

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

**IDENTIFICAÇÃO E CONTROLE EM LINHA DE PROCESSO DE
PERFURAÇÃO DE POÇOS DE PETRÓLEO UTILIZANDO REDES
NEURONAIAS**

VANESSA DE JESUS DA SILVA RIBEIRO

2018



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

**IDENTIFICAÇÃO E CONTROLE EM LINHA DE PROCESSO DE
PERFURAÇÃO DE POÇOS DE PETRÓLEO UTILIZANDO REDES
NEURONAIAS**

VANESSA DE JESUS DA SILVA RIBEIRO

Sob a Orientação da Professora

Márcia Peixoto Vega Domiciano

Dissertação submetida como
requisito parcial para a obtenção do
grau de **Mestre em Engenharia
Química**, Área de Concentração em
Tecnologia Química.

Seropédica, RJ

Agosto, 2018

R484i Ribeiro, Vanessa de Jesus da Silva, 1990-
Identificação e controle em linha de processo de
perfuração de poços de petróleo utilizando redes
neuronais / Vanessa de Jesus da Silva Ribeiro. - 2018.
156 f.: il.

Orientadora: Márcia Peixoto Vega.
Dissertação(Mestrado). -- Universidade Federal Rural
do Rio de Janeiro, Programa de Pós-Graduação em
Engenharia Química, 2018.

1. Rede neuronal. 2. Controle de pressão. 3.
Perfuração de poços. 4. Inteligência artificial. I.
Vega, Márcia Peixoto, 1972-, orient. II Universidade
Federal Rural do Rio de Janeiro. Programa de Pós
Graduação em Engenharia Química III. Título.

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

VANESSA DE JESUS DA SILVA RIBEIRO

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

DISSERTAÇÃO APROVADA EM 29/08/2018

Márcia Peixoto Vega Domiciano, D. Sc., DEQ/UFRRJ
(Orientador)

Cláudia Ossanai, D. Sc., UFF

Marcio Nele de Souza, D. Sc., EQ, UFRJ

*“Pássaros não voam, são levados pelo vento. Peixes não nadam, são carregados pela água.
Tudo que nos acontece é resultado de todas as coisas as quais somos ligados.”*

Morgan Freeman.

AGRADECIMENTOS

À Deus por ter colocado em meu caminho pessoas tão maravilhosas, que tornaram possível a realização desse trabalho.

Aos meus pais, Vânia e Daniel, por terem me apoiado nesse período. Agradeço também a meu irmão, Leonardo.

À professora Márcia Peixoto Vega Domiciano, pela orientação concedida, por todo apoio, confiança e paciência durante esta caminhada que se iniciou durante a iniciação científica. Agradeço também ao professor Lindoval por todo apoio na parte computacional desde o princípio, por todo tempo e esforço despendido. À professora Cláudia Scheid pelas contribuições para o desenvolvimento deste trabalho.

Aos companheiros de laboratório: Gabrielle Fontella, Sergio Magalhães, Eduardo Cunha, Elias Pacheco e Bruno Oechsler pelas trocas de ideias e aprendizados. Aos estagiários: Lisandra Barbosa, Pedro Sampaio, Rayssa Gybson, Mariana Petroceli e Thomas Nascimento pela dedicação, apoio e prestatividade em todas as tarefas, a ajuda de vocês foi imprescindível para a construção deste trabalho. Muito obrigada!

Aos professores Cláudia Ossanai (UFF) e Marcio Nele de Souza (Escola de Química/UFRJ), por participarem de minha banca e colaborarem com suas sugestões para a melhoria da qualidade deste trabalho.

Aos amigos de turma Caroline Eulino, Nanny Chantre, Isac Carvalho, Paula Aurora, Izadora Chauke e Roberta Sartori por compartilhar momentos de sofrimento e aflição durante as intensas matérias obrigatórias. Em especial agradeço a Anderson Radich pelos momentos de discussão e grande apoio ao longo desta jornada. Devo agradecer também as amigas do alojamento Gleiciane Maria, Tainara Ferrugem, Priscila Matos, Regiane Vilanova, Denise Gaiote e Silvane Holanda por tornarem a estadia mais leve. Em especial agradeço a Muara Cristian por compartilhar das alegrias e dificuldades enfrentadas ao longo desta caminhada que se iniciou ainda na graduação. Muito obrigada!!

