> Comparação entre os modelos estatístico e neuronal.....	44
<b>Figura 28.</b> Dados experimentais versus predições fornecidas pelos modelos testados.....	45
<b>Figura 29.</b> Erros relativos dos modelos. ....	45
<b>Figura 30.</b> Curvas de fluxo (a).....	56
<b>Figura 31.</b> Curvas de fluxo (b). ....	56
<b>Figura 32.</b> Curvas de fluxo (c).....	57

## LISTA DE ABREVIACOES E SIMBOLOS

$\theta$	ngulo de deformao (graus);
$R^2$	coeficiente de determinao;
$E_{QM}$	erro quadrtico mdio (cP <sup>2</sup> );
$E^p$	erro quadrtico para o padro $p$ (cP);
$\phi_p$	frao volumtrica de slidos (admin);
$\phi_m$	frao volumtrica mxima de slidos (admin.);
$n$	ndice de comportamento (adim.);
$K$	ndice de consistncia (dina.cm <sup>-2</sup> .s <sup>n</sup> );
$\tau_0$	limite de escoamento (dina/cm <sup>2</sup> );
$w_{ij}$	peso sinptico conectando a sada do neurnio $i$  entrada do neurnio $j$ ;
$d_i^p$	reposta desejada para o neurnio $i$ para o padro $p$ ;
$y_i^p$	signal funcional que aparece na sada do neurnio $i$ , na iterao $p$ ;
$\varphi_i$	sinais de entrada da rede;
$\dot{\gamma}$	taxa de deformao (s <sup>-1</sup> );
$\tau$	tenso de cisalhamento (dina/cm <sup>2</sup> );
$\Omega$	velocidade de rotao (rpm);
$\mu_{ap}$	viscosidade aparente (cP);
$\mu_0$	viscosidade do meio dispersgente (cP);
$\mu_{eff}$	viscosidade efetiva (cP);
$\mu_p$	viscosidade plstica (cP);

## SUMÁRIO

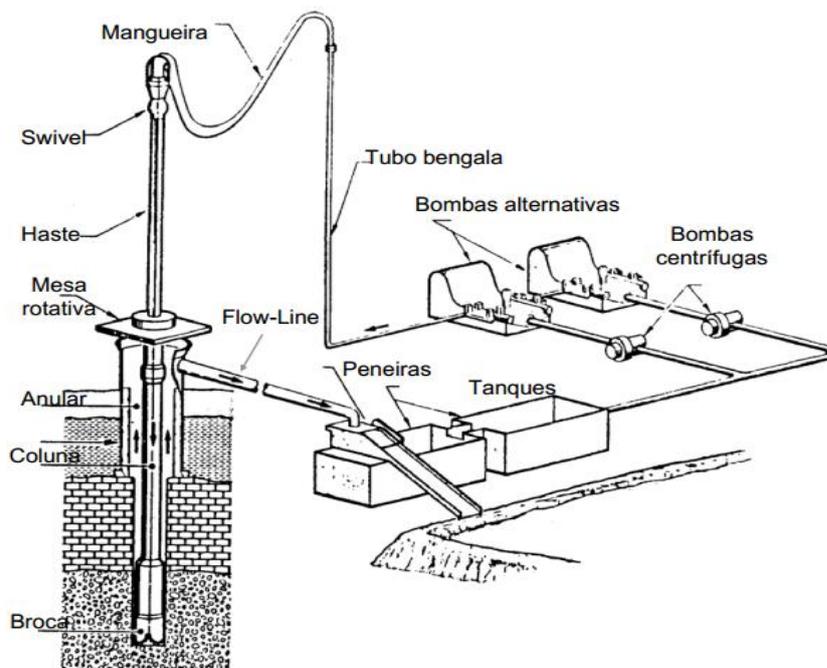
<b>1. INTRODUÇÃO</b>	<b>1</b>
<b>2. REVISÃO</b>	<b>3</b>
2.1 Fluidos de Perfuração	3
2.1.1 Fluido à base de água	3
2.1.2 Fluido à base de óleo	4
2.1.3 Aditivos	4
2.2 Fundamentos da Reologia	6
2.2.1 Modelo de Bingham	8
2.2.2 Modelo da potência de Ostwald e de Waelle	8
2.2.3 Modelo de Herschel-Buckley	10
2.2.4 Métodos de determinação experimental	10
2.3 Modelos Empíricos	11
2.3.1 Equações matemáticas	11
2.3.2 Modelos estatísticos	12
2.4 Redes Neurais	14
2.4.1 Modelo matemático do <i>perceptron</i> multicamadas	15
2.4.2 Algoritmo de treinamento das MLP	16
2.4.3 Aplicações das redes MLP	16
<b>3. MATERIAIS E MÉTODOS</b>	<b>18</b>
3.1 Materiais e Equipamentos	18
3.2 Planejamento Experimental	19
3.2.1 Preparação dos fluidos de perfuração	20
3.2.2 Determinação da viscosidade aparente	20
3.3 Métodos Estatísticos	22
3.3.1 Princípios básicos	22
3.3.2 Modelo de regressão estatístico	23
3.3.2.1 Análise de variância	24
3.3.3 Teste de normalidade	25
3.3.4 Teste de Wilcoxon do posto sinalizado	27
3.4 Redes Neurais	27
3.4.1 Coleta e separação dos dados	27
3.4.2 Configuração da rede	28
3.4.3 Treinamento da rede neuronal	29
3.5 Modelo Empírico de Liu	30

<b>4. RESULTADOS E DISCUSSÕES</b>	<b>32</b>
4.1 Caracterização Reológica	32
4.2 Influência dos Aditivos na Viscosidade Aparente	33
4.3 Identificação do Modelo Estatístico	35
4.4 Validação da Metodologia Experimental	37
4.5 Identificação do Modelo Neuronal	39
4.6 Identificação do Modelo de Liu	41
4.7 Comparação dos Modelos	44
<b>5. CONCLUSÕES</b>	<b>48</b>
<b>6. BIBLIOGRAFIA</b>	<b>49</b>
<b>7. ANEXOS</b>	<b>53</b>
A- Dados obtidos no planejamento preliminar	53
B- Dados obtidos no planejamento com a temperatura	53

# 1. INTRODUÇÃO

A perfuração de poços de petróleo caracteriza-se por ser uma atividade de grande complexidade, risco e, sobretudo, elevado custo financeiro. Com a expansão das fronteiras exploratórias e de produção, cada vez mais poços em águas profundas e ultraprofundas estão sendo perfurados. O desafio de perfurar nessas regiões tem aumentado o investimento em tecnologia a fim de reduzir custos, garantir maior segurança operacional e minimizar possíveis danos ambientais (CHIEZA, 2011).

A perfuração ocorre através de um conjunto de equipamentos que constituem a sonda de perfuração. O corte da formação geológica acontece pela ação rotativa de uma broca com o auxílio de fluidos pesados (fluidos de perfuração ou lamas) que são continuamente bombeados para o interior do poço de perfuração. A Figura 1 ilustra o caminho percorrido pelos fluidos de perfuração nas sondas de perfuração (COUTO, 2012).



Fonte: MANSANO, 2004.

**Figura 1.** Representação esquemática da circulação dos fluidos.

Os fluidos de perfuração são utilizados para manter a integridade mecânica da formação e auxiliar no carreamento dos sólidos removidos pela broca durante a perfuração, evitando com isso o desmoronamento do poço e o aprisionamento da broca. Devido a essas funções, há um rígido controle dos fluidos de perfuração com o objetivo de se evitar problemas que atrasem a operação e aumentem o custo do projeto.

O monitoramento dos fluidos é realizado, em grande parte, através de um conjunto de sensores e transmissores de dados localizados nas superfícies das sondas de perfuração e todas

as informações obtidas nesses sensores são armazenadas no sistema conhecido como *mud-logging*. Nesse serviço são monitoradas variáveis como: vazão de saída de fluido do poço; peso da lama na entrada e saída do poço; temperatura e o nível dos fluidos armazenados nos tanques de lama. A partir desse sistema de monitoramento, os dados são analisados por especialistas que monitoram e interpretam os dados a fim de antecipar e remediar potenciais problemas operacionais (CHIEZA, 2011).

Apesar de existir uma série de sensores, nem todas as variáveis são efetivamente medidas como, por exemplo, a viscosidade dos fluidos de perfuração. A medida dessa variável ocorre através de ensaios em laboratórios pela coleta de pequenas amostras de fluidos nos tanques de armazenamento. Somente a partir dos valores obtidos, são empregados aditivos químicos e físicos para corrigir as propriedades reológicas dos fluidos para valores exigidos naquela etapa de perfuração (TAVARES, 2006).

Dentro deste contexto, este trabalho foi realizado com o objetivo de desenvolver um sensor virtual baseado no modelo de rede neuronal MLP (*perceptron* de multicamadas) para determinar a viscosidade aparente de fluidos à base de água contendo goma xantana, barita e bentonita. Para isso, realizou-se um planejamento fatorial completo para avaliar a influência das variáveis, concentração dos aditivos e temperatura, na viscosidade aparente. Além disso, foi utilizada uma metodologia experimental para gerar dados suficientes para que a rede neuronal fosse capaz de extrair as características do processo estudado.

Esta dissertação de mestrado apresenta no primeiro capítulo uma pequena introdução sobre os fluidos de perfuração e seu monitoramento nas sondas de perfuração. No capítulo 2 há uma revisão de literatura sobre os tipos de fluidos de perfuração, modelos matemáticos empregados na estimação da viscosidade, além de uma breve descrição do modelo neuronal. No capítulo 3 são apresentados os materiais e equipamentos utilizados na formulação e determinação da viscosidade dos fluidos, além da metodologia experimental utilizada na coleta de dados para a identificação do modelo neuronal. Apresentam-se, no capítulo 4, as discussões dos resultados para os modelos utilizados e no capítulo 5 são relatadas as conclusões sobre os resultados obtidos na dissertação.

## 2. REVISÃO

### 2.1 Fluidos de Perfuração

Os fluidos de perfuração são primordiais nas atividades petrolíferas e podem ser caracterizados em duas grandes categorias: líquidos e gases. Segundo Bourgoyne Jr. *et al.* (1986), os fluidos líquidos são normalmente chamados em campo de “lama” de perfuração (ou *drilling mud*) em alusão ao fluido utilizado no poço de *Spindletop*, em 1901, primeiro poço a utilizar a técnica de perfuração rotativa.

Thomas (2004) considera que os fluidos de perfuração são misturas complexas de sólidos, líquidos, produtos químicos, e, por vezes, até gases. Assim, os fluidos de perfuração são classificados em categorias de acordo com o principal componente da fase contínua, podendo ser a água, óleo ou gás. Segundo Pereira (2006), dentre essa classificação os fluidos mais utilizados são os fluidos denominados fluidos base óleo (OBF, *oil based fluid*), sintéticos (SBF, *synthetic based fluid*) e fluidos à base de água (WBF, *water based fluid*).

Segundo Bourgoyne Jr. *et al.* (1986), a escolha do tipo de fluido durante a perfuração depende das informações obtidas em campo, como o tipo de formação geológica que está sendo perfurada, a faixa de temperatura a que o fluido será submetido, a qualidade da água disponível e os aspectos ecológicos e ambientais envolvidos. A partir dessas considerações, os fluidos devem exercer funções semelhantes, porém, com desempenhos diferenciados.

Dentre as inúmeras funções dos fluidos, destacam-se: a capacidade de transportar o sólido gerado no fundo do poço e permitir a sua separação na superfície; refrigerar e lubrificar a broca e a coluna de perfuração; manter a estabilidade do poço através do controle das pressões das camadas perfuradas; manter os cascalhos em suspensão durante as paradas na circulação (CAENN e CHILLINGAR, 1996).

#### 2.1.1 Fluido à base de água

A maioria dos fluidos de perfuração utilizados na perfuração apresentam como fase contínua a água. Segundo Couto (2012), o primeiro poço a ser perfurado com fluido à base de água foi o de *Spindletop* no Texas, em 1901. Inicialmente, somente a água foi utilizada como fluido de perfuração, porém, os resultados não eram satisfatórios por haver constantes desmoronamentos do poço perfurado. Durante a perfuração, os sondadores perceberam que a argila da formação quando misturada a água fornecia um fluido capaz de suportar as pressões hidrostáticas da formação rochosa e, com isso, manter a integridade do poço.

A partir disso, diferentes materiais foram pesquisados para aprimorar o desempenho dos fluidos de perfuração e adequá-lo a situações cada vez mais específicas. Segundo Serra (2003), grande parte do desenvolvimento das lamas de perfuração à base de água foi impulsionada principalmente para satisfazer as condições de estabilidade e pressão do poço.

Devido a dificuldades encontradas durante a perfuração com a evolução de novas tecnologias, como a perfuração direcional ou em águas profundas, os fluidos à base de água vêm recebendo grandes investimentos em pesquisa para acompanhar os novos desafios. A utilização dos fluidos à base de água sem o devido tratamento pode tornar a perfuração lenta e custosa (SCHAFFEL, 2002).

### 2.1.2 Fluido à base de óleo

Os fluidos de perfuração base não aquosa são frequentemente divididos em fluidos a base óleo e base sintético. Os fluidos à base de óleo se desenvolveram paralelamente aos fluidos à base de água e buscavam, principalmente, superar alguns problemas operacionais atribuídos aos fluidos aquosos.

Do ponto de vista químico, os fluidos à base de óleo são constituídos de uma fase líquida predominante composta de hidrocarbonetos. O óleo inicialmente empregado como base para os fluidos de base oleosa foi o diesel, devido à sua boa disponibilidade e baixo custo. Ao longo dos anos, os fluidos não aquosos passaram a ter como base as parafinas e o óleo mineral (SCHAFFEL, 2002; PEREIRA, 2010).

Segundo Schaffel (2002), os fluidos à base de óleo foram introduzidos no mercado na década de 40 e ganharam destaque mesmo apresentando custos mais elevados que os fluidos de base aquosa. Bourgoyne Jr. *et al.* (1986) destacaram que as lamas à base de óleo são frequentemente empregadas em perfurações profundas envolvendo altas temperaturas; em domos salinos (perfuração no sal); e em perfurações direcionais, para prevenir o travamento da coluna nas paredes do poço.

Pereira (2006) apresentou em seu trabalho algumas das limitações desses fluidos, enfatizando as restrições como a alta toxicidade e o elevado custo associado às necessidades especiais de manuseio. A toxicidade é considerada a desvantagem mais agravante das lamas à base de óleo, principalmente por gerar cascalhos que quando descartados no mar tendem a se aglomerar em “placas” que acumulam no fundo do mar.

Para contornar as restrições ambientais impostas aos fluidos à base de óleo e às limitações de desempenho dos fluidos aquosos foram desenvolvidos os fluidos sintéticos. O termo sintético refere-se aos fluidos cuja fase contínua é composta por um ou mais fluidos produzidos por uma reação química específica.

Segundo Schaffel (2002), os fluidos sintéticos foram divididos em duas gerações: a primeira, composta por ésteres, éteres, poliolefinas e acetatos, e a segunda, composta pelos alquilbenzenos lineares, linear alfa olefinas, olefinas internas e parafinas lineares.

### 2.1.3 Aditivos

A crescente preocupação com os danos ao meio ambiente e os custos envolvidos no descarte dos cascalhos contaminados com óleo têm levado à procura de aditivos que confirmam aos fluidos base água desempenho similares aos fluidos à base de óleo. Dessa forma, os fluidos aquosos devem não somente desempenhar adequadamente as funções dos fluidos de base óleo, mas também serem biodegradáveis e apresentarem baixa bioacumulação.

Os aditivos são empregados para controlar as propriedades físicas ou químicas dos fluidos de perfuração. As propriedades físicas mais importantes e frequentemente medidas nas sondas são a densidade, os parâmetros reológicos, as forças géis (inicial e final), os parâmetros de filtração e o teor de sólidos. As propriedades químicas determinadas com maior frequência nos laboratórios das sondas são o pH e alcalinidade (THOMAS, 2004).

Segundo Caenn e Chillingar (1996), os testes nos fluidos de perfuração são baseados em quatro categorias gerais: peso, viscosidade, perda de filtrado e reatividade dos folhelhos (rochas sedimentares argilosas). Para o controle dessas propriedades, os aditivos mais empregados são os polímeros, adensantes, sais e argilas (PEREIRA, 2006). Estes autores

também destacam os polímeros mais usados e as principais alterações nos fluidos de perfuração. Os autores classificam os polímeros em polímeros naturais, naturais modificados e sintéticos.

Os polímeros naturais nos fluidos de perfuração são as chamadas gomas, os biopolímeros e os à base de amido. Apresentam como característica básica a capacidade de absorver grandes quantidades de água e, por isso, são utilizados como agente de controle de perdas de fluido para a formação rochosa. Além disso, são utilizados como agentes de controle reológico, ou seja, controlam a viscosidade do fluido de modo que os cascalhos permaneçam em suspensão em casos de paradas de bombeamento. Os polímeros comerciais mais empregados são a goma xantana, goma guar e o amido.

Os polímeros modificados apresentam um encadeamento linear baseada na molécula base de celulose ou de amido. Os mais utilizados são o CMC (carboximetilcelulose), HEC (hidroxietilcelulose) e o CMS (carboximetilamido). Como são polímeros baseados em uma estrutura molecular mais simples, a função que exercem nos fluidos de perfuração é dependente do grau de substituição e do peso molecular. De acordo com Caenn e Chillingar (1996), esses polímeros são classificados como aditivos que promovem uma alta ou baixa viscosidade nos fluidos de perfuração.

O grupo que constitui os polímeros sintéticos é formado pelos poliacrilatos, polímeros produzidos através do petróleo e pelas poliacrilamidas, que são copolímeros de várias proporções de ácido acrílico e acrilamida. Esses polímeros atuam como floculantes e controladores de parâmetros reológicos (viscosidade aparente, limite de escoamento e força géis).

Os aditivos empregados para aumentar o peso específico dos fluidos de perfuração são chamados de adensantes e o principal agente densificante utilizado é a barita. Esse material é composto de sulfato de bário e apresenta massa específica em torno de  $4,2 \text{ g/cm}^3$ . O controle da densidade é essencial para manter a estabilidade dos poços de perfuração, que ocorre através do equilíbrio das pressões hidrostáticas do fluido e da formação rochosa nas camadas perfuradas. Materiais como a hematita ( $\text{Fe}_2\text{O}_3$ ) e o ilmenita ( $\text{FeO.TiO}_2$ ) também atuam no controle da densidade (BOURGOYNE JR *et al.*, 1986).

As argilas têm sido utilizadas há muitos anos como agentes dispersos na composição dos fluidos de perfuração. A principal argila utilizada na indústria petrolífera é a bentonita, material que se enquadra no grupo das esmectitas, possuindo como característica principal o alto poder de inchamento e capacidade de troca iônica. Esse comportamento nas lamelas de perfuração permite o controle da viscosidade e evita a invasão de fluidos para a formação rochosa (CAENN e CHILLINGAR, 1996; MELO, 2008).

Os sais também são aditivos comuns na indústria de petróleo. Os sais agem como inibidores das formações ativas (formações sujeitas a interações físico-química) reduzindo o escoamento hidráulico para a formação rochosa. Isso ocorre principalmente por estimular o escoamento de água da formação argilosa para o fluido de perfuração. Os sais mais comumente utilizados em fluidos de perfuração à base de água são os cloretos de sódio, de potássio e de cálcio (RABE, 2003; SHIROMA, 2012).

Há diversos aditivos disponíveis no mercado para atender necessidades específicas da perfuração de poços, como mostrado na Tabela 1. Neste trabalho, utilizou-se a goma xantana, a bentonita e a barita na formulação dos fluidos à base de água.

**Tabela 1.** Funções desempenhadas por aditivos na perfuração.

<b>Função</b>	<b>Ação</b>	<b>Tipo de Aditivo</b>
<b>Surfactantes</b>	Reduzir a tensão interfacial .	Emulsificantes, floculantes e umidificantes.
<b>Floculantes</b>	Agrupamento de partículas coloidais	Salmouras, cal hidratada e polímeros a base de acrilamida
<b>Dispersantes</b>	Reduzir a atração entre as partículas de argila.	Vários polifosfatos, lignita, materiais lignosulfonatos.
<b>Lubrificantes</b>	Reduzir o coeficiente de fricção.	Óleos, líquidos sintéticos, grafite e glicerina.
<b>Inibidores de inchamento de folhelhos</b>	Prevenir o alargamento excessivo ou desabamento do poço.	Fontes de cálcio solúvel e potássio.
<b>Estabilizadores de temperatura</b>	Aumentar a estabilidade reológica e de filtração de fluidos de perfuração expostos a altas temperaturas.	Polímeros acrílicos, polímeros sulfonados e copolímeros.
<b>Viscosificantes</b>	Aumentar a viscosidade para melhorar a limpeza do poço	Bentonita, CMC e argilas
<b>Redutores de filtrado</b>	Diminuir a perda do fluido para a formação geológica.	Argilas de bentonita e lignita,
<b>Controle de pH</b>	Controlar o grau de acidez ou alcalinidade do fluido.	Soda cáustica e bicarbonato de sódio.
<b>Bactericida</b>	Prevenir a degradação de aditivos orgânicos	-
<b>Inibidores de corrosão</b>	Controlar o pH para impedir a corrosão da broca.	Produtos químicos a base de amina e fosfato.
<b>Espessantes</b>	Controlar as pressões de formação.	Barita, óxidos de ferro e carbonatos de cálcio.
<b>Desobstrução do tubo de perfuração</b>	Reduzir a fricção e aumentar a lubrificação em áreas onde o tubo de perfuração está sujeito a emperrar	Detergentes, sabões, óleos, surfactantes.

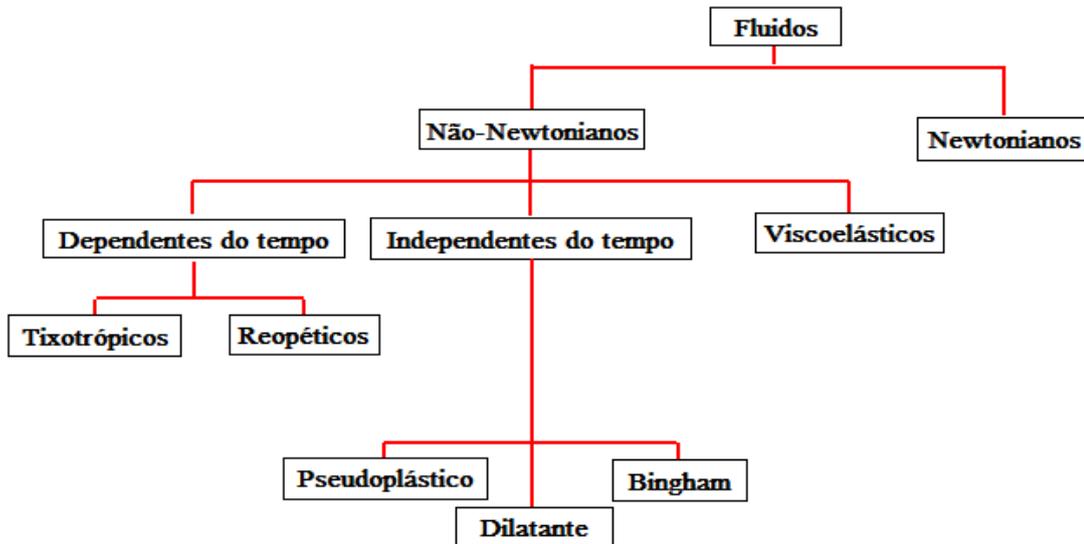
Fonte: Adaptado de SERRA, 2003.

## 2.2 Fundamentos da Reologia

A reologia é a ciência que permite estudar como a matéria se deforma ou escoar quando submetida a esforços originados por forças externas. O escoamento de um fluido, líquido ou gás, é caracterizado por leis que descrevem a variação contínua da taxa de deformação em função das forças aplicadas (MACHADO, 2002).

Isaac Newton, em 1687, foi o primeiro autor a estabelecer o comportamento de um fluido em função do gradiente de velocidade (ou taxa de deformação) e da força aplicada. Newton observou que a relação entre essas variáveis era proporcional à resistência ao fluxo, definindo essa constante como coeficiente de viscosidade (BARNES; HUTTON; WALTERS, 1989).

A partir do estudo de Newton, inúmeros fluidos foram avaliados e observou-se que nem todos possuíam a relação linear entre a taxa de deformação e a tensão. Desse modo, esses fluidos foram classificados como não newtonianos e a constante de proporcionalidade passou a ser definida como viscosidade aparente por ser dependente da tensão aplicada. Os fluidos não newtonianos ainda foram divididos em viscoelásticos, dependentes e independentes do tempo, conforme ilustrado na Figura 2 (FOX; MCDONALD; PRITCHARD, 2010).



**Figura 2.** Classificação dos fluidos de acordo com o comportamento reológico.

Fox, Mcdonald e Pritchard (2010) descrevem os viscoelásticos como fluidos que, após serem deformados, retornam parcialmente a sua forma original quando cessada a tensão aplicada. Paraíso (2011) acrescenta que nestes fluidos, uma parte da energia recebida na sua deformação é armazenada, como sólidos elásticos, e a outra parte dissipada, como nos fluidos puramente viscosos.

Segundo Schramm (2006), os fluidos dependentes do tempo apresentam como característica a mudança da viscosidade aparente com o tempo de aplicação da taxa de cisalhamento e são subdivididos em reopéticos e tixotrópicos. Os fluidos tixotrópicos apresentam diminuição da viscosidade aparente com o tempo, enquanto os reopéticos aumentam sua viscosidade com o tempo de atuação de uma taxa de cisalhamento constante.

De acordo com Machado (2002), os fluidos de perfuração são exemplos típicos de fluidos tixotrópicos. O arranjo molecular desses fluidos formam ligações que criam uma estrutura tridimensional em rede, frequentemente, chamada de “gel”. Quando essa reticulação é rompida, a viscosidade cai com o tempo de cisalhamento até que se atinja o nível mais baixo possível para uma determinada taxa de cisalhamento. Esse nível mínimo de viscosidade é descrito como o estado “sol” da dispersão.

O efeito tixotrópico dos fluidos é de extrema importância na operação de perfuração, pois, evita a sedimentação dos detritos gerados quando é necessário interromper a circulação do fluido (AMORIM, 2003). Os parâmetros reológicos que indicam o grau de gelificação e que são frequentemente medidos nas sondas são as forças géis inicial e final. A força gel inicial mede a resistência inicial para colocar o fluido em escoamento enquanto a força gel final mede a resistência do fluido para reiniciar o escoamento quando este fica certo tempo em repouso (DARLEY e GRAY, 1988 apud SHIROMA, 2012).

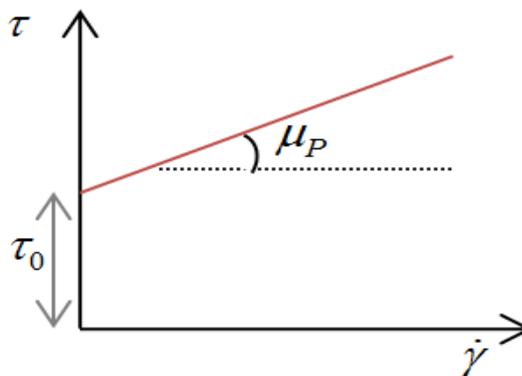
No campo da perfuração, além das forças géis, as propriedades como viscosidade aparente, viscosidade plástica e limite de escoamento estão vinculadas ao desempenho do fluido. São esses parâmetros reológicos que associados a modelos matemáticos permitem descrever o comportamento de fluidos não newtonianos e independentes do tempo. Dentre os modelos matemáticos existentes, os mais aplicados para sistemas de fluidos de perfuração são os modelos de Bingham, Ostwald-de-Waele (lei da potência) e Herschel-Buckley (THOMAS, 2004; SHIROMA, 2012).

### 2.2.1 Modelo de Bingham

Um fluido de Bingham não flui até uma tensão de cisalhamento,  $\tau$ , exceder um valor mínimo,  $\tau_0$ , conhecido como limite de escoamento ou *yield point*. Depois da tensão de cisalhamento mínimo ter sido aplicada, variações na tensão de cisalhamento são proporcionais às variações da taxa de deformação,  $\dot{\gamma}$ , e a constante de proporcionalidade é chamada de viscosidade plástica,  $\mu_p$  (MELO, 2008).

O modelo que descreve o comportamento de Bingham, ilustrado na Figura 3, é uma relação linear com dois parâmetros, o limite de escoamento e a viscosidade plástica, conforme mostrado na equação (2.1). Fisicamente, a viscosidade plástica representa o atrito entre as partículas dispersas e as moléculas do líquido, sendo assim, responsável pela resistência ao escoamento (AMORIM, 2003).

$$\tau = \tau_0 + \mu_p \dot{\gamma} \quad (2.1)$$



**Figura 3.** Curva de fluxo de um fluido de Bingham.

### 2.2.2 Modelo da potência de Ostwald e de Waele

O modelo de potência, ou *power law*, é o modelo mais simples que pode representar tanto fluidos em que a viscosidade aparente decresce com o aumento da taxa de deformação, chamados pseudoplásticos ou *shear-thinning*, quanto fluidos em que a viscosidade aparente

crece com o aumento da taxa, denominados dilatantes ou *shear thickening*. Para escoamentos unidimensionais a relação é descrita por um modelo exponencial conforme a equação (2.2) (FOX; MCDONALD; PRITCHARD, 2010).

$$\tau = K\dot{\gamma}^{n-1}\dot{\gamma} \quad (2.2)$$

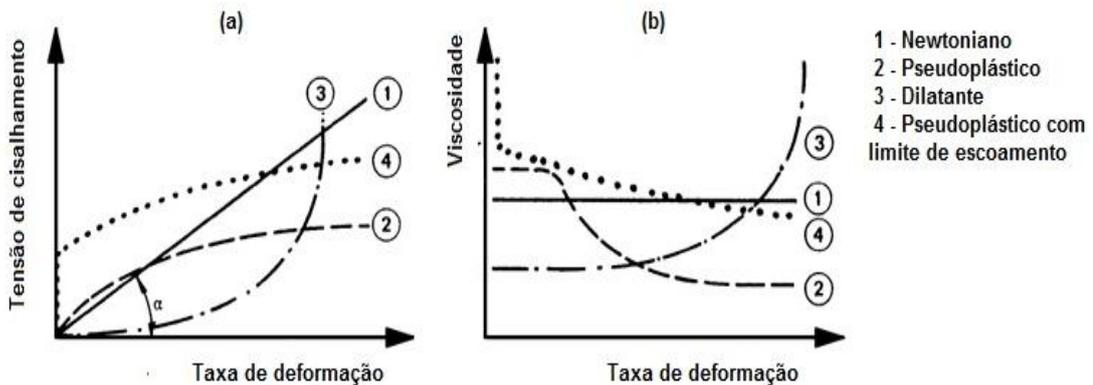
onde:  $K$  representa o índice de consistência;  $n$  simboliza o índice de comportamento do escoamento;  $\dot{\gamma}$  a taxa de deformação.

O modelo de *power-law* consegue abranger o comportamento de diferentes fluidos através do valor do índice de comportamento. Se  $n=1$ , a equação acima se reduz à equação de Newton, de modo que  $K$  representa a viscosidade absoluta do fluido,  $\mu$ . Se  $n<1$ , a equação (2.2) representa fluidos com comportamento pseudoplástico, em que a viscosidade aparente,  $\mu_{ap}$ , diminui com o aumento da taxa, segundo a equação abaixo.

$$\mu_{ap} = K\dot{\gamma}^{n-1} \quad (2.3)$$

Se  $n>1$ , a equação (2.2) representa os fluidos dilatantes, em que a viscosidade aparente cresce com o aumento da taxa de cisalhamento. O comportamento desses fluidos está ilustrado na Figura 4.

De acordo com Schwalbert (2013), o modelo da potência descreve boa parte dos fluidos, porém, normalmente apresenta problemas numéricos para descrever fluidos pseudoplásticos em baixas taxas de deformação.



Fonte: SCHRAMM, 2006.

**Figura 4.** a) Curvas de fluxo e b) curvas de viscosidades de fluidos Newtonianos e independentes do tempo.

### 2.2.3 Modelo de Herschel-Buckley

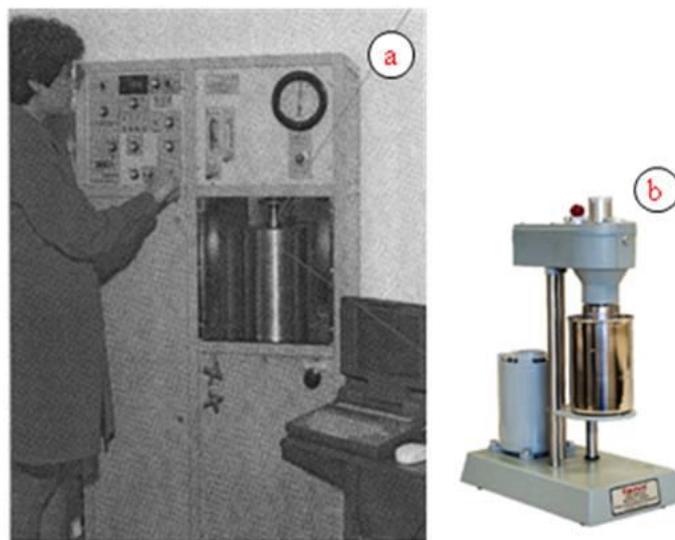
O modelo de Herschel-Buckley, representado na equação (2.4), possui características dos modelos da potência e de Bingham, ou seja, representam fluidos com tensão mínima para escoamento e que apresentam relação não linear entre tensão e taxa de deformação. Segundo Schramm (2006), fluidos que apresentam essas características são definidos como pseudoplásticos com limite de escoamento ou como fluidos plásticos. A Figura 4 ilustra o comportamento desses fluidos. Segundo Stefan (1966 apud AMORIM, 2003), os vários tipos de fluidos de perfuração, com exceção dos à base gás, comportam-se como fluidos plásticos.

$$\tau = K \dot{\gamma}^n + \tau_0 \quad (2.4)$$

### 2.2.4 Métodos de determinação experimental

As curvas de fluxo e de viscosidade, assim como as propriedades reológicas são obtidas através de ensaios experimentais pelo uso de reômetros ou viscosímetros. De acordo com Shiroma (2012), os reômetros são equipamentos versáteis capazes de medir propriedades tanto viscosas quanto elásticas de sólidos e fluidos. Segundo Schramm (2006), os reômetros podem ser do tipo capilar, cilindros-coaxiais, cone e placa, e a escolha de um determinado tipo está relacionado com o produto analisado e as características reológicas a serem medidas.

Os viscosímetros são equipamentos mais limitados, pois fornecem apenas à medida do comportamento do fluxo viscoso. Apesar de serem equipamentos simples, são os mais utilizados nas sondas de perfuração para medidas de viscosidade dos fluidos. Santoyo *et al.* (2001) destacam o uso de dois viscosímetros, o FANN 35 A e o FANN 50C, ilustrados na Figura 5.



Fonte: SANTOYO *et al.*, 2001.

**Figura 5.** a) Viscosímetro FANN 50C e b) viscosímetro FANN 35A.

Santoyo *et al.*(2001) utilizaram o FANN 50 C para averiguar a variabilidade da viscosidade da lama de perfuração com a temperatura em diferentes pressões. Com esse viscosímetro, os autores estabeleceram o perfil de viscosidade dos fluidos em diferentes trechos do poço perfurado.

O viscosímetro FANN 35 A é o mais utilizado para medir a viscosidade dos fluidos de perfuração mantidos nos tanques de armazenamentos, pois fornece medidas rápidas e simples de propriedades como o limite de escoamento e as forças géis dos fluidos, normalmente na temperatura ambiente (BOURGOYNE JR *et al.*, 1986).

O viscosímetro FANN 35A é classificado como viscosímetro rotacional com sistema Couette. Neste sistema de medida, o equipamento é constituído de dois cilindros coaxiais, no qual o cilindro externo gira a uma velocidade definida, provocando um escoamento na amostra de líquido entre dois cilindros. A resistência do líquido cisalhado transmite um torque ao cilindro interno, que é induzido a girar. Como o cilindro interno está fixo a uma mola de torção, a mesma se deforma até atingir o estado de equilíbrio. Com isso, o torque é medido pela determinação do contra-torque que mantém o cilindro interno estático (MACHADO, 2002).

Neste trabalho, utilizou-se o viscosímetro FANN 35A para determinar a viscosidade aparente dos fluidos de perfuração em diferentes velocidades de rotação,  $\Omega$ , e pela leitura de ângulo de deformação da mola,  $\theta$ , conforme mostrado na equação (2.5) fornecida pelo fabricante.

$$\mu_{ap} = \frac{300 \times \theta}{\Omega} \quad (2.5)$$

## 2.3 Modelos Empíricos

Nesta seção são apresentados alguns modelos e métodos estatísticos utilizados na literatura que relacionam a viscosidade de fluidos com variáveis diferentes daquelas utilizadas experimentalmente (tensão e taxa de deformação), assim como, o modelo neuronal e suas diversas aplicações na indústria de petróleo.

### 2.3.1 Equações matemáticas

A primeira relação teórica utilizada para descrever a relação da viscosidade de fluidos em função da concentração de sólidos foi proposta por Einstein em 1906. Einstein considerou uma suspensão de esferas rígidas tão diluída que o movimento de uma esfera não influencia o escoamento do fluido nas vizinhanças de qualquer outra esfera. Dessa forma, analisou o movimento do fluido em torno de uma única esfera e os efeitos individuais de cada esfera foram considerados aditivos. A equação de Einstein é mostrada na equação (2.6) (BIRD; STEWART; LIGHTFOOT, 2004).

$$\frac{\mu_{eff}}{\mu_0} = 1 + \frac{5}{2} \phi_p \quad (2.6)$$

onde  $\mu_{eff}$  é a viscosidade efetiva que substitui a viscosidade de fluidos em uma única fase,  $\mu_0$  representa a viscosidade do meio dispersante, e  $\phi_p$  representa a fração volumétrica das partículas.

Trabalhos baseados na equação de Einstein buscaram estabelecer relações que descrevessem a viscosidade de fluidos com elevadas concentrações de sólidos. As equações propostas foram baseadas em expansões da série de Taylor para a variável  $\phi_p$ , conforme a equação (2.7) (CHENG e LAW, 2003; DEOSARKAR e SATHE, 2011).

$$\frac{\mu_{eff}}{\mu_0} = 1 + k_1 \phi_p + k_2 \phi_p^2 + k_3 \phi_p^3 + \dots \quad (2.7)$$

onde  $k_1$ ,  $k_2$ ,  $k_3$  são parâmetros que representam a interação partícula-partícula e o movimento das partículas sólidas.

De acordo com Cheng e Law (2003), a maior parte dos modelos foi determinada a partir de funções de baixa ordem em  $\phi_p$  com  $k_2$  e  $k_3$ . Devido à dificuldade em estabelecer relações de interação entre as partículas, os autores propuseram modificações em que contabilizaram indiretamente efeitos como: a colisão entre as partículas; turbulência do fluido; e o movimento aleatório das partículas. Essas modificações resultaram em um modelo de ordem mais elevado com cinco parâmetros, conforme a equação (2.8).

$$\frac{\mu_{eff}}{\mu_0} = 1 + \frac{5}{2} \phi_p + \frac{35}{8} \phi_p^2 + \frac{105}{16} \phi_p^3 + \frac{1155}{128} \phi_p^4 + \frac{3003}{256} \phi_p^5 \quad (2.8)$$

Desoarkar e Sathe (2011) apresentaram uma série de correlações que utilizam como parâmetros a fração volumétrica máxima de sólidos,  $\phi_m$ . Este parâmetro representa o estado ou a condição de suspensões em que a viscosidade efetiva se aproxima do infinito e, com isso, a suspensão se comportaria como sólido. Algumas das equações relatadas nesse trabalho são mostradas na Tabela 2.

### 2.3.2 Modelos estatísticos

Diferentes métodos estatísticos vêm sendo empregados nos estudos de fluidos de perfuração com o objetivo de estabelecer formulações, avaliar a influência de diferentes componentes sobre a variável desejada e, além disso, estabelecer modelos de regressão que

descrevam as propriedades reológicas dos fluidos. A seguir serão apresentados alguns trabalhos que adotaram esta metodologia.

Amorim *et al.* (2002) avaliaram a influência de duas ferramentas de agitação (pilheta corrugada e em forma de borboleta), a velocidade e o tempo de agitação nas propriedades reológicas das dispersões de argilas bentoníticas através de um planejamento fatorial. Esse método permitiu o ajuste dos dados por um modelo de regressão e, com isso, foi possível avaliar a significância estatística de cada fator na viscosidade aparente e plástica dos fluidos.

Barbosa (2006) estudou a influência de dois aditivos poliméricos em argilas bentoníticas, o CMC (carboximetilcelulose) e a PAM (poliacrilamida). Através de um delineamento de mistura determinou um modelo matemático e as composições ótimas de cada aditivo que proporcionavam melhorias nos parâmetros reológicos dos fluidos à base de água.

**Tabela 2.** Diferentes equações para predição da viscosidade efetiva.

Autor (ano)	Equação
Einstein (1906)	$\frac{\mu_{eff}}{\mu_0} = 1 + \frac{5}{2} \phi_p$
Krieger e Dougherty (1959)	$\frac{\mu_{eff}}{\mu_0} = \left( 1 - \frac{\phi_p}{\phi_m} \right)^{-\eta \phi_m}$
Chong <i>et al.</i> (1971)	$\frac{\mu_{eff}}{\mu_0} = \left( 1 + 0,75 \frac{\frac{\phi_p}{\phi_m}}{1 - \frac{\phi_p}{\phi_m}} \right)^2$
Metzner (1985)	$\frac{\mu_{eff}}{\mu_0} = \left( 1 - \frac{\phi_p}{\phi_m} \right)^{-2}$
Leighton e Acrivos (1986)	$\frac{\mu_{eff}}{\mu_0} = \left( 1 + \frac{0,5\eta \phi_p}{1 - \frac{\phi_p}{\phi_m}} \right)^2$
Liu (2000)	$\frac{\mu_{eff}}{\mu_0} = a (\phi_m - \phi)^{-n}$

Fonte: Adaptado de DESOARKAR e SATHE, 2011.

Campos, Amorim e Ferreira (2007) empregaram o planejamento experimental para avaliar o efeito da composição de misturas ternárias de bentonitas na reologia de fluidos de perfuração. Por meio do planejamento, os autores estabeleceram as proporções dos componentes nas misturas ternárias das argilas e, então, construíram modelos de regressão

lineares, quadráticos e cúbicos, para relacionar a viscosidade aparente com a concentração de aditivos. Essa abordagem associada com a metodologia de superfícies de respostas permitiu determinar as composições de argilas que promovem melhorias nas propriedades reológicas dos fluidos.