RESUMO

RIBEIRO, Vanessa de Jesus da Silva. **Identificação e controle em linha de processo de perfuração de poços de petróleo utilizando redes neurais.** 2018 161p. Dissertação (Mestrado em Engenharia Química, Tecnologia Química). Instituto de Tecnologia, Departamento de Engenharia Química, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2018.

A garantia de um poço que apresente uma boa taxa de produção de óleo está diretamente relacionada com a etapa de perfuração do mesmo, sendo o controle da pressão anular de fundo ou *bottomhole pressure* (BHP) o ponto de interesse. Assim, este trabalho objetiva a implementação de controladores baseados em redes neurais para regular a pressão anular de fundo, durante o processo de perfuração de poços de petróleo, frente a distúrbios como *kick* de gás, perda de circulação e o procedimento de conexão de tubos. Tais distúrbios, além de causar flutuações de pressão que podem danificar o poço, podem levar a danos ambientais, financeiros e de recursos humanos, nos casos mais extremos. Neste estudo, utilizou como variável manipulada o índice de abertura da válvula *choke*. Pra fins de identificação e controle em tempo real utilizou-se uma rede neuronal do tipo *feedforward* com uma camada de neurônios ocultos, apresentando como sinais de entrada: pressão anular, pressão no *choke*, frequência da bomba de água e de lama, abertura da *choke*, vazão do anular, tempo e *set point*, e um neurônio na camada de saída. Controladores neurais são atrativos por apresentaremxi habilidade em lidar com sistema não lineares e inherentemente transitentes, como é o caso do processo de perfuração de poços de petróleo. Os controladores neurais foram comparados ao controlador clássico PI (Ziegler Nichols (1942) e Cohen-Coon (1953)). Além disso, foram realizados estudos de simulação e experimentos em unidade de perfuração. Os controladores desenvolvidos mostraram-se eficientes em controlar a pressão anular de fundo.

Palavras-chave: rede neuronal, controle, perfuração de poços.

ABSTRACT

RIBEIRO, Vanessa de Jesus da Silva. **Identificação e controle em linha de processo de perfuração de poços de petróleo utilizando redes neurais.** 2018, 161p. Dissertation (Master in Chemical Engineering, Chemical Technology). Instituto de Tecnologia, Departamento de Engenharia Química, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2018.

A well that presents a good oil production rate is directly related to the drilling stage being the control of the pressure is the most important step. Thus the major objective of this work is the implementation of neural network-based controllers to regulate the annulus bottomhole pressure (BHP) during drilling, in the event of disturbances such as gas kick, circulation and pipe connection procedure. Such disturbances, in addition to causing pressure fluctuations that can damage the well, can lead to environmental, financial and human resource damage in the most extreme cases. In this study, the choke valve was used as the manipulated variable. For the purpose of identification and control in real time, a feedforward neuronal network was used with a layer of hidden neurons, presenting as input signals: annular pressure, choke pressure, water pump and mud frequency, choke opening , annular flow, time and *set point*, and a neuron in the output layer. Neural controllers are attractive because they have the ability to deal with nonlinear and inherently transient systems, as is the case with of oil well drilling process. Neuronal controllers were compared with classical PI controller (Ziegler Nichols (1942) and Cohen-Coon (1953)). It is noteworthy that simulation studies and experiments in drilling unit were carried out. The developed closed loop scheme showed to be efficient to regulate annulus bottomhole pressure.

Key words: Neural network. Control. Oil well drilling.

LISTA DE TABELAS

Tabela 1 – Configuração para o treinamento neuronal.....	38
Tabela 2 – Configuração para treinamento de <i>kick</i> de gás e perda de circulação.	39
Tabela 3 - Estimação de parâmetros do controlador.	41
Tabela 4 – Condição operacional para fenômeno de <i>kick</i> e perda de circulação.	43
Tabela 5 – Quantitativo de dados para a realização da validação cruzada.....	45