Nascimento, Costa e Amorim (2012) avaliaram a influência do envelhecimento térmico nas propriedades reológicas e de filtração de fluidos argilosos. Os autores utilizaram um planejamento fatorial de 2ª ordem, adotando a concentração de argila, temperatura e o tipo de envelhecimento (estático ou dinâmico) como variáveis de entrada. Através do teste ANOVA (análise de variância), foram capazes de estabelecer modelos estatísticos para a viscosidade aparente, plástica e forças géis (inicial e final) dos fluidos.

Na presente dissertação, foi utilizada uma abordagem semelhante aos trabalhos descritos para avaliar a influência da concentração de aditivos e da temperatura na viscosidade aparente dos fluidos à base de água. Essa metodologia envolveu a construção de um planejamento fatorial completo e o uso do teste ANOVA para determinar um modelo de regressão linear para a variável de interesse, a viscosidade aparente.

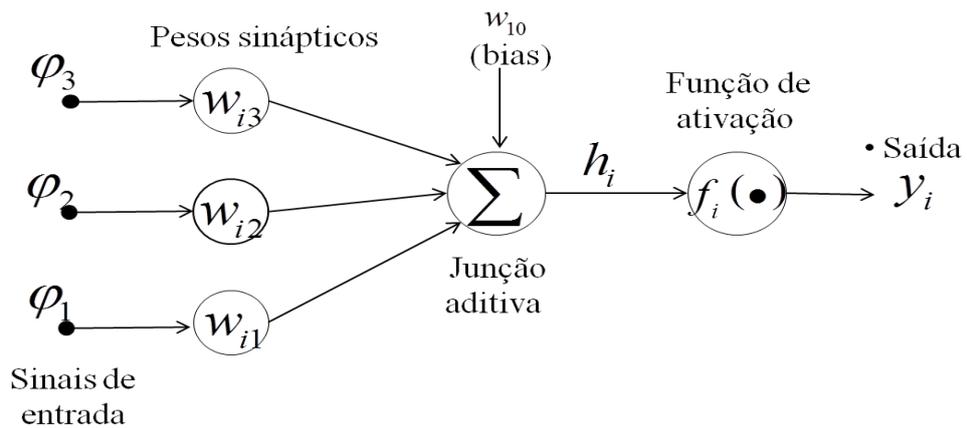
## 2.4 Redes Neurais

As redes neurais são um paradigma computacional composto por unidades processadoras, ou neurônios, que interagem localmente através das múltiplas conexões entre as camadas de neurônios. Estes modelos são identificados através de uma arquitetura, especificada pela característica funcional dos neurônios, pela topologia da rede e pelo algoritmo de treinamento utilizado (VALDMAN, 2010). Os neurônios utilizados em redes neurais artificiais foram definidos em analogia aos neurônios do cérebro humano. Sendo assim, as redes neurais constituem uma metodologia com capacidade de aprender e reconhecer padrões operacionais (DA SILVA; SPATTI; FLAUZINO, 2010).

Uma rede neuronal é um processador paralelamente distribuído constituído de unidades de processamento simples, neurônios artificiais, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso (HAYKIN, 2001).

Os elementos básicos de um neurônio podem ser visualizados na Figura 6. Pela figura observa-se que os neurônios recebem sinais ( $\varphi_i$ ) e que ao final do processamento o transformam em uma informação de saída. Cada sinal apresentado ao neurônio artificial é ponderado por um parâmetro, ou peso, que indica a sua influência na saída da unidade. Em seguida, os sinais ponderados são somados produzindo certo nível de atividade ( $h_i$ ). Caso esse sinal exceda um limite, *bias*, o neurônio dispara uma resposta restringida por uma função de ativação que é propagada aos elementos de processamento interligados em sequência ou este sinal representa o valor da variável desejada para os neurônios da última camada.

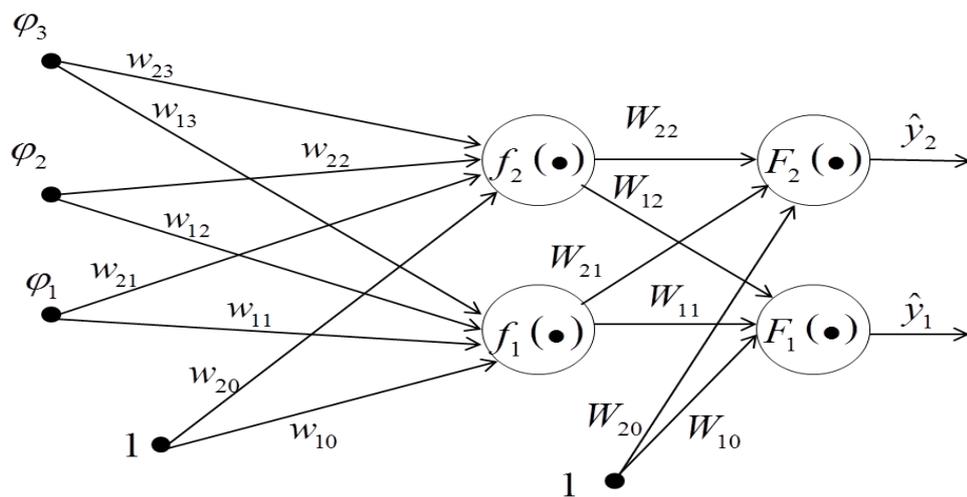
Vários autores (BRAGA; LUDERMIR; CARVALHO, 2000; HAYKIN, 2001; DA SILVA; SPATTI; FLAUZINO, 2010) utilizaram as redes neurais abordando diferentes arquiteturas, algoritmos de treinamento e áreas de aplicação. No entanto, as redes do tipo *perceptron* de múltiplas camadas (*Multilayer Perceptron*, MLP) são provavelmente o tipo de modelo mais empregados nas tarefas de identificação e controle de sistemas não lineares. Uma das razões para este sucesso está relacionada ao fato dessas estruturas serem capazes de modelar adequadamente tanto relações funcionais simples quanto complexas (NORGAARD *et al.*, 2000 apud MELEIRO, 2002a).



**Figura 6.** Representação esquemática de um neurônio.

### 2.4.1 Modelo matemático do *perceptron* multicamadas

A rede MLP possui os neurônios ordenados em camadas, de modo que cada neurônio em uma dada camada tome como entradas somente as saídas dos neurônios da camada anterior ou as entradas externas, conforme ilustrado na Figura 7. Este tipo de estrutura pertence à arquitetura *feedforward* de camadas múltiplas, cujo treinamento é efetivado de forma supervisionada. O fluxo de informação nessa estrutura de rede se inicia na camada de entrada passando pelas camadas intermediárias e sendo finalizado na camada neuronal de saída (DA SILVA; SPATTI; FLAUZINO, 2010).



**Figura 7.** *Perceptron* multicamadas do tipo *feedforward*.

Segundo Haykin (2011), os neurônios de cada camada apresentam diferentes funções de ativação, sendo geralmente empregada a função tangente hiperbólica na camada interna,

$f_i(\bullet)$ , e função linear para os neurônios da camada de saída,  $F_i(\bullet)$ . Assim, a saída da rede neuronal,  $\hat{y}_i$ , pode ser representada por:

$$\hat{y}_i = g_i[\varphi, \theta] = F_i \left[ \sum_{j=1}^{n_h} W_{i,j} f_j \left( \sum_{l=1}^{n_\varphi} w_{j,l} \varphi_l + w_{j,0} \right) + W_{i,0} \right] \quad (2.9)$$

onde  $\theta$  especifica o vetor de parâmetros que contém todos os parâmetros ajustáveis da rede neuronal, ou seja, os pesos e *biases* ( $w_{j,i}$ ,  $W_{j,i}$ ).

### 2.4.2 Algoritmo de treinamento das MLP

Definida a topologia (número de camadas e número de neurônios em cada camada) e as funções de ativação, a rede neuronal deve passar por uma etapa de treinamento. Durante esta etapa, dados de entrada e saída são apresentados à rede e seus parâmetros são ajustados continuamente mediante a aplicação de ações comparativas, executadas pelo algoritmo de otimização, que supervisiona a diferença entre as respostas produzidas em relação àquelas desejadas. Há inúmeros métodos de treinamento, mas o mais utilizado é conhecido como *backpropagation* (RUMELHART, MCCLELLAND, 1986).

O algoritmo *backpropagation* utilizado no treinamento de rede neuronais do tipo MLP é baseado na minimização de uma função objetivo, calculada através da média dos erros ao quadrado, onde o erro é a diferença entre os valores fornecidos pelos neurônios da camada de saída e os valores alvo para todos os padrões fornecidos a rede, conforme apresentado na equação abaixo (HAYKIN, 2011).

$$F_{\text{Objetivo}} = \frac{1}{2} (y_d - \hat{y})^2 \quad (2.10)$$

onde:  $F_{\text{Objetivo}}$ , é a função de custo ou índice de desempenho;  $\hat{y}$ , representa os valores fornecidos pelos neurônios de saída da rede neuronal em resposta aos padrões utilizados;  $y_d$ , é o vetor contendo os valores alvo para os padrões fornecidos à rede durante o aprendizado.

### 2.4.3 Aplicações das redes MLP

Devido à complexidade operacional dos processos de transformação envolvidos e a busca constante pela maximização da qualidade e minimização de custos, a indústria petroquímica possui uma base consistente de instrumentação instalada. No entanto, o

monitoramento e o controle de certas variáveis são limitados pela falta de equipamentos de instrumentação capazes de medir variáveis específicas.

De acordo com a literatura, modelos de redes neuronais vêm sendo empregados na solução de problemas na indústria de petróleo por apresentarem melhores predições do que as aproximações provenientes de modelos empíricos. Alguns trabalhos utilizaram as redes multicamadas para estabelecer relações entre diferentes variáveis de interesse na engenharia de petróleo como, por exemplo, na estimação da permeabilidade relativa de um poço, predição do comportamento dos gases nos reservatórios e na estimativa da viscosidade de óleo cru (ARPAT; GÜMRAH; YETEN, 1998; AMINZADEH *et al.*, 1999; GONZÁLEZ; BARRUFET; STARTZMAN, 2003; AL - MARHOUN *et al.*, 2012).

Poucos trabalhos foram encontrados na literatura que direcionaram as redes neuronais MLP (*perceptron* de multicamadas) para a estimação da viscosidade aparente de fluidos de perfuração, variável de interesse neste trabalho. Abaixo são apresentados esses trabalhos e as abordagens utilizadas.

Deosarkar e Sathe (2012) utilizaram as redes neuronais para predizer a viscosidade efetiva de fluidos contendo sólidos de magnetita em soluções de CMC e goma guar, materiais empregados nos fluidos de perfuração para aumentar a viscosidade e a densidade. Para o treinamento da rede, os autores utilizaram a fração volumétrica de sólidos, taxa de cisalhamento e tamanho das partículas sólidas como variáveis de entrada para a predição da variável de interesse. Além disso, avaliaram a influência da concentração de sólidos na viscosidade através de modelos empíricos. Os autores concluíram que o modelo neuronal apresentou resultados mais próximos aos obtidos experimentalmente.

Razi *et al.* (2013) aplicaram a rede *feedforward* do tipo MLP para estimar as propriedades reológicas (viscosidade aparente, viscosidade plástica e limite de escoamento) de fluidos de perfuração à base de água contendo bentonita e amido em sua formulação. Para a estimação dessas variáveis foram utilizados neurônios com função de transferência logística na camada intermediária e funções lineares na camada de saída. Para o treinamento das redes utilizaram como variáveis de entrada a temperatura, taxa de deformação e a concentração de bentonita. Os autores observaram que a rede escolhida foi capaz de predizer a viscosidade aparente desses fluidos.

Neste trabalho, as redes neuronais foram utilizadas para estimar a viscosidade aparente de fluidos à base de água contendo goma xantana, bentonita e barita como componentes. O treinamento da rede foi realizado empregando as concentrações dos aditivos e a temperatura dos fluidos como sinais de entrada. O melhor modelo neuronal foi comparado com a equação de Liu para avaliar qual apresenta melhores ajustes aos dados experimentais, metodologia semelhante a utilizada por Deosarkar e Sathe (2012).

### 3. MATERIAIS E MÉTODOS

Neste capítulo serão descritos os materiais e equipamentos utilizados, assim como a metodologia empregada na formulação e determinação da viscosidade aparente dos fluidos à base de água. Também serão apresentados os métodos estatísticos empregados e a descrição da metodologia elaborada para a identificação do modelo neuronal.

#### 3.1 Materiais e Equipamentos

Para o preparo dos fluidos foram utilizadas goma xantana, bentonita e barita, aditivos que têm funções distintas nos fluidos de perfuração, conforme apresentado na Tabela 3. A bentonita e barita foram fornecidas pela empresa Brasilminas, situada em Cumbica, Garulhos, SP. A goma xantana foi fornecida pela empresa Carboflex, localizada São Sebastião do Passe, BA.

**Tabela 3.** Componentes dos fluidos de perfuração à base de água.

Aditivos	Função	Fornecedor
<b>Goma Xantana</b>	Viscosificante	Carboflex
<b>Bentonita</b>	Viscosificante	Brasilminas
<b>Barita</b>	Adensante	Brasilminas

Para homogeneização dos fluidos foi utilizado o agitador Hamilton Beach<sup>®</sup> com três velocidades (13000, 16000 e 18000 rpm). O controle da temperatura do fluido foi realizado por um banho termostatizado Technal<sup>®</sup> Te-2005, acoplado a um copo encamisado, capaz de circular a água na faixa de -10 a 80<sup>o</sup>C. Utilizou-se o viscosímetro FANN 35A para a obtenção da viscosidade aparente do fluido de perfuração. Os equipamentos descritos nesta seção são mostrados na Figura 8.



**Figura 8.** a) Agitador Hamilton Beach<sup>®</sup>, b) Banho térmico, c) copo encamisado e d) viscosímetro Fann 35A.

### 3.2 Planejamento Experimental

Neste trabalho foi realizado um planejamento experimental fatorial completo com três níveis para quatro variáveis, cada nível foi codificado como baixo (-1), médio (0) e alto (+1), conforme apresentado na Tabela 4.

**Tabela 4.** Níveis utilizados nos planejamentos experimentais.

Níveis	-1	0	1
Temperatura (°C)	20	40	60
Goma Xantana (g/300mL H <sub>2</sub> O)	0,75	1,5	2,25
Bentonita (g/300mL H <sub>2</sub> O)	90	120	150
Barita (g/300mL H <sub>2</sub> O)	80	220	360

No entanto, foi realizado um planejamento preliminar, utilizando apenas os aditivos como variáveis, com o intuito de verificar o comportamento desses compostos durante a preparação dos fluidos. Esse delineamento experimental resultou em 27 ensaios, porém, para que fosse possível a realização de inferências estatísticas foram realizados mais três ensaios nos pontos centrais. Com isso, foram preparados 30 fluidos de perfuração conforme mostrado na Tabela 5. Através deste planejamento foi possível construir as curvas reológicas dos fluidos de perfuração na temperatura ambiente e averiguar a influência dos aditivos na viscosidade aparente dos fluidos.

**Tabela 5.** Planejamento inicial contendo 30 experimentos (continua).

Experimento	Goma xantana	Bentonita	Barita
1	-1	-1	-1
2	-1	-1	0
3	-1	-1	1
4	-1	0	-1
5	-1	0	0
6	-1	0	1
7	-1	1	-1
8	-1	1	0
9	-1	1	1
10	0	-1	-1
11	0	-1	0
12	0	-1	1
13	0	0	-1
14	0	0	0
15	0	0	1
16	0	1	-1
17	0	1	0
18	0	1	1
19	1	-1	-1
20	1	-1	0

**Tabela 5.** (Continuação).

<b>Experimento</b>	<b>Goma xantana</b>	<b>Bentonita</b>	<b>Barita</b>
<b>21</b>	1	-1	1
<b>22</b>	1	0	-1
<b>23</b>	1	0	0
<b>24</b>	1	0	1
<b>25</b>	1	1	-1
<b>26</b>	1	1	0
<b>27</b>	1	1	1
<b>28</b>	0	0	0
<b>29</b>	0	0	0
<b>30</b>	0	0	0

Posteriormente, foi realizado um novo planejamento experimental utilizando os mesmos aditivos, além da temperatura como variáveis. Este delineamento foi realizado com o intuito de obter um conjunto maior de dados experimentais visando identificar um modelo neuronal e, além disso, estabelecer um novo modelo estatístico para estimar a viscosidade aparente dos fluidos na velocidade de 300 rpm em várias temperaturas. Nesse planejamento também foram realizadas três réplicas no ponto central, o que resultou em um total de 84 ensaios experimentais, conforme a Tabela 15 presente no anexo.

### **3.2.1 Preparação dos fluidos de perfuração**

Para o preparo dos fluidos, utilizou-se 300 mL de água e os aditivos foram pesados, conforme as especificações da Tabela 4, e misturados com o agitador Hamilton Beach<sup>®</sup>. Os aditivos foram colocados no copo do agitador aos poucos e sob constante agitação, alternando a velocidade entre 13000 e 16000 rpm. Ao acrescentar todos os componentes, a velocidade do agitador foi alterada para 18000 rpm por 10 minutos para garantir a homogeneização dos fluidos. Após a agitação, os fluidos permaneceram em repouso por 24 horas para garantir que os polímeros atingissem a completa hidratação. Essa metodologia segue a norma N-2605 (PETROBRAS, 1998) conforme apresentado em Amorim (2003).

### **3.2.2 Determinação da viscosidade aparente**

Os fluidos de perfuração, após o intervalo de repouso, foram armazenados no copo encamisado e levados ao viscosímetro FANN 35A para a determinação da viscosidade aparente.

Para a realização do planejamento preliminar, foi utilizado o viscosímetro FANN 35A/SR-12, capaz de trabalhar com 12 velocidades de rotação (0,9; 1,8; 3; 6; 30; 60; 90; 100; 180; 200; 300 e 600 rpm). Foram realizadas as medidas dos ângulos de deformação sempre da menor velocidade para a maior. Cada leitura foi obtida após um intervalo de 5 a 10 minutos, apenas quando o ponteiro do viscosímetro permanecia fixo.

Após a leitura, o viscosímetro era desligado e a medida em outra velocidade realizada apenas quando o fluido retornava à condição de “gel”. Esse estado de “gel” foi observado quando o ângulo de deformação da mola retornava à condição inicial, ou seja, quando o ponteiro do viscosímetro indicava o ângulo de deformação igual à zero.

Através das especificações do viscosímetro fornecidas pelo fabricante (Quadro 1), a velocidade de rotação e os valores de deformação angular foram convertidos em valores de tensão de cisalhamento, taxa de deformação e viscosidade aparente.

Pela equação de viscosidade aparente, observa-se que o ângulo de deformação na velocidade 300 rpm representa a própria viscosidade aparente do fluido. Por este motivo, o uso dos viscosímetros FANN 35A nas sondas de perfuração são utilizados apenas na velocidade de 300 rpm por permitir leituras rápidas de viscosidade. Dessa forma, os ensaios realizados nesta dissertação envolvendo a temperatura seguiram o procedimento padrão realizado nas sondas de perfuração, sendo considerados os valores de viscosidade aparente correspondentes apenas à velocidade de 300 rpm.

**Quadro 1.** Especificações do viscosímetro FANN 35A.

$\theta$ (graus)	Ângulo de deformação
$\Omega$ (rpm)	Velocidade Angular
$k_1$ (dina/cm. $\theta$ )	386,2433
$k_2$ (cm <sup>-3</sup> )	0,01323
$k_3$ (s <sup>-1</sup> /rpm)	1,7023
Taxa de deformação (s <sup>-1</sup> )	$\dot{\gamma} = k_3\Omega$
Tensão de cisalhamento (dina/cm <sup>2</sup> )	$\tau = k_1k_2\theta$
Viscosidade aparente (cP, centipoise)	$\mu_{ap} = \frac{300 \times \theta}{\Omega}$

A temperatura do fluido foi controlada através do banho termostático acoplado ao copo encamisado, Figura 8, e os fluidos foram aquecidos da temperatura ambiente até a temperatura do planejamento. Durante o aquecimento, o viscosímetro permaneceu ligado para homogeneizar a mistura e manter os fluidos no estado de fluidez (estado “sol”), além de diminuir o gradiente de temperatura dentro do copo.

A viscosidade aparente foi medida em duplicata, isto é, a viscosidade foi avaliada duas vezes em tempos diferentes. A primeira medida foi obtida quando o termômetro mergulhado no copo encamisado indicava a temperatura desejada inicialmente. A segunda leitura foi realizada após cerca de 10 minutos quando alcançado o equilíbrio térmico. As medidas foram codificadas como leituras na temperatura controlada e pontual.

Durante todo o aquecimento também foram coletados dados de viscosidade em valores de temperatura intermediários àqueles estabelecidos pelo delineamento experimental. Este procedimento permitiu aumentar consideravelmente o número de dados experimentais em diferentes condições de temperatura, o que contribuiu positivamente para a identificação do modelo neuronal. Dessa forma, na rampa de aquecimento fornecida pelo banho termostático, os dados de viscosidades foram coletados na temperatura do termômetro sempre que o ponteiro do viscosímetro apresentava baixa oscilação.

Antes de serem empregados na identificação por rede neuronal, os dados coletados foram avaliados por alguns testes estatísticos, conforme será descrito na seção 3.3.

### 3.3 Métodos Estatísticos

Os dados do planejamento obtidos em duplicata, denominados temperatura controlada e temperatura pontual, foram analisados pelos testes de Kolmogorov - Smirnov e de Wilcoxon do posto sinalizado. Através desses testes foi avaliado se os 84 dados obtidos em duplicata poderiam ser considerados iguais e, com isso, se a metodologia empregada para coletar dados durante o aquecimento poderia ser questionada.

O teste de Kolmogorov - Smirnov foi utilizado usando a correção de Lilliefors para determinar se o conjunto de dados apresenta distribuição normal. Segundo Rodrigues e Lemma (2009), a metodologia estatística empregada depende da forma com que os dados estão distribuídos, podendo ser dividida em duas partes: estatística paramétrica, constituída dos métodos derivados dos parâmetros média e variância; e estatística não paramétrica, constituída de métodos que independem da forma de distribuição. Baseado na distribuição dos dados, o teste de Wilcoxon do posto sinalizado foi escolhido para avaliar se os dados obtidos em duplicata podem ser considerados equivalentes. Toda a análise estatística foi realizada através do *software Statistica*<sup>®</sup>, versão 10, com nível de significância de 5%.

Além desses testes, foi aplicado o teste análise da variância, ANOVA, para obter um modelo de regressão linear capaz de prever a viscosidade aparente em função dos níveis das variáveis do planejamento. Nesta seção são abordados os princípios básicos dos testes estatísticos e uma breve descrição de cada método aplicado.

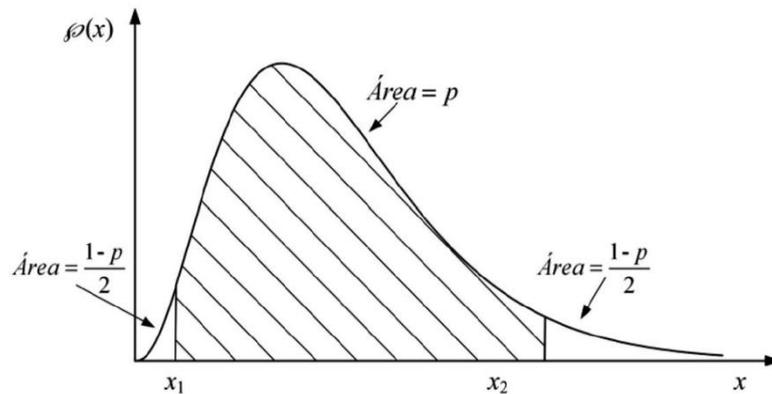
#### 3.3.1 Princípios básicos

Boa parte dos métodos estatísticos está baseada em decisões que envolvem a aceitação ou rejeição de alguma afirmativa sobre algum parâmetro de uma ou mais populações. Essa afirmativa é, em geral, chamada de hipótese, e o procedimento de decisão em relação a essa afirmativa é chamado teste de hipótese (HINES *et al.*, 2006; MONTGOMERY e RUNGER, 2010).

Segundo Rodrigues e Lemma (2009), os testes de hipóteses consideram, sempre, duas hipóteses: a hipótese nula,  $H_0$ , e a alternativa,  $H_a$ . A hipótese nula é a hipótese que está sendo posta à prova, enquanto a alternativa é a hipótese que será aceita caso  $H_0$  seja rejeitado.

De acordo com Schwaab e Pinto (2007), para que seja possível tomar decisões, é preciso decidir que resultados podem ser considerados normais (com grande probabilidade de ocorrer) e que resultados devem ser considerados anormais (ou seja, que têm probabilidade tão baixa de ocorrer que podem ser descartados na grande maioria das vezes). Dessa forma, definem um intervalo de confiança,  $p\%$ , ao conjunto de resultados que, segundo uma curva de distribuição de probabilidade (Figura 9) concentra  $p\%$  dos resultados admissíveis. Assim, os resultados menos prováveis são descartados com  $(100 - p\%)$ , sendo essa probabilidade dividida nas extremidades superior e inferior.

As regiões críticas, mostradas na figura abaixo, estabelecem os limites para as hipóteses testadas de acordo com um nível de significância do teste, denotada por  $\alpha$  e, em geral, igual a 5%. Essas regiões podem ser subdivididas em região de não rejeição de  $H_0$ , representada pela área igual a  $p\%$ , e rejeição de  $H_0$ , simbolizada pela as áreas extremas da Figura 9 (RODRIGUES e LEMMA, 2009).



Fonte: SCHWAAB e PINTO, 2007.

**Figura 9.** Ilustração gráfica do conceito de intervalo de confiança.

As análises estatísticas foram realizadas através do *software Statistica*<sup>®</sup> com nível de significância de 5%. Segundo Rodrigues e Lemma (2009), quando o teste de hipótese é realizado através de algum programa estatístico, o *output* fornecido pelo programa é o p-valor (*p-value*), nível descritivo ou probabilidade de significância do teste. Esse p-valor representa a probabilidade de ocorrência de valores da variável do teste mais extremos que o obtido através dessa amostra. Assim, a decisão dos testes de hipóteses pode ser feita em termos do p-valor: rejeitando ou não  $H_0$ , conforme o p-valor seja, respectivamente, menor ou não que o nível de significância,  $\alpha$ , estabelecido.

### 3.3.2 Modelo de regressão estatístico

O planejamento experimental completo permite descrever as observações experimentais através de modelos lineares estatísticos. Para descrever as relações entre os fatores do planejamento e a viscosidade aparente empregou-se a metodologia de superfície de resposta. Segundo Montgomery e Runger (2010), esta técnica é uma coleção de ferramentas matemáticas e estatísticas, utilizada principalmente na modelagem e análise em aplicações onde a resposta de interesse é influenciada por muitas variáveis.

A primeira etapa da modelagem consiste em ajustar os dados a um polinômio de baixo grau, se a resposta for bem modelada por uma função linear, então a função de aproximação será o modelo de primeira ordem, equação (3.1). Caso o sistema apresente curvatura, um modelo polinomial de maior grau deve ser utilizado, tal como o modelo de segunda ordem descrito pela equação (3.2) (MONTGOMERY e RUNGER, 2010).

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (3.1)$$

Em que  $Y$  é a variável dependente ou de resposta,  $k$  são as variáveis regressoras e  $x$  representam os níveis codificados do planejamento. Os parâmetros  $\beta_j$ , são chamados de coeficientes de regressão e  $\varepsilon$  é definido como o erro aleatório com distribuição normal padrão.

$$Y = \beta_0 + \sum_{j=1}^k \beta_j x_j + \sum_{i < j} \sum_{i < j} \beta_{ij} x_i x_j + \sum_{j=1}^k \beta_{jj} x_j^2 + \varepsilon \quad (3.2)$$

Para o modelo de segunda ordem,  $\beta_0$  representa a média do conjunto de dados, e os parâmetros lineares, quadráticos e de interação são representados pelos  $\beta_j$ ,  $\beta_{jj}$  e  $\beta_{ij}$ , respectivamente.

Segundo Hines *et al.*(2006), os modelos polinomiais não são aproximações razoáveis da relação funcional em todo domínio das variáveis independentes, porém, para uma região relativamente pequena, são modelos que geralmente representam bem os dados experimentais.

### 3.3.2.1 Análise de variância

Em problemas de regressão múltipla, o teste de análise de variância (ANOVA) é aplicado para verificar a adequação do modelo através de testes de hipóteses sobre seus parâmetros. O princípio básico desta técnica consiste em avaliar se existe uma relação linear entre a variável de resposta e um subconjunto de regressores (MONTGOMERY e RUNGER, 2010).

A hipótese nula da análise de variância considera que os parâmetros  $\beta$  dos modelos são iguais à zero, enquanto na hipótese alternativa os parâmetros são diferentes de zero. A rejeição da hipótese nula implica que os regressores testados contribuem significativamente para o modelo.

Segundo Rodrigues e Lemma (2009), o procedimento base para o teste ANOVA divide a variância total na variável de resposta em componentes significativas, soma quadrática devido à regressão,  $SQ_R$ , e a soma dos quadrados devido ao erro,  $SQ_E$ . E a análise da hipótese é realizada através da razão entre o quadrado médio dos erros de ajustamento,  $F_0$ , ou pela probabilidade de significância do teste, p-valor. A Tabela 6 representa as etapas de cálculo e a forma com que o resultado do teste ANOVA é fornecido pelo *software Statistica*®.

**Tabela 6.** Quadro da análise de variância.

Fonte de Variação	Soma dos quadrados	Graus de liberdade	Quadrados Médios	$F_0$	p-valor
<b>Regressão</b>	$SQ_R = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$	$k=1$	$MQ_R = \frac{SQ_R}{k}$	$\frac{MQ_R}{MQ_E}$	
<b>Resíduo</b>	$SQ_E = \sum_{i=1}^n (y_i - \hat{y}_i)^2$	$n-k+1$	$MQ_E = \frac{SQ_E}{(n-k+1)}$	-	-
<b>Total</b>	$SQ_T = \sum_{i=1}^n (y_i - \bar{y})^2$	$n-1$	-	-	-

A variável  $y_i$  representa os valores experimentais observados,  $\hat{y}_i$  os valores estimados através do modelo ajustado,  $\bar{y}$  a média geral das respostas e  $n$  o número de observações.

O teste de ANOVA foi empregado para determinar um modelo de baixo grau consistente com os dados experimentais. Esse teste foi aplicado a modelos de regressão lineares de segunda ordem, equação (3.2), para investigar os termos quadráticos, lineares ou de interação que mais influenciam no ajuste dos dados de viscosidade aparente. A seleção dos melhores parâmetros para a construção do modelo reduzido foi determinada através da técnica de eliminação regressiva. Essa técnica consiste em analisar todos os regressores candidatos ao modelo ao mesmo tempo e, de acordo com o resultado do teste ANOVA, esses parâmetros podem ser ou não retirados do modelo. O teste foi aplicado até que fosse encontrado um modelo com apenas regressores significantes estatisticamente na predição da viscosidade aparente.

### 3.3.3 Teste de normalidade

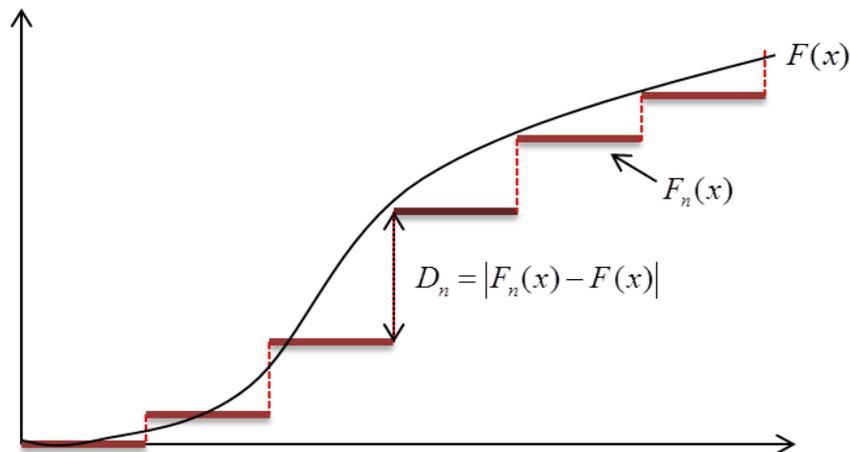
Segundo Rodrigues e Lemma (2009), a metodologia estatística utilizada sobre um conjunto de dados depende da forma com que os dados estão distribuídos. Dessa forma, aplicou-se o teste de Kolmogorov-Smirnov com correção de Lilliefors para avaliar a hipótese de normalidade dos dados, Quadro 2.

**Quadro 2.** Teste de hipótese de Kolmogorov-Smirnov.

<b>Hipótese nula (<math>H_0</math>)</b>	Os dados seguem uma distribuição normal
<b>Hipótese alternativa (<math>H_a</math>)</b>	Os dados não seguem uma distribuição normal

O princípio do teste baseia-se na comparação da curva de frequência cumulativa dos dados com a função de distribuição teórica em hipótese. Para a realização das inferências sobre as hipóteses define-se a estatística  $D_n$  como a medida da máxima distância da função de distribuição da amostra,  $F_n(x)$ , e a função proposta,  $F(x)$ . Como critério do teste, o valor

de  $D_n$  é comparado com um valor crítico tabelado dado o nível de significância do teste. A Figura 10 ilustra o ajuste da função de distribuição empírica a uma função normal (ACTION, 2013).



**Figura 10.** Ilustração do ajuste do teste Kolmogorov-Smirnov.

Segundo Action (2013), para a aplicação do teste Kolmogorov-Smirnov é preciso especificar os parâmetros da distribuição normal, média e variância, e, por isso, esse teste apresenta a tendência em aceitar a hipótese nula. Assim, para evitar esse tipo de erro, aplicouse o teste com a correção de Lilliefors.

A correção de Lilliefors padroniza os dados através da média,  $\bar{X}$ , e o desvio padrão amostral,  $S$ , conforme a equação (3.3). Dessa forma, a variável  $X$  com distribuição normal passa a ter uma distribuição com média zero e desvio padrão igual a 1, representada pela notação  $N(\mu = 0, \sigma^2 = 1)$ . Assim, as hipóteses e a estatística do teste passam a ser definidas em função dos dados padronizados, conforme mostrado no Quadro 3.

$$z = \frac{X - \bar{X}}{S} \tag{3.3}$$

**Quadro 3.** Teste de hipótese de normalidade com correção de Lilliefors.

<b>Hipótese nula (<math>H_0</math>)</b>	Os dados padronizados, $z$ , seguem a distribuição $N(\mu = 0, \sigma^2 = 1)$ .
<b>Hipótese alternativa (<math>H_a</math>)</b>	Os dados padronizados, $z$ , não seguem a distribuição.
<b>Estatística do teste</b>	$D_n =  F_n(z) - F(z) $

### 3.3.4 Teste de Wilcoxon do posto sinalizado

Segundo Chiann (2013), o teste de Wilcoxon do posto sinalizado avalia duas variáveis aleatórias  $X$  e  $Y$ , cujas amostras são observações pareadas, isto é, tem-se  $(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$ , como sendo amostras aleatórias de tamanho  $n$ . Esse método avalia a diferença entre as amostras,  $D = Y - X$ , atribuindo os postos  $1, 2, \dots, n$ , para valores absolutos da menor para a maior diferença. Para a análise do teste considera-se a soma dos postos que apresentam diferenças positivas,  $W^+$  e negativas,  $W^-$ , sendo apenas utilizado o menor valor para avaliar a hipótese dado um nível de significância.

De acordo com Action (2013), para aplicar o teste de Wilcoxon do posto sinalizado deve-se estabelecer as hipóteses como mostrado no Quadro 4. Esse teste avalia se as observações pareadas possuem medianas,  $\bar{\mu}$ , equivalentes, ou seja, se a diferença das medianas,  $\bar{\mu}_D$ , é igual a zero. Segundo o autor, as medianas, assim como a média, informam se diferentes populações diferem em localização, sendo assim, possível inferir se as amostras pareadas são provenientes de uma mesma população.

**Quadro 4.** Teste de hipótese do teste de Wilcoxon do posto sinalizado.

<b>Hipótese nula (<math>H_0</math>)</b>	$\bar{\mu}_D = 0$
<b>Hipótese alternativa (<math>H_a</math>)</b>	$\bar{\mu}_D \neq 0$
<b>Estatística do teste</b>	$W_{\min} = (W^+, W^-)$

## 3.4 Redes Neurais

### 3.4.1 Coleta e separação dos dados

Os dois primeiros passos do processo de desenvolvimento de redes neurais artificiais são a coleta de dados relativos ao problema e a sua separação em conjuntos. Normalmente, os dados coletados são separados em duas categorias: *i*) dados de treinamento, que são utilizados para o ajuste dos parâmetros da rede, pesos e *biases*, e *ii*) dados de teste, que são utilizados para verificar o desempenho da rede sob condições reais de utilização (HAYKIN, 2001).

Sendo assim, para o processo de identificação da rede neuronal foram utilizados os dados obtidos durante os experimentos como descrito na seção 3.2. Através da metodologia experimental, foi possível coletar 1017 dados de viscosidades a partir dos 84 ensaios experimentais. Esses dados foram misturados de forma aleatória, para a prevenção de tendências associadas à ordem de apresentação dos dados, e divididos em 750 dados de treinamento e 267 para validação. Essa divisão foi realizada de modo que os dados de treinamento incluíssem toda a faixa experimental.

Os níveis das variáveis do planejamento (goma xantana, bentonita, barita e temperatura) foram utilizados como dados de entrada para a rede neuronal, enquanto os dados de viscosidade aparente representam os sinais de saída desejados pela rede. Para aumentar a eficiência computacional dos algoritmos de aprendizagem, visto que os neurônios da camada

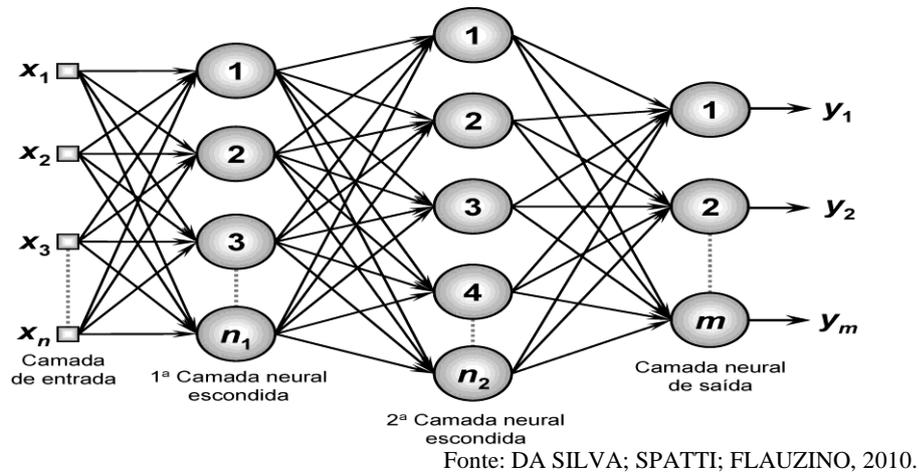
intermediária são do tipo tangente hiperbólica, esses dados foram normalizados no intervalo  $[-0,95; 0,95]$  de acordo com a equação (3.4).

$$N = \frac{1,9 * (A - A_{\min})}{A_{\max} - A_{\min}} - 0,95 \quad (3.4)$$

onde  $A$  representa os valores dos dados de entrada e saída da rede,  $A_{\max}$  e  $A_{\min}$  correspondem aos valores de máximo e mínimo de cada variável, e  $N$  os valores normalizados.

### 3.4.2 Configuração da rede

A arquitetura de rede utilizada neste trabalho foi a do tipo *feedforward* com camadas múltiplas. Redes pertencentes a esta arquitetura são constituídas pela presença de uma ou mais camadas escondidas de neurônios, como ilustrado na Figura 11, e são frequentemente empregadas em soluções de problemas relacionados à aproximação de funções, reconhecimento de padrões, identificação e otimização de sistemas (DA SILVA; SPATTI; FLAUZINO, 2010).



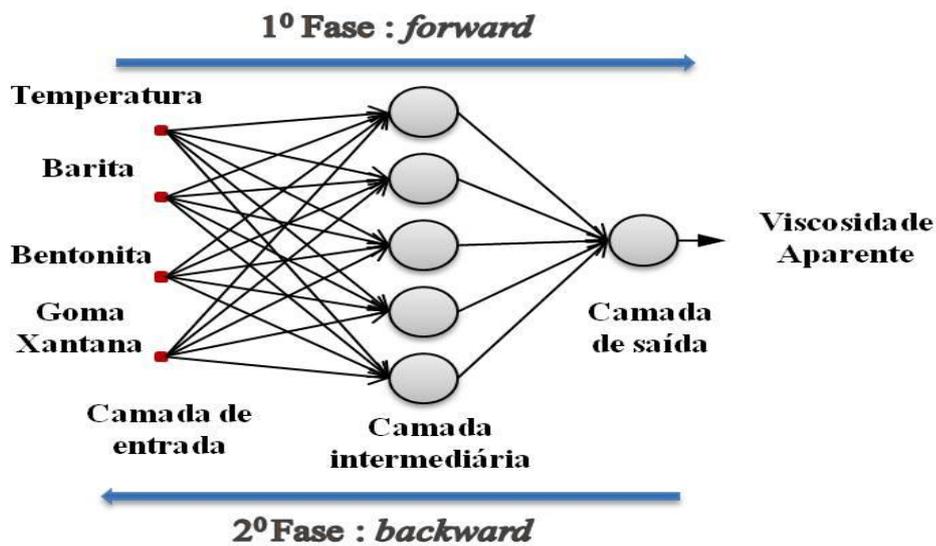
**Figura 11.** Exemplo de rede *feedforward* de camadas múltiplas.

Dentre as redes com arquiteturas do tipo *feedforward*, foi selecionada a rede MLP (*Multilayer Perceptron*) com apenas uma camada intermediária como paradigma neuronal utilizado nesta dissertação. Foram investigadas redes com 5 a 15 neurônios na camada intermediária, ativados por funções de tangente hiperbólica, equação (3.5). Para representar a viscosidade aparente dos fluidos de perfuração foi utilizado um neurônio linear na camada neuronal de saída.

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (3.5)$$

### 3.4.3 Treinamento da rede neuronal

O processo de treinamento das redes MLP foi efetuado utilizando o algoritmo *backpropagation*. Este treinamento ocorre em duas fases, *forward* e *backward*. Na primeira fase, *forward*, os sinais da amostra do conjunto de treinamento são inseridos nas redes e propagados camada a camada até a produção das respectivas saídas, Figura 12. A aplicação desta fase visa à obtenção das respostas da rede, levando-se em consideração apenas os valores atuais de pesos sinápticos e limiares dos neurônios, os quais permanecem inalterados durante cada execução desta fase. Na fase seguinte, *backward*, os valores de erros são retropropagados e os parâmetros dos neurônios ajustados (DA SILVA; SPATTI; FLAUZINO, 2010).