LISTA DE FIGURAS

Figura 1 – Janela operacional. Fonte: Adaptado de Rocha & Azevedo, 2009.	1
Figura 2 – Esquema simplificado de uma sonda de perfuração.....	5
Figura 3 – Representação do modelo do tubo em U. Fonte: Adaptado de Stamnes et al., 2008..	7
Figura 4 - Modelo não linear de um neurônio. Fonte: Adaptado de Haykin, 2009.	11
Figura 5 – Rede neuronal multicamada. Fonte: Adaptado de Haykin, 2009.	12
Figura 6 - Rede neuronal recorrente sem <i>loop feedback</i> . Fonte: Adaptado de Haykin, 2009.	13
Figura 7 – Propagação e retro propagação do erro. Fonte: Adaptado de Haykin, 2009.	16
Figura 8 – Representação do neurônio de saída j. Fonte: Adaptado de Haykin, 2009.	17
Figura 9 – Neurônio j conectado ao neurônio oculto k. Fonte: Adaptado de Haykin, 2009.	19
Figura 10 - Diagrama de blocos da identificação de sistemas. Fonte: Adaptado de Haykin, 2009.	21
Figura 11 – Esquema de adaptação da unidade experimental em relação ao processo de perfuração de poços. Fonte: Russano, 2014.....	24
Figura 12 – Esquema da unidade experimental de controle.	25
Figura 13 – Diagrama P&ID da unidade experimental de perfuração de poços: E-1: Tanque de nível; E-2: Tanque de água; E-3: Bomba principal; E-4: Tanque reservatório; E-5: Compressor de ar; I-1: Medidor de vazão e densidade; V-1, V-2, V-5, V-6: Válvulas esfera; V-3: Válvula de retenção; V-4: Válvula <i>choke</i> (válvula de controle acionada pneumáticaamente); V-7, V-8: Válvula de entrada/ saída de ar; V-9: Válvula de permeabilidade; V- 10: Válvula gaveta (Broca); PT: Sensor/Transmissor de pressão; LT: Sensor/Transmissor de nível; FT: Sensor/Transmissor de vazão.	25
Figura 14 - Bomba helicoidal de deslocamento positivo (Bomba principal).	26
Figura 15 - Bomba helicoidal de deslocamento positivo (Bomba secundária).	26
Figura 16 – Transdutor de pressão.....	27
Figura 17 – Válvula <i>choke</i>	27
Figura 18 – Medidor de vazão Micro Motion com saída analógica.	28
Figura 19 - Sensor de nível.	28
Figura 20 – Tanque de nível.	29
Figura 21 - Tanque reservatório.....	29
Figura 22 – Compressor de ar.....	30
Figura 23 – Instrumentação no tanque reservatório. Fonte: Patrício, 2016.	30
Figura 24 - Válvulas reguladoras de entrada e saída de ar do reservatório. Fonte: Patrício, 2016.	31
Figura 25 – Filtro regulador de ar. Fonte: Patrício, 2016.	31
Figura 26 - Válvula de permeabilidade. Fonte: Patrício, 2016.	32
Figura 27 - Interface do programa para controle do poço.	32
Figura 28 - Interface do programa para controle do tanque reservatório.	33
Figura 29 – Interface de treinamento experimental da rede neuronal.	33
Figura 30 – Janela de inserção de dados de treinamento.	34
Figura 31 – Rede com uma camada oculta do tipo 7-7-1.	35
Figura 32 – Rede para o controlador não linear, do tipo 8-7-2.....	35
Figura 33 – Diagrama da unidade experimental: 1 – Tanque de nível; 2 – Bomba de deslocamento positivo (bomba de alimentação da coluna de perfuração); 3 – Manômetro; 4 – Válvula de restrição representando a broca de perfuração; 5 – Sensor de vazão e densidade; 6 – Válvula <i>choke</i> ;7 – Válvula esfera; LT – Transmissor de nível; PT – Transmissor de pressão.....	36

Figura 34 – Configuração para <i>kick</i> e perda de circulação: 1 – Tanque de nível; 2 – Bomba de deslocamento positivo (bomba de alimentação da coluna de perfuração); 3 – Manômetro; 4 – Válvula de restrição representando a broca de perfuração; 5 – Sensor de vazão e densidade; 6 – Válvula <i>choke</i> ; 7 – Válvula esfera; 8 – Tanque reservatório; 9 - Válvula de permeabilidade; LT – Transmissor de nível; PT – Transmissor de pressão.....	37
Figura 35 – Configuração para o procedimento de conexão de tubos: E-1: Tanque de nível; E-2: Tanque de água; E-3: Bomba principal; E-4: Tanque reservatório; E-5: Compressor de ar; E -6 e E-7: Tanques de lama; E-8: Bomba secundária; I-1: Medidor de vazão e densidade; V-1, V-2, V-5, V-6, V-11, V-12, V-13 e V-14: Válvulas esfera; V-3, V-17: Válvulas de retenção; V-15, V-16: Válvulas borboleta; V-4: Válvula <i>choke</i> (válvula de controle acionada pneumáticaamente); V-10: Válvula gaveta (Broca); PT: Sensor/Transmissor de pressão; LT: Sensor/Transmissor de nível; FT: Sensor/Transmissor de vazão.....	38
Figura 36 – Curva de reação do processo. Fonte: Freitas, 2013.	40
Figura 37 – Treinamento da rede neuronal manipulando a frequência da bomba de alimentação da coluna de perfuração com válvula <i>choke</i> 95% aberta.	42
Figura 38 – Treinamento de <i>kick</i> com válvula de permeabilidade em 60%, abertura da válvula <i>choke</i> em 95% com sete dados passados de pressão e cinco neurônios na camada oculta.....	43
Figura 39 – Treinamento perda de circulação com válvula de permeabilidade em 60%, abertura da válvula <i>choke</i> em 25%, com três dados passados de pressão e sete neurônios na camada oculta.	44
Figura 40 – Treinamento variando índice de abertura da <i>choke</i> , para frequência de 45 Hz para a bomba principal, com sete neurônios na camada oculta.	44
Figura 41 – Perda de circulação com sete dados passados de pressão e cinco neurônios na camada oculta.	46
Figura 42 – Ajuste dos dados estimados pelo modelo versus o valor observado.	46
Figura 43 – Perda de circulação com cinco dados passados de pressão e sete neurônios na camada oculta.	46
Figura 44 – Ajuste dos dados estimados pelo modelo versus o valor observado.	46
Figura 45 – Perda de circulação com cinco dados passados de pressão e cinco neurônios na camada oculta.	47
Figura 46 – Ajuste dos dados estimados pelo modelo versus o valor observado.	47
Figura 47 – <i>Kick</i> de gás com cinco dados passados de pressão e sete neurônios na camada oculta.	47
Figura 48 – Ajuste dos dados estimados pelo modelo versus o valor observado.	47
Figura 49 – <i>Kick</i> de gás com sete dados passados de pressão e cinco neurônios na camada oculta.	47
Figura 50 – Ajuste dos dados estimados pelo modelo versus o valor observado.	47
Figura 51 – <i>Kick</i> de gás com sete dados passados de pressão e nove neurônios na camada oculta.	48
Figura 52 – Ajuste dos dados estimados pelo modelo versus o valor observado.	48
Figura 53 – Teste da rede neuronal para variação de vazão com sete neurônios na camada oculta.	48
Figura 54 - Ajuste dos dados estimados pelo modelo da rede versus o valor obsrvado da pressão anular.....	48
Figura 55 – Teste da rede neuronal para variação de vazão com cinco neurônios na camada oculta.	49
Figura 56 - Ajuste dos dados estimados pelo modelo da rede versus o valor observado.	49
Figura 57 – Estimação da abertura da válvula <i>choke</i> com nove neurônios na camada oculta. ..	49
Figura 58 - Ajuste dos dados estimados pelo modelo da rede versus o valor obsrvado da abertura da válvula <i>choke</i>	49