**Figura 12.** Fluxo de processamento do algoritmo *backpropagation*.

A aplicação sucessiva dessas etapas faz com que os pesos sinápticos e os limiares dos neurônios (*biases*) se ajustem automaticamente em cada interação, implicando na gradativa diminuição da soma dos erros produzidos pelas respostas da rede frente àquelas desejadas.

Para medir o desempenho local, associado aos resultados produzidos pelos neurônios de saída, utilizou-se a função erro quadrático, descrito na equação (3.6).

$$E^p = \frac{1}{2} \sum_{i=1}^n (d_i^p - y_i^p)^2 \quad (3.6)$$

onde  $E^p$  representa o erro quadrático para o padrão  $p$  apresentado a rede,  $y_i^p$  a resposta obtida pela rede e  $d_i^p$  a resposta desejada.

Com o objetivo de avaliar a evolução do desempenho global do algoritmo *backpropagation*, para um conjunto de treinamento com  $N$  amostras, utilizou-se o erro quadrático médio dado pela equação (3.7).

$$E_{QM} = \frac{1}{N} \sum_{p=1}^N E^p \quad (3.7)$$

A etapa treinamento da rede MLP foi realizada utilizando-se o método de otimização de Levenberg-Marquardt a fim de potencializar a eficiência do algoritmo *backpropagation*. Enquanto o algoritmo *backpropagation* é um método de descida no gradiente da função erro quadrático a fim de minimizá-la, o algoritmo de Levenberg-Marquardt é uma aproximação de Newton. Com isso, o treinamento das redes MLP são na ordem de 10 a 100 vezes mais rápidos que o algoritmo *backpropagation* convencional (DA SILVA; SPATTI; FLAUZINO, 2010).

Neste trabalho, foi utilizado o ambiente de programação MATLAB, versão 2007, para a identificação dos modelos neuronais e as rotinas foram desenvolvidas por MELEIRO (2002a). Como critério de parada do algoritmo de treinamento foi adotado a norma Euclidiana da estimativa do vetor gradiente com uma tolerância igual a  $10^{-5}$ .

### 3.5 Modelo Empírico de Liu

Na seção 2.3, foram destacados alguns modelos matemáticos utilizados na predição da viscosidade de fluidos contendo sólidos em suspensão. Equações que estabelecem relações entre a fração volumétrica de sólidos,  $\phi_p$ , fração volumétrica máxima de sólidos,  $\phi_m$ , e a viscosidade relativa (razão entre a viscosidade efetiva do fluido,  $\mu_{eff}$ , e a viscosidade do meio dispersante,  $\mu_0$ ).

Segundo Desoarkar e Sathe (2011), dentre os modelos citados na Tabela 2, o modelo de Liu apresentou melhores resultados na estimativa da viscosidade relativa de fluidos contendo CMC (carboximetilcelulose) e sólidos de magnetita, materiais que atuam como viscosificante e adensante nos fluidos de perfuração. Dessa forma, utilizou-se neste trabalho o modelo proposto por Liu, descrito na equação (3.8), para predizer a viscosidade aparente dos fluidos de perfuração à base água e comparar com as estimativas do modelo neuronal.

$$\frac{\mu_{eff}}{\mu_0} = a(\phi_m - \phi_p)^{-n} \quad (3.8)$$

Para que fosse possível estabelecer a comparação entre os modelos, novos fluidos foram preparados segundo as especificações da Tabela 7. Os níveis de goma xantana e de bentonita foram mantidos constantes, pois os fluidos formados por esses componentes foram utilizados como meio dispersante para as diferentes concentrações de barita. Como o modelo de Liu não é dependente da temperatura, as medidas de viscosidade foram realizadas na temperatura fixa de 40 °C e na velocidade de 300 rpm.

Os níveis de barita representam a concentração volumétrica de sólidos, sendo assim, para o desenvolvimento do modelo foram determinadas as frações de sólidos correspondentes pelo uso de uma proveta. Foram medidos os volumes de fluido do meio dispersante,  $V_f$ , e o

volume total,  $V_T$ , após a adição de barita, para a determinação do volume de sólidos,  $V_S$ , do meio. Com esses dados, a fração volumétrica de sólidos foi determinada de acordo com a equação (3.9).

$$\phi_P = \frac{V_S}{V_T} = \frac{V_T - V_f}{V_T} \quad (3.9)$$

**Tabela 7.** Malha experimental com apenas variação da concentração de sólidos.

Experimento	Goma xantana	Bentonita	Barita
1	0	0	-1
2	0	0	-0,75
3	0	0	-0,25
4	0	0	0
5	0	0	0,25
6	0	0	0,75
7	0	0	1

Para a especificação do modelo, determinou-se a fração volumétrica de sólidos máxima,  $\phi_m$ , parâmetro que representa o máximo de sólidos presentes na suspensão em que o fluido se comporta como um sólido. A metodologia utilizada na determinação deste parâmetro foi a mesma apresentada por Desoarkar e Sathe (2011), onde os dados de viscosidade e fração volumétrica são ajustados pela relação linear dada pela equação (3.10).

$$1 - \left( \frac{\mu_{eff}}{\mu_0} \right)^{-0,5} = b_1 \cdot \phi_P + b_0 \quad (3.10)$$

Após o ajuste, aplicou-se a condição limite em que o fluido tende à viscosidade do sólido e, dessa forma, determinou-se a fração volumétrica de sólidos máxima conforme a equação (3.12). Para a completa determinação do modelo de Liu, as constantes  $a$  e  $n$  foram determinadas a partir de uma segunda linearização da equação (3.8).

$$\phi_m = \frac{1 - b_0}{b_1} \quad (3.11)$$

## 4. RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados e discutidos o comportamento reológico dos fluidos preparados e a influência de cada aditivo sobre a viscosidade aparente. Apresentam-se também os resultados dos procedimentos de identificação dos modelos neuronal, estatístico e empírico, assim como o desempenho de cada modelo na tarefa de estimar a viscosidade aparente dos fluidos preparados. Ao final, é feita uma comparação entre a capacidade de predição dos três modelos identificados.

### 4.1 Caracterização Reológica

Pelo planejamento preliminar, descrito na seção 3.2, utilizou-se o viscosímetro FANN 35A em 12 velocidades e, com isso, foram construídas as curvas reológicas de cada fluido de perfuração na temperatura de 22 °C, temperatura ambiente do laboratório. Na Figura 13 são apresentadas as curvas de fluxo dos fluidos com concentrações codificadas nos níveis baixo (-1), médio (0) e alto (+1) para todos os aditivos.

Através da curva de fluxo (Figura 13), foi observado que os fluidos de perfuração preparados apresentam características de fluido pseudoplástico, com limite de escoamento, ou seja, a viscosidade diminui com o aumento da taxa de deformação a partir de uma tensão mínima. Os dados obtidos experimentalmente foram ajustados ao modelo Herschell-Buckley, descrito na equação (2.4), através do *software OriginPro*<sup>®</sup>, versão 8.5. Esse modelo foi escolhido, pois, conforme discutido na seção 2.2.3, representam fluidos que apresentam esse tipo de comportamento.

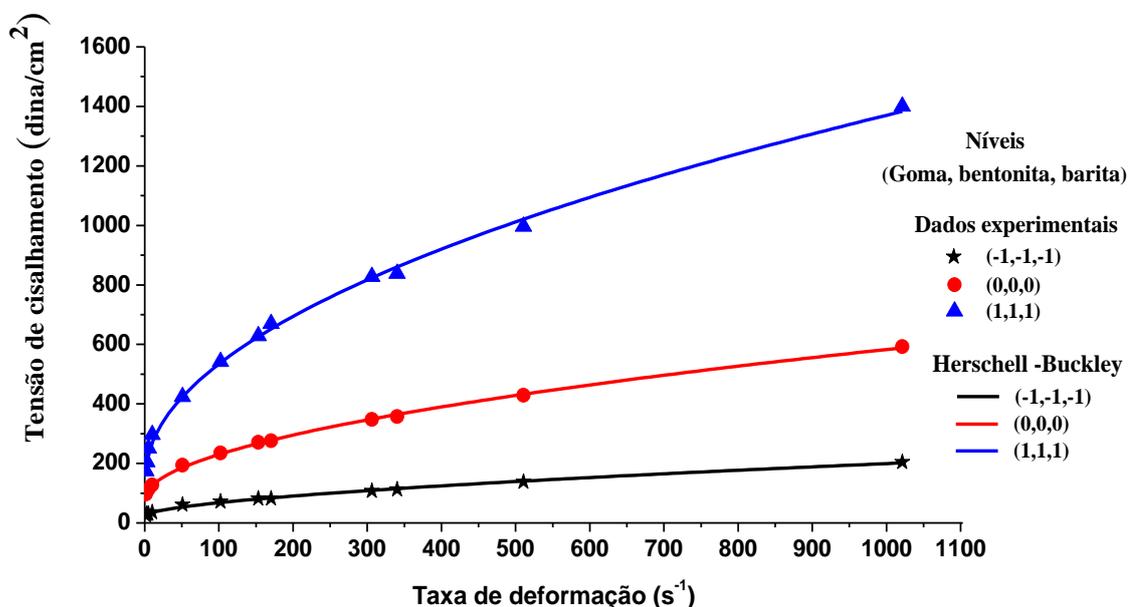


Figura 13. Curva de fluxo dos fluidos de perfuração.

Pela Figura 13, observou-se que os modelos foram capazes de descrever adequadamente o comportamento desses fluidos. Foram aplicados os mesmos procedimentos aos outros fluidos obtidos através do planejamento e se observou que todos apresentaram o

mesmo comportamento reológico. No Anexo A são apresentados os ângulos de deflexão do viscosímetro, as curvas de fluxo, os parâmetros e os coeficientes de determinação encontrados para o modelo de Herschell-Buckley aplicados a todos os fluidos deste planejamento.

Na Tabela 8 são apresentados os parâmetros dos modelos e os coeficientes de determinação ( $R^2$ ) encontrados.

**Tabela 8.** Parâmetros do modelo de Herschell-Buckley.

Níveis (Goma, Bentonita, Barita)	$n$ (adimensional)	$K$ (dina.cm <sup>-2</sup> .s <sup>n</sup> )	$\tau_0$ (dina.cm <sup>-2</sup> )	$R^2$
(-1,-1,-1)	0,614	2,501	25,522	0,995
( 0, 0, 0)	0,535	12,351	84,799	0,999
( 1, 1, 1)	0,502	38,138	149,865	0,997

## 4.2 Influência dos Aditivos na Viscosidade Aparente

O planejamento preliminar foi proposto para averiguar a influência dos aditivos na viscosidade aparente e, com isso, determinar quais variáveis são significantes na identificação do modelo neuronal. Para isso, aplicou-se o teste ANOVA ao conjunto de dados de viscosidade obtidos a 300 rpm.

Inicialmente os dados foram ajustados ao modelo de 2ª ordem (equação 3.2) com o objetivo de obter informações preliminares sobre o comportamento das variáveis na viscosidade dos fluidos. Através do teste ANOVA, determinam-se os parâmetros lineares, quadráticos e de interação do modelo com significância estatística na predição da viscosidade.

Os resultados do teste, apresentados na Tabela 9, foram obtidos com um nível de significância igual a 0,05 no *Statistica*®. Observou-se que os parâmetros encontrados possuem p-valor menor que o nível de significância, indicando que a hipótese nula foi rejeitada e, portanto, estes parâmetros são significantes na estimação da viscosidade. O modelo obtido com o teste apresentou coeficiente de correlação,  $R^2$ , igual a 0,9796, o que mostra bons ajustes aos 30 dados experimentais.

**Tabela 9.** Resultados do teste de análise de variância.

Fonte de Variação	Soma dos quadrados	Graus de liberdade	Média Quadrada	$F_0$	p-valor
Gx (L)	29443,56	1	29443,56	201,10	0,000
Bt(L)	3872,00	1	3872,00	26,44	0,000
Br (L)	14000,22	1	14000,22	95,62	0,000
Gx (L) x Bt (L)	1752,08	1	1752,08	11,96	0,002
Gx (Q) x Br (L)	802,78	1	802,78	5,48	0,028

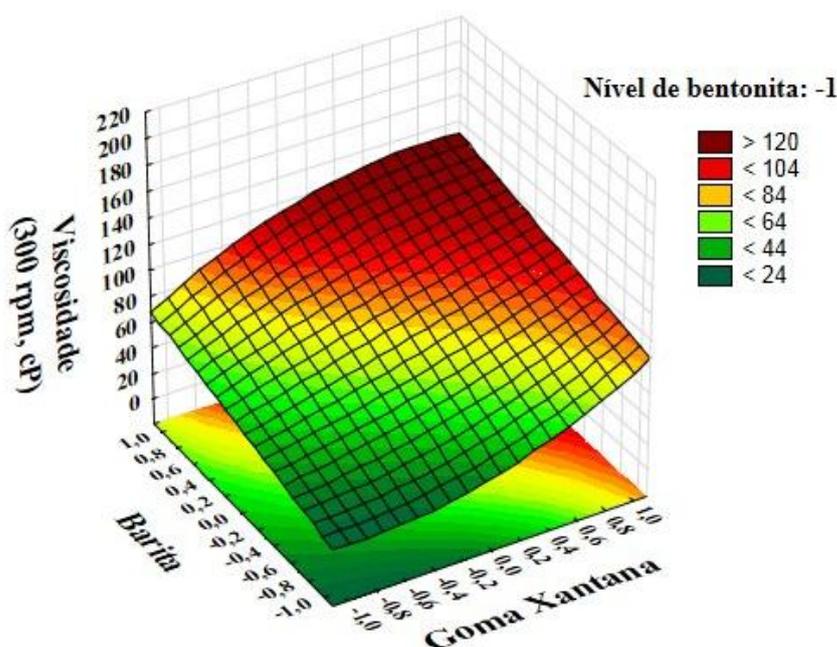
Na Tabela 10 são apresentados os valores e o desvio padrão de cada parâmetro do modelo. Com o teste ANOVA, observou-se que os parâmetros que representam os aditivos

são significantes na estimação da viscosidade aparente e, com isso, conclui-se que nenhum deles pode ser retirado na identificação do modelo neuronal.

**Tabela 10.** Coeficientes de regressão para o modelo do planejamento preliminar.

Variável	Coefficiente de Regressão	Desvio padrão
Média	91,90	2,21
Gx (L)	40,44	2,85
Bt(L)	14,66	2,85
Br (L)	37,33	4,94
Gx (L) x Bt (L)	12,08	3,49
Gx (Q) x Br (L)	-14,16	6,05

A fim de avaliar a linearidade do sistema, foi construída a superfície de contorno no nível mínimo de bentonita (Figura 14), onde se observou a presença de curvatura nesse sistema.



**Figura 14.** Superfície de contorno para o nível mínimo de bentonita.

Para ilustrar o comportamento da viscosidade nos diferentes níveis de aditivos, foi construído o gráfico das médias marginais, ilustrado na Figura 15. Esses gráficos mostram os efeitos cruzados proporcionados pela adição dos componentes na viscosidade aparente, além de fornecerem uma ideia do comportamento das superfícies de contorno. Através da Figura 15, observou-se que a viscosidade aparente apresenta comportamento complexo e regiões de curvatura em diferentes combinações de aditivos. Por esse motivo, o modelo neuronal foi

escolhido para buscar o relacionamento funcional da viscosidade aparente com a concentração dos aditivos e a temperatura.

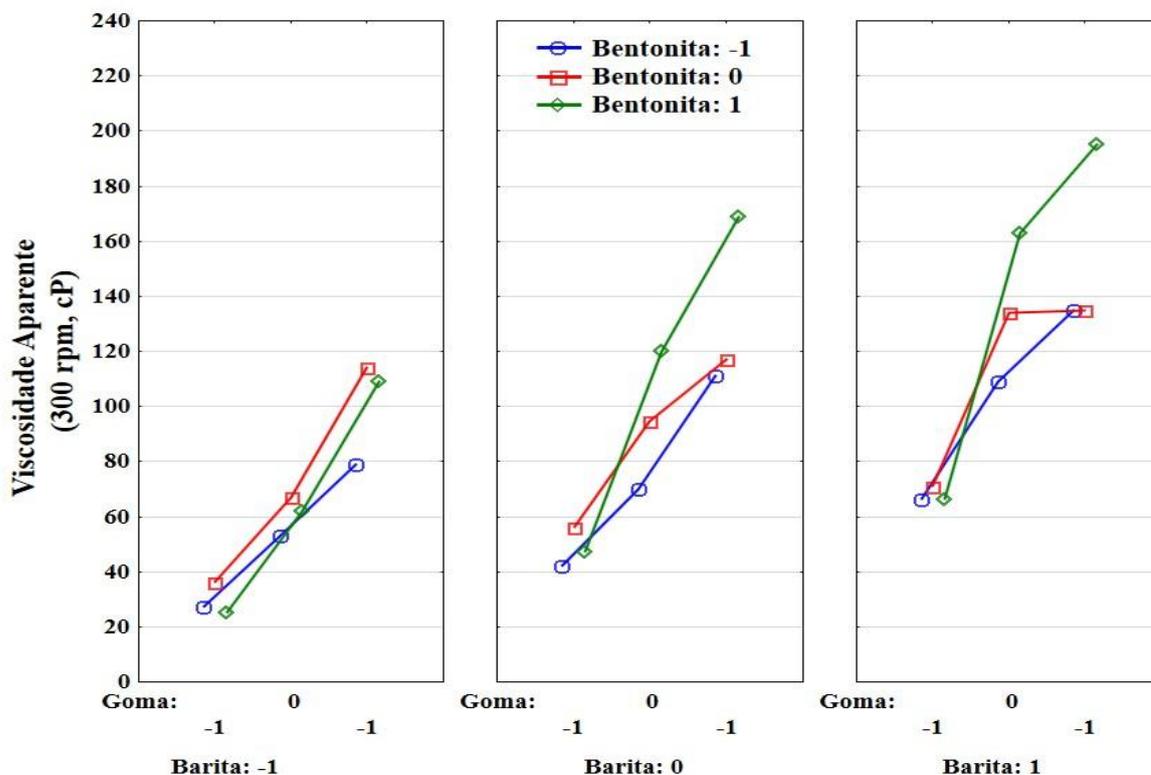


Figura 15. Gráfico das médias marginais.

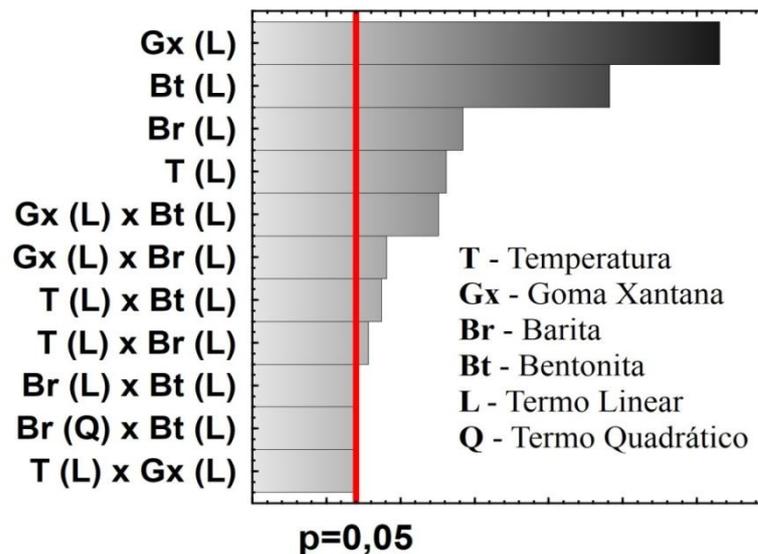
### 4.3 Identificação do Modelo Estatístico

Foram preparados 84 fluidos e determinadas as viscosidades na velocidade de 300 rpm em três níveis de temperatura, como foi descrito na seção 3.2.1. Os dados de viscosidade do planejamento, apresentados no Anexo B, foram ajustados pelo modelo de 2ª ordem, equação (3.2). Os parâmetros do modelo e sua influência na viscosidade foram avaliados pelo teste ANOVA com nível de significância de 5%. Inicialmente, o teste foi aplicado ao modelo contendo todos os parâmetros lineares, de interação e quadráticos de cada variável. Diversas eliminações foram realizadas até a obtenção do modelo de regressão com apenas parâmetros significativos na predição da viscosidade. Na Tabela 11 são listados os valores dos parâmetros e o desvio padrão encontrado para cada variável do modelo reduzido.

Para avaliar o efeito de cada variável do modelo foi construído o diagrama de Pareto, ilustrado na Figura 16. Os efeitos de cada parâmetro são calculados pelo teste de t-Student e mostrados em ordem decrescente nesse gráfico. Observou-se que os efeitos das variáveis encontradas para o modelo reduzido são significantes, com p-valor maior que o nível estabelecido, como já era esperado pelo resultado do teste ANOVA (Tabela 11). Através desse gráfico, verificou-se que todas as variáveis do planejamento contribuem na viscosidade aparente e que os efeitos predominantes são provenientes de termos lineares e de interação.

**Tabela 11.** Coeficientes de regressão do modelo estatístico.

Variáveis	Coeficiente de Regressão	Desvio padrão
<b>Média</b>	82,56	1,20
<b>T (L)</b>	-12,15	1,50
<b>Gx (L)</b>	39,87	1,50
<b>Br (L)</b>	13,83	1,50
<b>Bt (L)</b>	33,17	2,60
<b>T (L) x Gx (L)</b>	-3,81	1,84
<b>T (L) x Br (L)</b>	-5,25	1,84
<b>T (L) x Bt (L)</b>	-6,83	1,84
<b>Gx (L) x Br (L)</b>	7,50	1,84
<b>Gx (L) x Bt (L)</b>	13,92	1,84
<b>Br (L) x Bt (L)</b>	3,97	1,84
<b>Br (Q) x Bt (L)</b>	-6,70	3,19



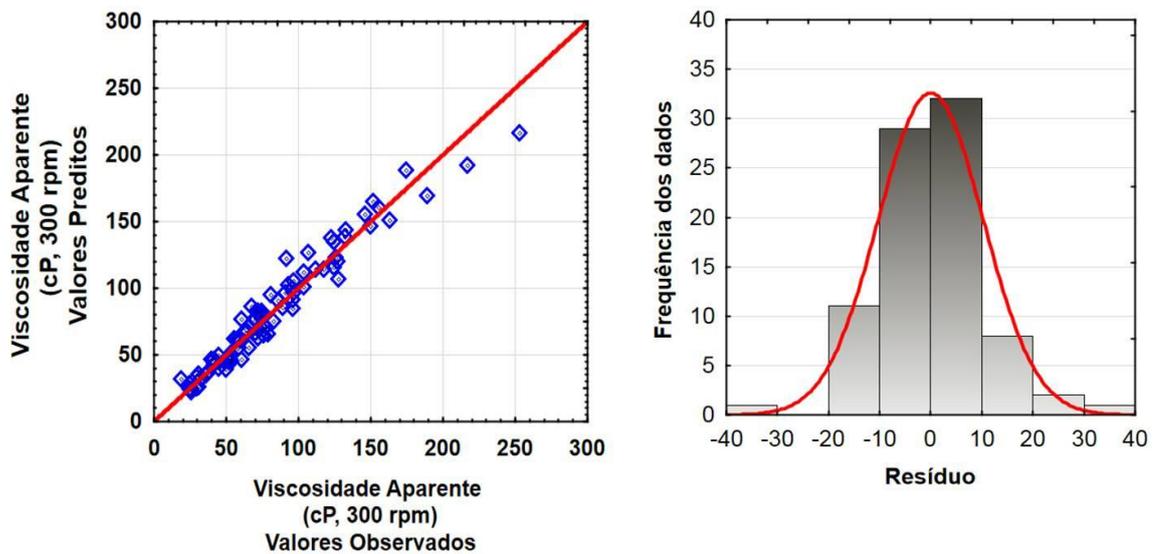
**Figura 16.** Parâmetros significativos do modelo de regressão.

Durante o preparo do fluido, observou-se que a goma xantana foi o componente que mais alterava a viscosidade, mesmo quando empregada em baixas concentrações. Com isso, o resultado obtido no diagrama para principal variável do modelo, goma xantana, apresentou resultado coerente com o observado experimentalmente. A bentonita também possui a função de elevar a viscosidade do fluido, porém, o aumento promovido, mesmo em altas concentrações, não foi tão pronunciado quando comparado com a goma xantana. Assim, a comparação estatística foi condizente com o observado experimentalmente para os parâmetros lineares que representam os viscosificantes.

Experimentalmente, verificou-se também que, após a mistura da goma xantana e bentonita, o acréscimo de barita eleva a viscosidade devido ao aumento de sólidos em suspensão nos fluidos, sendo assim, uma variável importante ao modelo. Observou-se também que o aumento da temperatura diminui a viscosidade do fluido e, por isso, essa variável é essencial para qualquer modelo que avalie a reologia.

Dessa forma, os efeitos dos parâmetros lineares mostrados no diagrama são coerentes experimentalmente, mostrando que a análise dos efeitos pode ser uma boa ferramenta para avaliar as variáveis do processo. Os efeitos de interação são mais difíceis de tratar, pois os fluidos apresentam comportamento complexo associado à característica de cada componente. Portanto, o diagrama de Pareto fornece informações importantes sobre quais variáveis exercem efeito significativo sobre a viscosidade dos fluidos de perfuração à base de água preparados neste trabalho.

O modelo de regressão encontrado apresentou um coeficiente de determinação ( $R^2$ ) igual a 0,949. Através desse coeficiente e de acordo com o histograma do resíduo, representado na Figura 17, verificou-se que o modelo estatístico foi capaz de ajustar os dados experimentais com a maior parte dos erros absolutos compreendidos no intervalo de -10 a +10 cP.



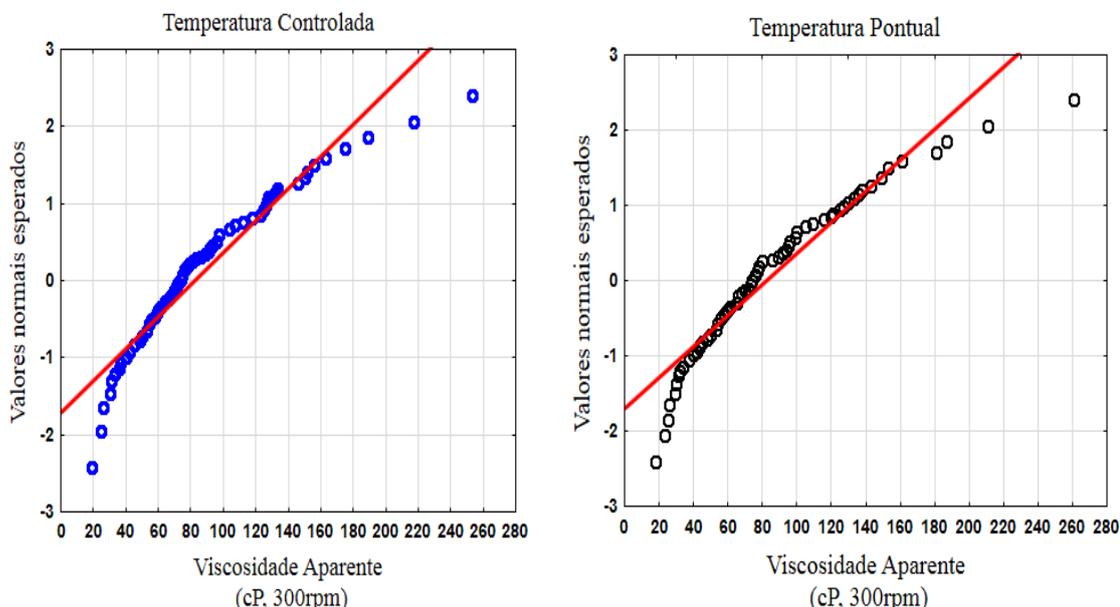
**Figura 17.** Ajuste do modelo estatístico aos dados experimentais.

#### 4.4 Validação da Metodologia Experimental

A fim de avaliar a metodologia empregada na obtenção dos dados de viscosidade para o treinamento da rede neuronal, foram realizados os testes de Kolmogorov-Smirnov e de Wilcoxon do posto sinalizado. Os testes foram realizados sobre os dados de viscosidade aparente determinados na etapa do planejamento (os 84 pontos) e que foram obtidos em duplicata, através da obtenção das temperaturas controlada e pontual.

O teste de Kolmogorov, com a correção de Lilliefors, foi aplicado a este conjunto de dados e verificou-se que os dados dos dois conjuntos não possuem distribuição normal, pois o p-valor encontrado foi igual a 0,01, menor do que o nível de significância adotado. Essa análise foi confirmada através da construção da curva de probabilidade normal, padronizada

com média zero e desvio padrão igual a 1, ilustrada na Figura 18. Através da análise desta figura, observou-se que os dados experimentais não se ajustaram aos valores normais, representada pela linha destacada em vermelho, e, com isso, confirmou-se que os dados não possuem normalidade.

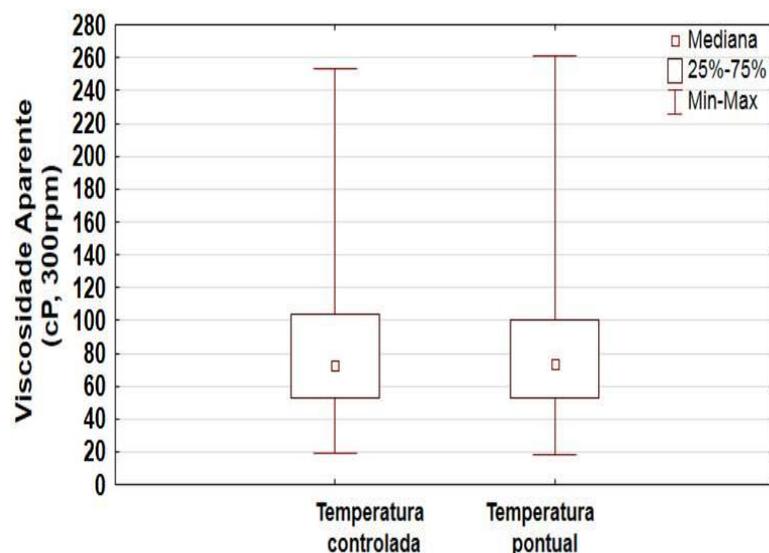


**Figura 18.** Ajuste dos dados pelo gráfico de probabilidade normal.

A partir do resultado do teste de normalidade, observou-se que os dados obtidos em duplicata não apresentam distribuição normal e, dessa forma, para avaliar se as medidas são equivalentes foi adotado o teste não paramétrico de Wilcoxon. Esse teste avalia se a diferença entre as medianas de duas populações podem ser consideradas iguais. A mediana, assim como a média, são medidas de tendência central de um conjunto de dados e partir desses parâmetros comparam-se diferentes populações. O teste foi realizado sobre o conjunto de dados de viscosidade obtidos nas temperaturas pontual e controlada. Através do *Statistica*<sup>®</sup> foi obtido um p-valor igual a 0,921, indicando que as medianas das duas populações são equivalentes estatisticamente e, portanto, os dados apresentam distribuições semelhantes.

O gráfico de caixa, representado na Figura 19, mostra que a diferença entre as medianas é realmente pouco significativa, confirmando o resultado do teste. Com o teste de Wilcoxon do posto sinalizado, verificou-se que as medidas realizadas sem o controle da temperatura são equivalentes àquelas obtidas quando o fluido alcançava o equilíbrio térmico. Dessa forma, considerou-se que as leituras de viscosidade realizadas durante o aquecimento (no intervalo entre os pontos do planejamento) seriam equivalentes caso a temperatura fosse controlada.

Dessa forma, os 1017 dados de viscosidade obtidos a partir da leitura de valores intermediários de temperatura entre os 84 pontos fornecidos pelo planejamento experimental puderam ser utilizados com segurança para o treinamento e validação da rede neuronal.



**Figura 19.** Gráfico de caixa para a mediana.

## 4.5 Identificação do Modelo Neuronal

Para identificação da rede neuronal foram testadas diferentes topologias, conforme foi discutido na seção 3.4. Para a determinação da topologia ótima foi analisada a variação do erro quadrático médio desnormalizado para a variável de interesse, a viscosidade aparente, em função do número de neurônios na camada intermediária das redes testadas.

Pela análise da Figura 20, foi observado que o aumento do número de neurônios durante a fase de treinamento fez com que a rede apresentasse baixos valores de erro quadrático na etapa de validação, condição conhecida como sobre-treinamento ou *overfitting*. Nessa situação, as redes acabam memorizando as respostas do conjunto de dados de treinamento e perdem a capacidade de generalização. Assim, para a escolha da melhor topologia, avaliou-se o erro quadrático médio obtido durante a etapa de validação da rede. Através da figura abaixo, observou-se que a rede com melhores previsões possui seis neurônios na camada intermediária com erro quadrático médio igual a 7,73 cP<sup>2</sup>.

Normalmente as redes neuronais apresentam erros maiores na etapa de validação, justamente por serem apresentados dados diferentes daqueles usados no treinamento. Entretanto, conforme verificado na Figura 20, o conjunto de dados de validação apresentou erros bem menores do que o conjunto de dados de treinamento. Para justificar este comportamento, foi construído o histograma de frequência dos dois conjuntos de dados de viscosidade apresentados à rede (Figura 21). Nota-se, pela figura, que os dados de validação estão localizados em uma região mais estreita quando comparado com o conjunto de dados de treinamento, configurando-se como um sub-conjunto deste último, fato que possivelmente explica os baixos valores de erro quadrático médio para as amostras de validação.

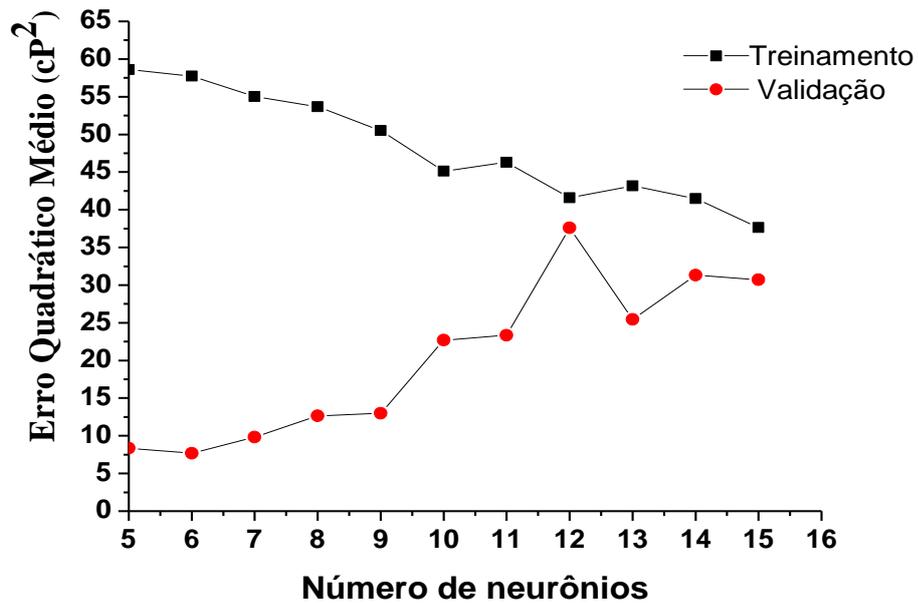


Figura 20. Erro quadrático médio pelo número de neurônios.

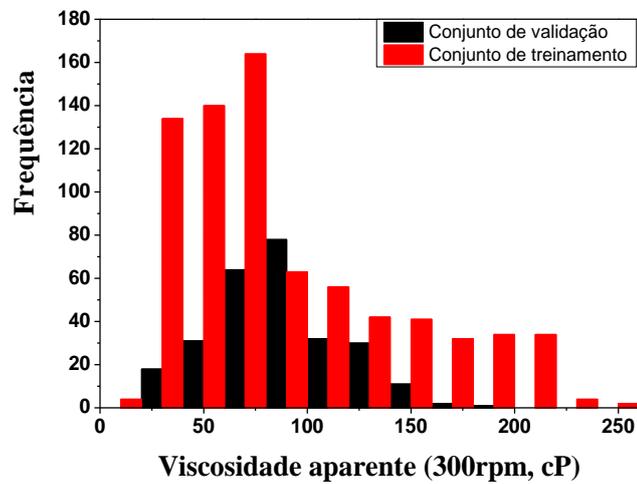
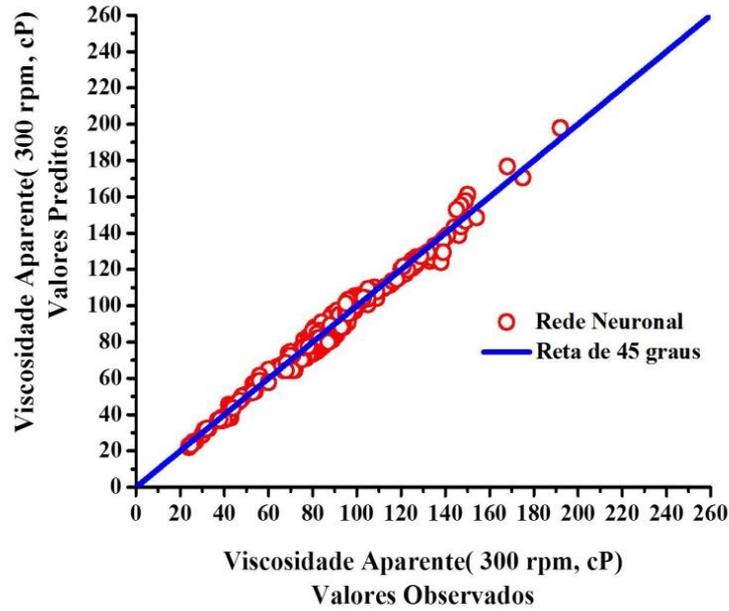
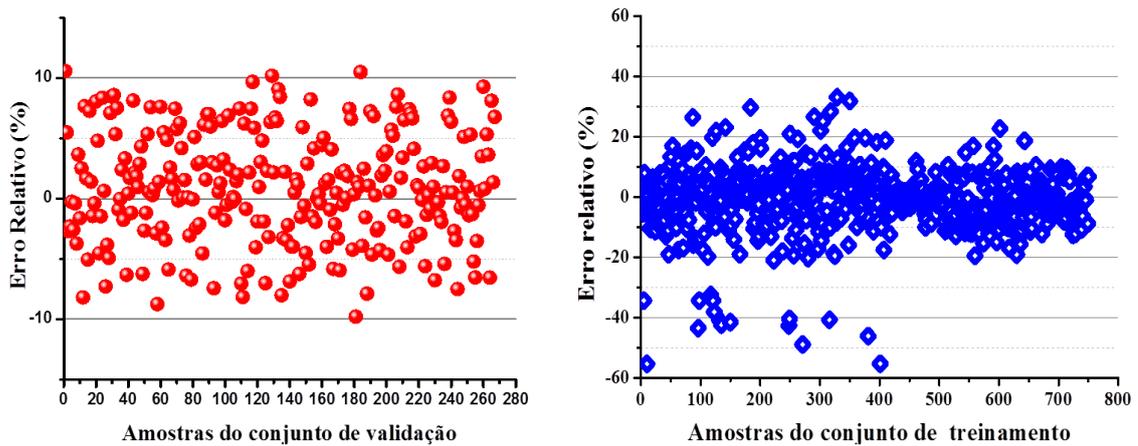


Figura 21. Distribuição dos dados de treinamento e validação.

Pelas Figuras 22 e 23, concluiu-se que a rede neuronal com seis neurônios na camada intermediária obteve bom desempenho, apresentando erros relativos menores do que 10% para o conjunto de validação enquanto para os dados de treinamento a maior parte ficou compreendida em 20%.



**Figura 22.** Predição dos dados de validação com a rede com 6 neurônios.



**Figura 23.** Erros relativos da rede neuronal.

#### 4.6 Identificação do Modelo de Liu

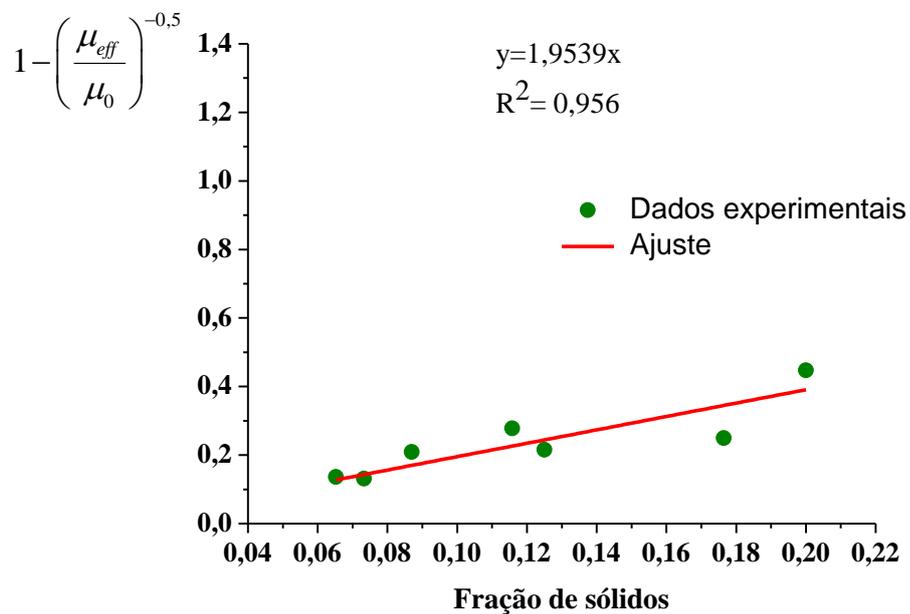
Com o propósito de avaliar a predição da viscosidade aparente pelo modelo de Liu foram realizados experimentos com fluidos contendo diferentes concentrações de barita, como discutido na seção 3.5 Para isso, foi determinada a fração volumétrica de barita,  $\phi_p$ , a viscosidade do meio dispersante,  $\mu_0$ , constituído de goma xantana e bentonita, e a viscosidade aparente de cada fluido,  $\mu_{eff}$ , na temperatura de 40<sup>0</sup>C. Nesses experimentos foi encontrada a viscosidade de 40 cP para o fluido base, meio dispersante, e os outros resultados são apresentados na Tabela 12.