Figura 59 - Predição da abertura da válvula <i>choke</i> com nove neurônios na camada oculta.....	50
Figura 60 - Ajuste dos dados preditos pelo modelo da rede versus o valor medido da abertura da válvula <i>choke</i>	50
Figura 61 – Predição da abertura da válvula <i>choke</i> com cinco neurônios na camada oculta.	50
Figura 62 – Ajuste dos dados preditos pelo modelo da rede versus o valor medido da abertura da válvula <i>choke</i>	50
Figura 63 – Saída da rede para dados de entrada em malha fechada, variável manipulada: frequência da bomba de água.....	51
Figura 64 – Saída da rede para dados de entrada em malha fechada, variável manipulada: frequência da bomba de água.....	51
Figura 65 – Saída da rede para dados de entrada em malha fechada, variável manipulada: frequência da bomba de água.....	51
Figura 66 – Saída da rede para dados de entrada em malha fechada, variável manipulada: válvula <i>choke</i>	51
Figura 67 – Saída da rede para dados de entrada em malha fechada, variável manipulada: válvula <i>choke</i>	51
Figura 68 – Distúrbio de vazão.....	53
Figura 69 – Variável manipulada.....	54
Figura 70 – Variação do ganho do controlador frente a distúrbio de vazão.	54
Figura 71 – Controle da pressão para o procedimento de conexão de tubos.	55
Figura 72 – Variação do índice de abertura da válvula <i>choke</i>	55
Figura 73 – <i>Kick</i> de gás.....	56
Figura 74 – Perda de circulação.....	56
Figura 75 – <i>Kick</i> de gás com 40% de permeabilidade da rocha reservatório.	57
Figura 76 – Resposta da variável manipulada.	58
Figura 77 – Ganho do controlador.....	58
Figura 78 – Perda de circulação com 40% de permeabilidade da rocha reservatório.	59
Figura 79 – Resposta da variável manipulada.	60
Figura 80 – Ganho do controlador.....	60
Figura 81 – Controle via rede neuronal da pressão anular de fundo.	61
Figura 82 – Comportamento da variável manipulada para mudança de <i>set point</i>	62
Figura 83 – Ganho do controlador atualizado via rede neuronal.....	62
Figura 84 – Controle da pressão anular de fundo via rede neuronal.	64
Figura 85 – Comportamento da variável manipulada.....	64
Figura 86 – Ganho do controlador atualizado via rede neuronal.....	65
Figura 87 – Controle da pressão anular para diferentes <i>set points</i>	66
Figura 88 – Resposta do controlador neuronal inverso.	66
Figura 89 – Controle de <i>kick</i> de gás.....	67
Figura 90 – Resposta do controlador neuronal inverso.	67
Figura 91 – Controle da pressão anular frente a perda de circulação.	68
Figura 92 – Resposta do controlador neuronal inverso.	68
Figura 93 – Controle da pressão anular durante o procedimento de conexão de tubos.	69
Figura 94 – Resposta do controlador neuronal inverso.	69
Figura 95 – Controle da pressão anular durante perfuração.	70
Figura 96 – Resposta do controlador neuronal inverso.	71
Figura 97 - Três dados passados de pressão, índice de abertura da válvula <i>choke</i> em 95% e sete neurônios na camada oculta.	81
Figura 98 - Três dados passados de pressão, índice de abertura da válvula choke em 95% e nove neurônios na camada oculta.	81

Figura 99 - Sete dados passados de pressão, índice de abertura da válvula choke em 95% e cinco neurônios na camada oculta.....	81
Figura 100 - Três dados passados de pressão, índice de abertura da válvula choke em 55% e nove neurônios na camada oculta.....	81
Figura 101 - Cinco dados passados de pressão, índice de abertura da válvula choke em 55% e sete neurônios na camada oculta.....	81
Figura 102 - Cinco dados passados de pressão, índice de abertura da válvula choke em 55% e nove neurônios na camada oculta.....	81
Figura 103 - Treinamento com sete dados passados de pressão, índice de abertura da válvula choke em 55% e e nove neurônios na camada oculta, respectivamente.....	82
Figura 104 - Treinamento com três dados passados de pressão, índice de abertura da válvula choke em 25% e e nove neurônios na camada oculta, respectivamente.....	82
Figura 105 - Treinamento com três dados passados de pressão, índice de abertura da válvula <i>choke</i> em 95%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	83
Figura 106 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula <i>choke</i> em 95%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	83
Figura 107 - Treinamento com sete dados passados de pressão, índice de abertura da válvula <i>choke</i> em 95%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	84
Figura 108 - Treinamento com três dados passados de pressão, índice de abertura da válvula <i>choke</i> em 55%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	84
Figura 109 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula <i>choke</i> em 55%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	85
Figura 110 - Treinamento com sete dados passados de pressão, índice de abertura da válvula <i>choke</i> em 55%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	85
Figura 111 - Treinamento com três dados passados de pressão, índice de abertura da válvula <i>choke</i> em 25%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	86
Figura 112 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula <i>choke</i> em 25%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	86
Figura 113 - Treinamento com sete dados passados de pressão, índice de abertura da válvula <i>choke</i> em 25%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	87
Figura 114 - Treinamento com três dados passados de pressão, índice de abertura da válvula <i>choke</i> em 95%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	87
Figura 115 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula <i>choke</i> em 95%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	88
Figura 116 - Treinamento com sete dados passados de pressão, índice de abertura da válvula <i>choke</i> em 95%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	88