Para a especificação do modelo empírico de Liu foram determinadas a fração volumétrica máxima de sólidos e as constantes  $a$  e  $n$ . A fração volumétrica máxima foi

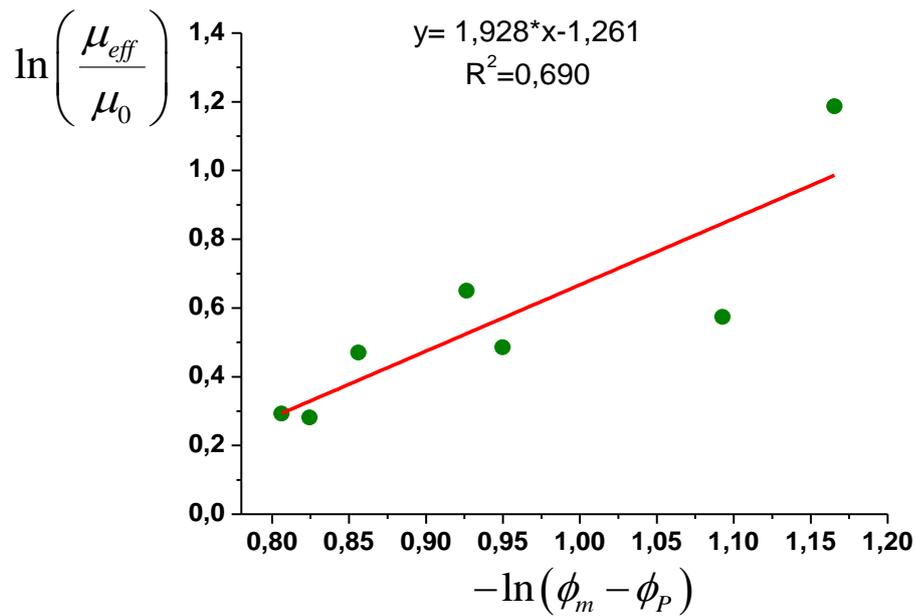
determinada através do ajuste da equação aos dados, conforme ilustrado na Figura 24. A partir dessa equação foi encontrado o valor de 0,512 para a fração volumétrica máxima de sólidos. As constantes,  $a$  e  $n$ , foram determinadas através da linearização do modelo de Liu, apresentada na equação (3.9), e pelo ajuste da melhor reta aos dados, conforme ilustrado na Figura 25. Com isso, foram encontrados os valores de 1,923 e 1,928 para os parâmetros  $a$  e  $n$ , respectivamente.

**Tabela 12.** Fração volumétrica de sólidos e viscosidade aparente dos fluidos a 40 °C

Goma Xantana	Bentonita	Barita	Fração volumétrica	Viscosidade Aparente (cP, 300 rpm)
0	0	-1	0,065	54
0	0	-0,75	0,073	53
0	0	-0,25	0,087	64
0	0	0	0,116	77
0	0	0,25	0,125	65
0	0	0,75	0,176	71
0	0	1	0,200	131

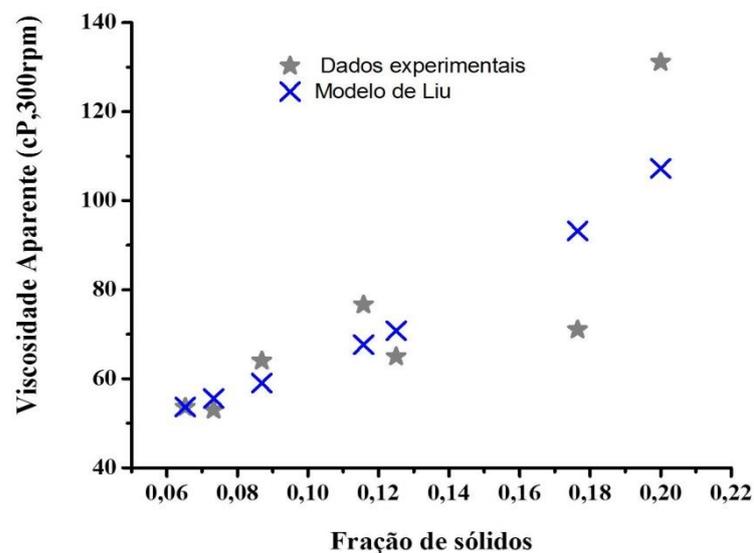


**Figura 24.** Ajuste para a determinação da fração volumétrica máxima de sólidos.



**Figura 25.** Ajuste para a determinação dos parâmetros do modelo de Liu.

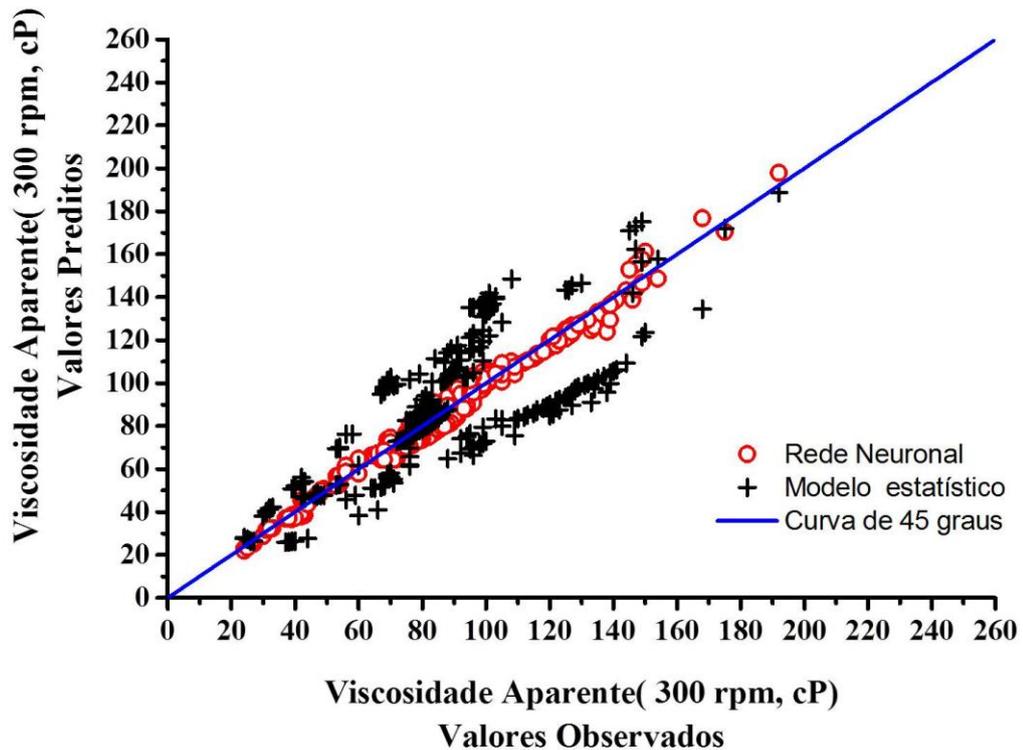
De acordo com a Figura 26, observou-se que o modelo de Liu identificado neste trabalho foi capaz de prever a viscosidade aparente dos fluidos em boa parte das concentrações de barita. No entanto, o modelo divergiu a partir da fração volumétrica igual a 0,125, valor que corresponde à concentração de 0,85 kg/L, fato que indica que o modelo representa bem apenas misturas diluídas.



**Figura 26.** Predição da viscosidade aparente pelo modelo de Liu.

## 4.7 Comparação dos Modelos

Os dados utilizados na validação da rede também foram empregados ao modelo estatístico (discutido na seção 4.3) para avaliar a sua adequação aos dados experimentais e comparar com os resultados do modelo neuronal. A comparação dos modelos foi realizada através da construção do gráfico de viscosidade predita por cada modelo versus o valor determinado experimentalmente e o resultado é apresentado na Figura 27.



**Figura 27.** Comparação entre os modelos estatístico e neuronal.

Foi observado que o modelo estatístico não possui boa capacidade de predição quando são empregados dados diferentes dos 84 utilizados em sua identificação. O modelo de regressão estatístico apresentou o erro quadrático médio igual a 228,09 cP<sup>2</sup>, valor extremamente alto quando comparado com o valor de 7,73 cP<sup>2</sup> obtido pelo modelo neuronal. Dessa forma, o modelo neuronal com seis neurônios na camada intermediária apresentou desempenho bastante superior na predição da viscosidade aparente dos fluidos quando comparado ao modelo estatístico.

Como discutido na seção 3.5, foram realizados experimentos para avaliar a capacidade de extrapolação da rede neuronal em diferentes concentrações de barita. Os dados de entrada utilizados foram os mesmos empregados na determinação do modelo de Liu e, com isso, também foi possível comparar os modelos neuronal e empírico. As Figuras 28 e 29 mostram os resultados obtidos na predição da viscosidade aparente e os erros relativos encontrados para cada modelo.

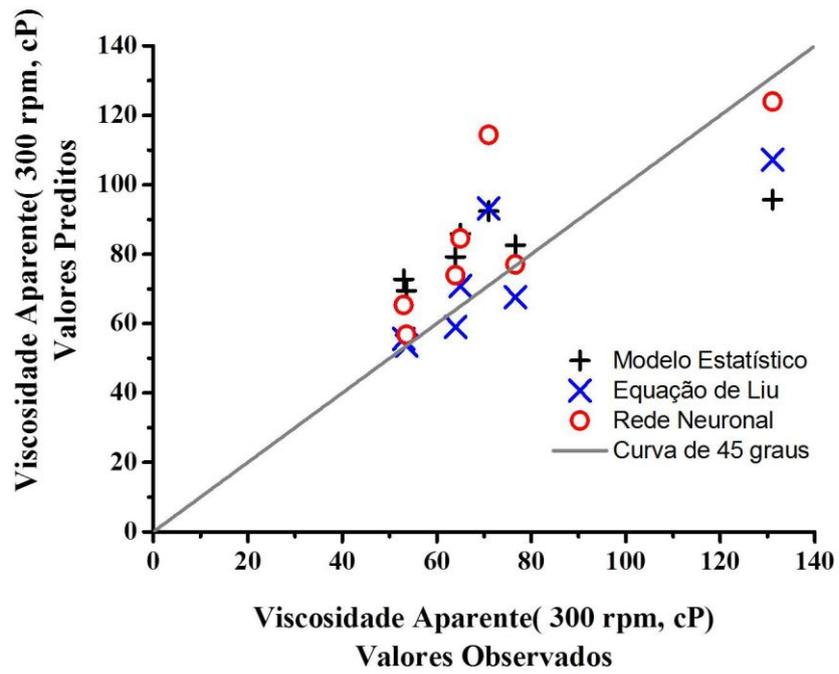


Figura 28. Dados experimentais versus previsões fornecidas pelos modelos testados.

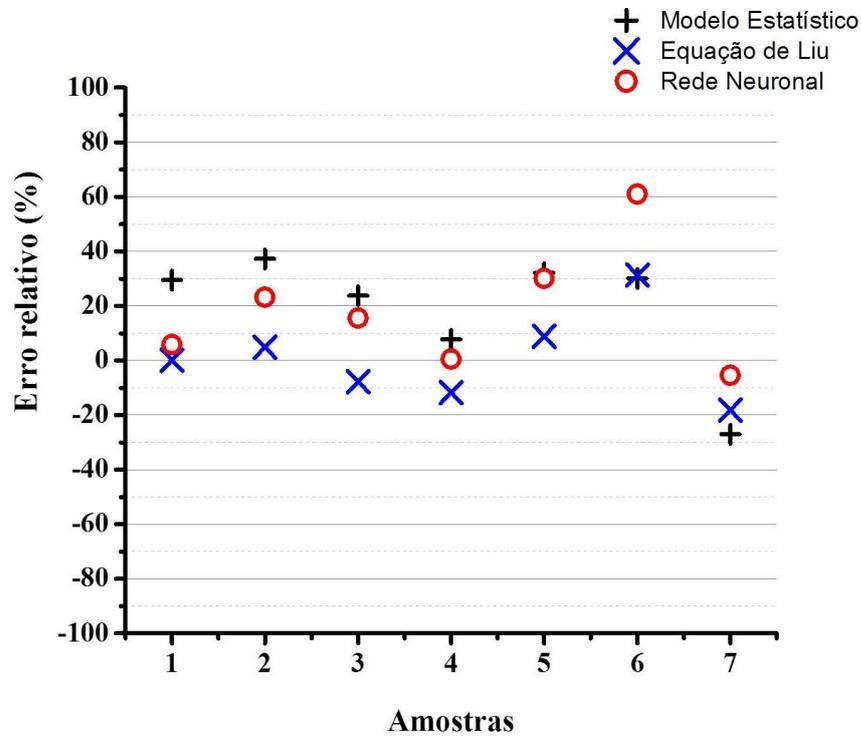


Figura 29. Erros relativos dos modelos.

Através da análise da Figura 29, observou-se que o modelo estatístico apresentou a maior parte dos erros acima de 20%, enquanto a rede neuronal e o modelo de Liu obtiveram melhores resultados. Porém, notou-se que o modelo neuronal exibiu desvios acima de 30 % e não apresentou uma distribuição dos erros ao redor de zero, indicando que o modelo apresenta falhas na estimação da viscosidade.

Através do Quadro 5, verificou-se que os maiores desvios são relativos aos fluidos contendo níveis de barita diferentes daqueles apresentados a rede no processo de treinamento, o que confirma a deficiência do modelo neuronal para realizar boas extrapolações.

**Quadro 5.** Resultados obtidos para os fluidos contendo goma xantana e bentonita fixados no nível central.

Amostras	Barita	Fração de sólidos	Viscosidade Aparente Experimental (cP, 300 rpm)	Modelo Neuronal		Modelo de Liu	
				Viscosidade Aparente	Erro relativo (%)	Viscosidade Aparente	Erro relativo (%)
1	-1,00	0,065	54	56,73	5,84	53,65	0,09
2	-0,75	0,073	53	65,30	23,21	55,56	4,84
3	-0,25	0,087	64	73,91	15,50	59,06	-7,71
4	0,00	0,116	77	76,98	0,46	67,63	-11,74
5	0,25	0,125	65	84,53	30,06	70,77	8,88
6	0,75	0,176	71	114,31	61,01	93,20	31,27
7	1,00	0,200	131	123,96	-5,42	107,24	-18,19

Dos modelos testados, o modelo de Liu foi o que obteve melhores resultados neste novo conjunto de dados, apresentando desvios ao redor de 20%. Contudo, ainda que o modelo de Liu tenha fornecido bons resultados, a comparação com os modelos neuronal e estatístico não é muito adequada, pois aquele modelo utiliza informações diferentes destes. Para estimar a viscosidade, o modelo de Liu utiliza como referência a viscosidade de um fluido e posteriores correções com a fração de sólidos. Além disso, trata-se de um modelo mais simples, que não leva em consideração a temperatura e variações nos outros componentes da formulação.



## 5. Conclusões

Um dos objetivos dessa dissertação foi desenvolver um sensor virtual baseado no modelo neuronal com a finalidade de estimar a viscosidade aparente de fluidos de perfuração à base água. O modelo neuronal foi escolhido por apresentar grande poder de adaptação e capacidade de representação não linear.

Antes da determinação do modelo neuronal foram aplicados métodos estatísticos para avaliar a importância da goma xantana, barita e bentonita na viscosidade aparente dos fluidos à base água. Foi observado que todos os aditivos proporcionam aumento na viscosidade aparente dos fluidos e que o relacionamento funcional entre essas variáveis apresenta regiões de não linearidade. Por esse motivo, o modelo neuronal *perceptron* multi-camadas foi utilizado para extrair o relacionamento funcional da viscosidade aparente dos fluidos em diferentes temperaturas e proporções dos seus componentes.

A temperatura dos fluidos também foi avaliada por ser uma variável constantemente monitorada e controlada nas sondas de perfuração. A partir da análise dos efeitos foi observado que esta variável é significativa para modelos que descrevem as propriedades reológicas dos fluidos. Através dos ensaios experimentais foi observado que o aumento da temperatura reduz a viscosidade dos fluidos analisados. Dessa forma, a temperatura e os aditivos foram utilizados como variáveis de entrada para a identificação do modelo neuronal.

Através de um planejamento de experimentos foram coletados dados suficientes para o treinamento e validação da rede neuronal. Esses dados foram analisados por métodos estatísticos para que fossem utilizados com relativa segurança na obtenção do modelo. Com esses experimentos, foi determinada que a melhor rede neuronal possui seis neurônios não lineares na camada intermediária e um linear na camada de saída, modelo que apresenta 37 parâmetros (pesos e *biases*).

Com intuito de avaliar a qualidade do modelo neuronal encontrado foi identificado um modelo linear estatístico que levou em consideração parâmetros lineares, quadráticos e de interação. As repostas dos modelos foram comparadas e observou-se que o modelo linear não forneceu boas previsões quando comparadas às do modelo neuronal.

A capacidade de extrapolação da rede foi avaliada através da estimação da viscosidade de fluidos com diferentes concentrações de barita na temperatura de 40 °C. Os resultados foram comparados com o modelo matemático de Liu e o modelo neuronal não forneceu resultados satisfatórios, enquanto o modelo de Liu forneceu boas estimativas para certa faixa de concentração. Isso se deve ao fato de que os parâmetros dos modelos foram determinados por diferentes conjuntos de dados e, dessa forma, a comparação entre eles não foi adequada. Sendo assim, para uma melhor avaliação da capacidade de extrapolação da rede e comparação dos modelos, os parâmetros dos modelos deveriam ter sido determinados utilizando um mesmo conjunto de dados.

## 6. BIBLIOGRAFIA

ACTION. **Técnicas Não Paramétricas**. Disponível em: <[http:// portalaction.com.br](http://portalaction.com.br)> . Acesso em: 12 nov. 2013.

AL-MARHOUN, M. A. *et al.* Prediction of crude oil viscosity curve using artificial intelligence techniques. **Journal of Petroleum Science and Engineering**, v. 86–87

AMINZADEH, F. *et al.* Estimation of reservoir parameter using a hybrid neural network. **Journal of Petroleum Science and Engineering**, v. 24, n. 1, p. 49-56, 1999.

AMORIM, L. V. **Melhoria, Proteção e Recuperação da Reologia de Fluidos Hidroargilosos para Uso na Perfuração de Poços de Petróleo**. 2003. 290 p. Tese (Doutorado em Engenharia e Processos). Centro de Ciências e Tecnologia, Universidade Federal de Campina Grande Campina Grande, PB.

AMORIM, L. V.; BARBOSA, M. I. R.; FERREIRA, H. C. Desenvolvimento de compostos bentonita/polímeros para aplicação em fluidos de perfuração: Parte 2. **Matéria (Rio de Janeiro)**, v. 13, p. 209-219, 2008.

AMORIM, L. V. *et al.* Comportamento reológico de dispersões de argilas bentoníticas: efeitos do tipo de ferramenta, velocidade e tempo de agitação. **Cerâmica**, v. 48, p. 234-238, 2002.

ARPAT, G. B.; GÜMRAH, F.; YETEN, B. The neighborhood approach to prediction of permeability from wireline logs and limited core plug analysis data using backpropagation artificial neural networks. **Journal of Petroleum Science and Engineering**, v. 20, n. 1–2, p. 1-8, 1998.

BARBOSA, M. I. R. **Bentonitas aditivas com polímeros para a aplicação em fluidos de perfuração**. 2006. 80 p. Dissertação (Mestrado em Engenharia de Materiais). Centro de Ciências e Tecnologia, Universidade Federal de Campina Grande

BARNES, H. A.; HUTTON, J. F.; WALTERS, K. **An Introduction to Rheology**. Elsevier, 1989.

BIRD, R. B.; STEWART, W. E; LIGHTFOOT, E. N. **Fenômenos de transporte**. Livros Técnicos e Científicos, 2004.

BOURGOYNE JR, A. T. *et al.* Applied drilling engineering. Volume 2. 1986.

BRAGA;, A. D. P.; LUDERMIR;, T. B.; CARVALHO, A. C. P. D. L. F. **Redes Neurais Artificiais: Teoria e aplicações**. LTC, 2000.

CAENN, R.; CHILLINGAR, G. V. Drilling fluids: State of the art. **Journal of Petroleum Science and Engineering**, v. 14, n. 3–4, p. 221-230, 1996.

CAMPOS, L. F. A.; AMORIM, L. V.; FERREIRA, H. C. Utilização do planejamento experimental no estudo do efeito da composição de misturas de bentonitas na reologia de fluidos de perfuração. Parte II: composições ternárias. **Cerâmica**, v. 53, p. 68-73.

CHENG, N.-S.; LAW, A. W.-K. Exponential formula for computing effective viscosity. **Powder Technology**, v. 129, n. 1-3, p. 156-160. 2003.

CHIANN, C. **Testes não Paramétricos**. 2012. Apostila do curso de Introdução à Probabilidade e à Estatística II –Instituto de Matemática e Estatística.

CHIEZA, C. P. **Diagnósticos de problemas operacionais durante a perfuração de poços de petróleo**. 2011. Dissertação (Mestrado). Departamento de Engenharia Mecânica, Pontifícia Universidade Católica do Rio de Janeiro.

COUTO, P. **Perfuração de Poços**. 2012 Apostila do curso de Engenharia de Perfuração I - Universidade Federal do Rio de Janeiro.

DA SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e: ciências aplicadas - curso prático**. ARTLIBER, 2010.

DARLEY, H. C. H.; GRAY, G. R. **Composition and Properties of Drilling and Completion Fluids**. Gulf Publishing Company, Book Division, 1988.

DEOSARKAR, M. P.; SATHE, V. S. Predicting effective viscosity of magnetite ore slurries by using artificial neural network. **Powder Technology**, v. 219, p. 264-270, 2012.

DE PÁDUA BRAGA, A. **Redes neurais artificiais: teoria e aplicações**. LTC Editora, 2007.

FOX, R. W.; MCDONALD, A. T.; PRITCHARD, P. J. **Introdução à mecânica dos fluidos**. LTC, 2010.

GONZÁLEZ, A.; BARRUFET, M. A.; STARTZMAN, R. Improved neural-network model predicts dewpoint pressure of retrograde gases. **Journal of Petroleum Science and Engineering**, v. 37, n. 3-4, p. 183-194, 2003.

HAYKIN, S. **Neural networks: a comprehensive foundation**. Prentice Hall PTR, 1994.

HINES, W. W. *et al.* **Probabilidade e estatística na engenharia**. Livros Técnicos e Científicos, 2006.

MACHADO, J. C. V. **Reologia e Escoamento de Fluidos-Ênfase na Indústria de Petróleo; 2º Edição**. 2002.

MANSANO, R. B. **Engenharia de Perfuração e Completação em Poços de Petróleo**. Apresentação em slides. Agosto de 2004, PETROBRAS. Universidade Federal de Santa Catarina. Florianópolis, 2004.

MELEIRO, L. A. D. C. **Projeto e aplicação de controladores baseados em modelos lineares, neurais e nebulosos**. 2002a. 330 p. Tese (Doutorado). Faculdade de Engenharia Química, Universidade Estadual de Campinas.

\_\_\_\_\_, L. A. D. C., **Redes Neurais Artificiais: Uma Breve Introdução**, 2007b.36 p. Apostila do curso de redes neurais – Universidade Federal do Paraná.

MELO, K. C. D. **Avaliação e modelagem reológica de fluidos de perfuração base água**, 2008. 100 p., Dissertação (Mestrado). Departamento de Engenharia Química, Universidade Federal do Rio Grande do Norte Natal, RN.

MENG, X. *et al.* Effects of carbon ash on rheological properties of water-based drilling fluids. **Journal of Petroleum Science and Engineering**, v. 100, n. 0, p. 1-8, 2012.

MONTGOMERY, D. C.; RUNGER, G. C. **Applied statistics and probability for engineers**. Wiley, 2010.

NASCIMENTO, R. C. A. M.; COSTA, A. C. A.; AMORIM, L. V. **Desempenho de fluidos argilosos envelhecidos termicamente**. Revista Eletrônica de Materiais e Processos. 7.3: 205-214 p. 2012.

NORGAARD, M., RAVN, O., POULSEN, N.K e HANSEN, L.K. (2000). **Neural Networks for Modelling and Control of Dynamic System**, Springer-Verlag.

PARAISO, E. C. **Estudo do escoamento de pasta de cimento em dutos circulares e anulares concêntricos**. 2011. 110 p. Dissertação (Mestrado). Universidade Federal Rural do Rio de Janeiro, Seropédica.

PEREIRA, F. A. R. **Escoamento laminar de líquidos não newtonianos em seções anulares: estudos de CFD e abordagem experimental**. 2006. 229 p. Dissertação (Doutorado). Universidade Federal de Uberlândia, Uberlândia.

PETROBRAS. **Ensaio de Viscosificante par Fluido de Perfuração Base de Água na Exploração e Produção de Petróleo**. Método, N 2605, 1998.

RABE, C. **Estudo experimental da interação folhelho-fluido através de ensaios de imersão**. 2003. 263 p. Tese (Doutorado). Departamento de Engenharia Civil, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro.

RAZI, M. M. *et al.* Artificial Neural Network Modeling of Plastic Viscosity, Yield Point, and Apparent Viscosity for Water-Based Drilling Fluids. **Journal of Dispersion Science and Technology**, v. 34, n. 6, p. 822-827, 2013.

RODRIGUES, M. I.; LEMMA, A. F. **Planejamento de Experimentos & Otimização de Processos**. Casa do Espírito Amigo Fraternidade Fé e Amor, 2009.

RUMELHART, D.E.; MCCLELLAND, J.L. **Parallel Distributed Processing: Explorations in the Microstructure of Cognition**, MIT Press, Cambridge, 1986.

SANTOYO, E. *et al.* Rheological property measurement of drilling fluids used in geothermal wells. **Applied Thermal Engineering**, v. 21, n. 3, p. 283-302, 2001.

SCHAFFEL, S. B. **A Questão Ambiental na Etapa da Perfuração de Poços Marítimos de Óleo e Gás no Brasil**. 2002. 130 p. Dissertação (Mestrado). COPPE, Universidade Federal do Rio de Janeiro.

SCHRAMM, G. **Reologia e reometria: fundamentos teóricos e práticos**. Artliber Editora 2006.

SCHWAAB, M.; PINTO, J. C. **Análise de Dados Experimentais: I. Fundamentos de Estatística e Estimação de Parâmetros**. Editora E-papers, 2007.

SCHWALBERT, M. PALHARINI. **Simulação de Escoamento Não Newtonianos Não Isotérmicos e sua Aplicação à Engenharia de Poços de Petróleo**. 2013. 210 p. Dissertação (Mestrado). COPPE. Universidade Federal do Rio de Janeiro, RJ.

SERRA, A. C. D. S. **A influência de aditivos de lama de perfuração sobre as propriedades geoquímicas de óleos**. 2003. 146 p. Dissertação (Mestrado). Universidade Federal do Rio de Janeiro.

SHIROMA, P. H. **Estudo do comportamento reológico de suspensões aquosas de bentonita e CMC: influência da concentração do NaCl** 2012. 130 p. Dissertação (Mestrado). Departamento de Engenharia Química, Escola Politécnica da Universidade de São Paulo

STEFAN, P. Métodos de Ensaio de Argilas e Bentonitas para Fluidos de Perfuração. **Cerâmica 12**, v. 47/48, 1966.

TAVARES, R. M. **Interpretação e análise de dados de perfuração em poços de petróleo**. 2006. 145 p. Dissertação (Mestrado). Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas

THOMAS, J. E. **Fundamentos de engenharia de petróleo**. Interciência, 2004

VALDMAN, A. **Sistema de Automação para Monitoramento Online de Gases Residuais e Diagnóstico de uma Caldeira Operada com Misturas Diesel/Biodiesel**. 2010. 152 p. Dissertação (Mestrado). Escola de Química, Universidade Federal do Rio de Janeiro.

## **7. ANEXOS**

### **A- Dados obtidos no planejamento preliminar.**

**A1- Parâmetros do modelo reológico.**

**A2- Dados obtidos no viscosímetro FANN 35A.**

**A3- Gráficos de tensão por taxa de deformação.**

### **B- Dados obtidos no planejamento com a temperatura.**

## ANEXO A

### A1- Parâmetros do modelo reológico.

**Tabela 13.** Parâmetros do modelo de Herschell-Buckley.

Níveis (Goma, Bentonita, Barita)	$\tau_0$ (dina.cm <sup>-2</sup> )		K (dina.cm <sup>-2</sup> .s <sup>n</sup> )		n (adimensional)		R <sup>2</sup>
	Valor	desvio padrão	Valor	desvio padrão	Valor	desvio padrão	
(-1,-1,-1)	25,523	2,474	2,502	0,503	0,614	0,029	0,9953
(-1,-1,0)	33,047	4,348	2,598	0,600	0,694	0,033	0,9944
(-1,-1,1)	32,373	1,602	4,650	0,247	0,671	0,008	0,9997
(-1, 0,-1)	27,573	2,126	3,676	0,460	0,601	0,018	0,9981
(-1, 0, 0)	28,666	2,133	5,983	0,451	0,606	0,011	0,9993
(-1, 0, 1)	34,162	2,210	4,863	0,335	0,675	0,010	0,9995
(-1, 1,-1)	25,611	4,108	1,560	0,585	0,687	0,054	0,9853
(-1, 1, 0)	33,530	3,592	2,579	0,455	0,711	0,026	0,9968
(-1, 1, 1)	24,857	3,192	3,598	0,383	0,722	0,015	0,9989
(0,-1,-1)	60,751	21,788	19,450	11,575	0,383	0,081	0,9546
(0,-1, 0)	78,408	3,455	11,647	1,118	0,512	0,014	0,9988
(0,-1, 1)	78,730	7,242	16,930	2,091	0,538	0,018	0,9981
(0, 0,-1)	76,054	14,369	22,570	7,216	0,400	0,044	0,9865
(0, 0, 0)	84,799	3,551	12,351	1,038	0,535	0,012	0,9991
(0, 0, 1)	96,653	4,624	16,101	1,116	0,577	0,010	0,9994
(0,1,-1)	74,718	3,300	9,259	1,023	0,522	0,016	0,9984
(0, 1, 0)	79,996	22,126	24,575	7,443	0,503	0,043	0,9881
(0, 1, 1)	104,428	4,799	20,821	1,201	0,570	0,008	0,9996
(1,-1,-1)	101,479	13,349	18,051	5,907	0,434	0,045	0,9858
(1,-1, 0)	135,744	16,095	17,636	5,575	0,496	0,045	0,9870
(1,-1, 1)	131,745	3,880	31,870	1,565	0,458	0,007	0,9997
(1, 0, -1)	129,951	22,644	12,243	6,187	0,550	0,072	0,9687
(1, 0, 0)	140,567	8,916	24,558	3,392	0,473	0,019	0,9975
(1, 0, 1)	-32,288	238,564	182,290	190,207	0,233	0,121	0,8973
(1, 1,-1)	59,108	15,869	80,814	10,956	0,296	0,017	0,9978
(1, 1, 0)	142,363	11,360	53,472	5,429	0,414	0,014	0,9986
(1, 1, 1)	149,865	16,012	38,139	5,408	0,502	0,020	0,9974
(0, 0, 0)	91,416	17,227	13,860	4,713	0,550	0,049	0,9856

## A2- Dados obtidos no viscosímetro FANN 35A.

**Tabela 14.** Ângulo de deflexão em diferentes velocidades de rotação.

(goma, bentonita, barita)	0,9 rpm	1,8 rpm	3 rpm	6 rpm	30 rpm	60 rpm	90 rpm	100 rpm	180 rpm	200 rpm	300 rpm	600 rpm
(-1,-1,-1)	5	6	6	7	12	14	16	16	21	22	27	40
(-1,-1,0)	6	7	8	9	16	20	24	25	33	35	42	70
(-1,-1,1)	7	8	9	11	20	27	33	35	48	52	66	102
(-1, 0,-1)	6	7	7	8	14	18	20	21	27	29	36	52
(-1, 0, 0)	6	8	9	11	19	25	30	32	43	46	56	84
(-1, 0, 1)	7	9	9	12	21	29	35	37	51	55	71	109
(-1, 1,-1)	4	5	6	7	11	14	15	16	20	21	25	42
(-1, 1, 0)	6	7	8	10	16	21	25	27	35	38	47	77
(-1, 1, 1)	6	7	6	8	18	25	31	34	49	53	66	110
(0,-1,-1)	16	17	21	23	27	30	33	42	50	52	53	64
(0,-1, 0)	17	19	21	24	33	40	45	47	57	61	70	95
(0,-1, 1)	18	21	25	29	42	53	63	70	89	93	109	153
(0, 0,-1)	20	22	24	27	35	40	45	50	61	65	67	84
(0, 0, 1)	21	25	27	32	51	66	77	79	104	109	134	192
(0,1,-1)	16	18	19	21	30	35	39	41	49	53	62	82
(0, 1, 0)	19	23	30	36	46	60	71	83	107	112	120	172
(0, 1, 1)	25	28	30	36	61	79	92	95	125	133	163	232
(1,-1,-1)	24	25	28	31	38	45	50	53	60	65	79	89
(1,-1, 0)	30	32	34	39	53	62	67	70	81	85	111	132
(1,-1, 1)	32	36	40	45	64	77	88	91	112	116	135	175
(1, 0, -1)	27	30	32	36	49	52	63	66	76	80	114	130
(1, 0, 0)	31	35	39	43	60	72	80	83	97	102	117	157
(1, 0, 1)	39	43	40	45	85	106	122	91	158	116	135	175
(1, 1,-1)	29	32	39	44	62	73	81	84	97	103	109	135
(1, 1, 0)	41	45	49	55	79	97	111	114	142	146	169	209
(1, 1, 1)	34	40	49	58	83	106	123	131	162	164	195	274

### A3- Gráficos de tensão por taxa de deformação.

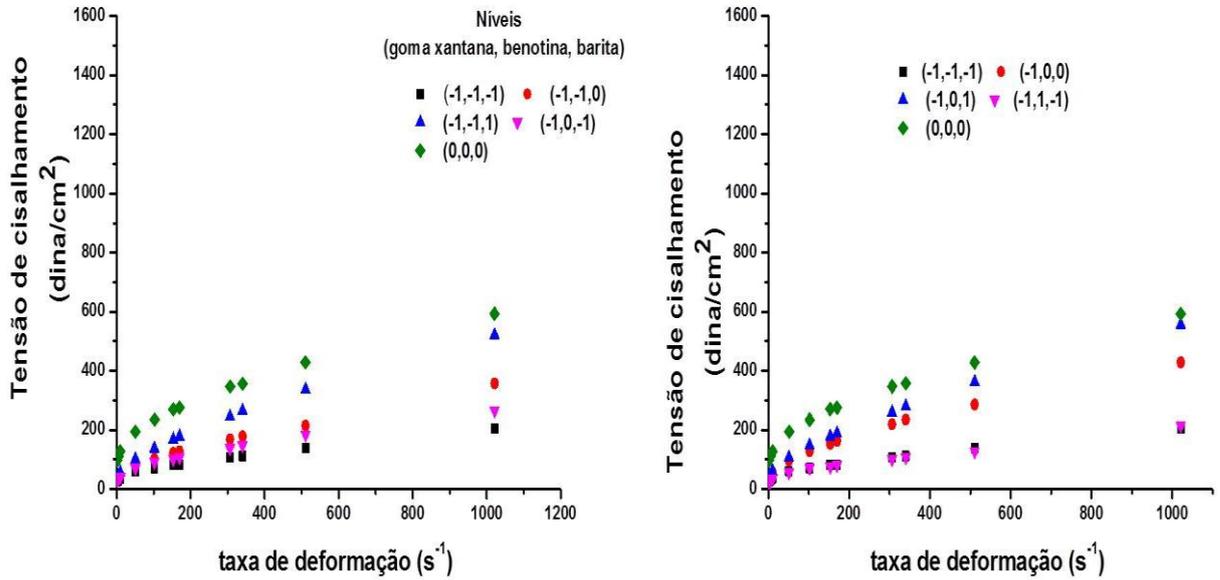


Figura 30. Curvas de fluxo (a).

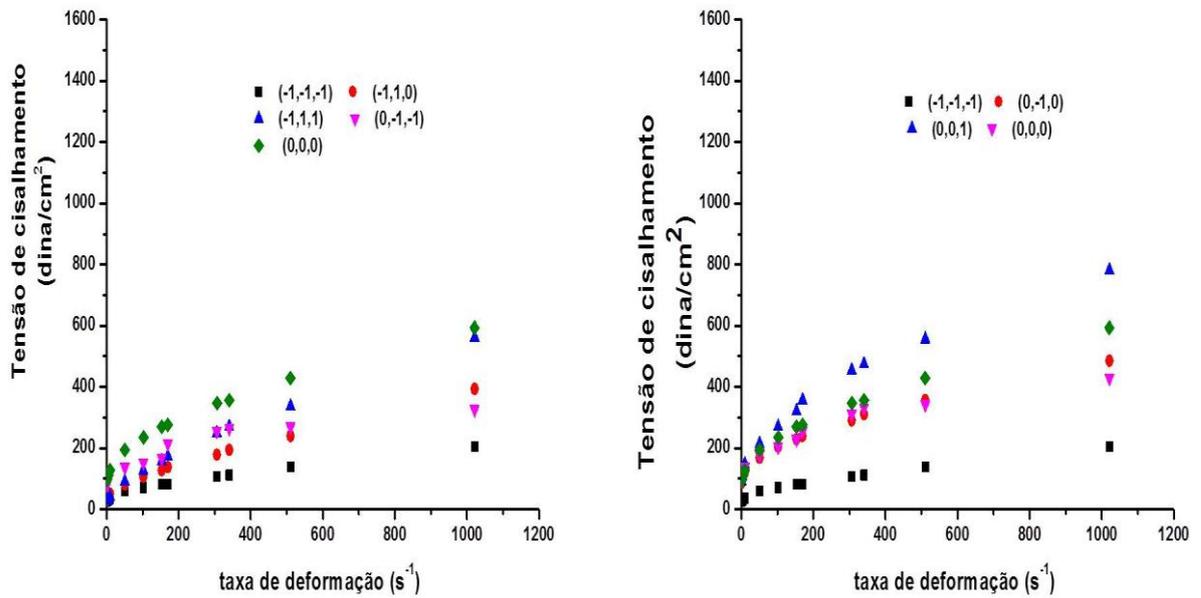


Figura 31. Curvas de fluxo (b).

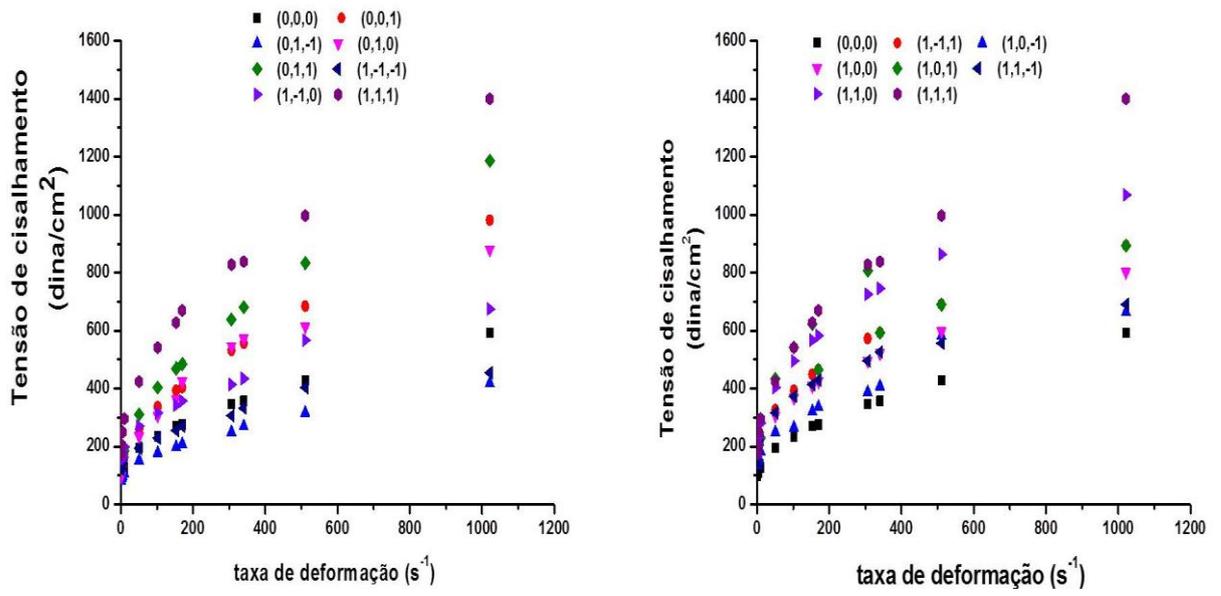


Figura 32. Curvas de fluxo (c).

## ANEXO B

**Tabela 15.** Dados obtidos no planejamento com a temperatura controlada (continua).

Ensaio	Temperatura	Goma Xantana	Bentonita	Barita	Viscosidade (300 rpm, cP)
1	-1	-1	-1	-1	25
2	-1	-1	-1	0	45
3	-1	-1	-1	1	66
4	-1	-1	0	-1	30
5	-1	-1	0	0	53
6	-1	-1	0	1	70
7	-1	-1	1	-1	50
8	-1	-1	1	0	72
9	-1	-1	1	1	68
10	-1	0	-1	-1	53
11	-1	0	-1	0	70
12	-1	0	-1	1	97
13	-1	0	0	-1	58
14	-1	0	0	0	81
15	-1	0	0	1	125
16	-1	0	1	-1	61
17	-1	0	1	0	118
18	-1	0	1	1	163
19	-1	1	-1	-1	76
20	-1	1	-1	0	104
21	-1	1	-1	1	146
22	-1	1	0	-1	96
23	-1	1	0	0	132
24	-1	1	0	1	217
25	-1	1	1	-1	112
26	-1	1	1	0	152
27	-1	1	1	1	253
28	0	-1	-1	-1	25
29	0	-1	-1	0	37
30	0	-1	-1	1	54
31	0	-1	0	-1	26
32	0	-1	0	0	42
33	0	-1	0	1	58
34	0	-1	1	-1	33
35	0	-1	1	0	45
36	0	-1	1	1	79
37	0	0	-1	-1	42
38	0	0	-1	0	64
39	0	0	-1	1	96
40	0	0	0	-1	54
41	0	0	0	0	75
42	0	0	0	1	125
43	0	0	1	-1	64
44	0	0	1	0	91
45	0	0	1	1	107
46	0	1	-1	-1	76
47	0	1	-1	0	104
48	0	1	-1	1	123

**Tabela 15.** Continuação.

Ensaio	Temperatura	Goma Xantana	Bentonita	Barita	Viscosidade (300 rpm, cP)
49	0	1	0	-1	83
50	0	1	0	0	92
51	0	1	0	1	189
52	0	1	1	-1	96
53	0	1	1	0	133
54	0	1	1	1	175
55	1	-1	-1	-1	19
56	1	-1	-1	0	30
57	1	-1	-1	1	37
58	1	-1	0	-1	26
59	1	-1	0	0	36
60	1	-1	0	1	61
61	1	-1	1	-1	31
62	1	-1	1	0	31
63	1	-1	1	1	49
64	1	0	-1	-1	40
65	1	0	-1	0	56
66	1	0	-1	1	75
67	1	0	0	-1	53
68	1	0	0	0	78
69	1	0	0	1	97
70	1	0	1	-1	59
71	1	0	1	0	74
72	1	0	1	1	93
73	1	1	-1	-1	60
74	1	1	-1	0	86
75	1	1	-1	1	127
76	1	1	0	-1	70
77	1	1	0	0	128
78	1	1	0	1	150
79	1	1	1	-1	89
80	1	1	1	0	126
81	1	1	1	1	156
82	0	0	0	0	72
83	0	0	0	0	71
84	0	0	0	0	75