Figura 149 - Treinamento com sete dados passados de pressão, índice de abertura da válvula <i>choke</i> em 25%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	105
Figura 150 - Treinamento com três dados passados de pressão, índice de abertura da válvula <i>choke</i> em 95%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	106
Figura 151 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula <i>choke</i> em 95%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	106
Figura 152 - Treinamento com sete dados passados de pressão, índice de abertura da válvula <i>choke</i> em 95%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	107
Figura 153 - Treinamento com três dados passados de pressão, índice de abertura da válvula <i>choke</i> em 55%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	107
Figura 154 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula <i>choke</i> em 55%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	108
Figura 155 - Treinamento com sete dados passados de pressão, índice de abertura da válvula <i>choke</i> em 55%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	108
Figura 156 - Treinamento com três dados passados de pressão, índice de abertura da válvula <i>choke</i> em 25%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	109
Figura 157 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula <i>choke</i> em 25%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	109
Figura 158 - Treinamento com sete dados passados de pressão, índice de abertura da válvula <i>choke</i> em 25%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.....	110
Figura 159 - Treinamento com sete dados passados de pressão, frequência de 30 Hz e cinco, sete e nove neurônios na camada	111
Figura 160 - Treinamento com três dados passados de pressão, frequência de 45 Hz e cinco, sete e nove neurônios na camada oculta, respectivamente.....	111
Figura 161 - Treinamento com cinco dados passados de pressão, frequência de 45 Hz e cinco, sete e nove neurônios na camada oculta, respectivamente.....	112
Figura 162 - Treinamento com sete dados passados de pressão, frequência de 45 Hz e cinco, sete e nove neurônios na camada oculta, respectivamente.....	112
Figura 163 - Treinamento com três dados passados de pressão, frequência de 60 Hz e cinco, sete e nove neurônios na camada oculta, respectivamente.....	113
Figura 164 - Treinamento com cinco dados passados de pressão, frequência de 60 Hz e cinco, sete e nove neurônios na camada oculta, respectivamente.....	113
Figura 165 - Treinamento com sete dados passados de pressão, frequência de 60 Hz e cinco, sete e nove neurônios na camada oculta, respectivamente.....	114
Figura 166 – <i>Kick</i> de gás com 40% de permeabilidade da rocha reservatório.....	132
Figura 167 – Resposta da variável manipulada.....	132
Figura 168 – Ganho do controlador.....	132
Figura 169 – <i>Kick</i> de gás com 50% de permeabilidade da rocha reservatório.....	132
Figura 170 – Resposta da variável manipulada.....	132
Figura 171 – Ganho do controlador.....	132

Figura 172 – Kick de gás com 50% de permeabilidade da rocha reservatório.	133
Figura 173 – Resposta da variável manipulada.	133
Figura 174 – Ganho do controlador.	133
Figura 175 – Kick de gás com 60% de permeabilidade da rocha reservatório.	133
Figura 176 – Resposta da variável manipulada.	133
Figura 177 – Ganho do controlador.	133
Figura 178 – Perda de circulação com 50% de permeabilidade da rocha reservatório.	134
Figura 179 – Resposta da variável manipulada.	134
Figura 180 – Ganho do controlador.	134
Figura 181 – Perda de circulação com 60% de permeabilidade da rocha reservatório.	134
Figura 182 – Resposta da variável manipulada.	134
Figura 183 – Ganho do controlador.	134
Figura 184 – Controle da pressão anular frente kick de gá com válvula de permeabilidade em 50%.	135
Figura 185 – Resposta do controlador neuronal inverso.	135
Figura 186 – Controle da pressão anular frente kick de gá com válvula de permeabilidade em 50%.	135
Figura 187 – Resposta do controlador neuronal inverso.	135
Figura 188 – Controle da pressão anular frente a perda de circulação com válvula de permeabilidade em 40%.....	135
Figura 189 – Resposta do controlador neuronal inverso.	135
Figura 190 – Controle da pressão anular frente a perda de circulação com válvula de permeabilidade em 50%	136
Figura 191 – Resposta do controlador neuronal inverso.	136
Figura 192 – Controle da pressão anular para procedimento de conexão de tubos.....	136
Figura 193 – Resposta do controlador neuronal inverso.	136
Figura 194 – Controle da pressão anular durante processo de perfuração.	136
Figura 195 – Resposta do controlador neuronal inverso.	136

LISTA DE SÍMBOLOS

v_k	Potencial de ativação do neurônio k
x_i	Sinal de entrada i
w_{ki}	Peso sináptico entre o neurônio k e sinal de entrada i
b_k	Bias ligado ao neurônio k
y_k	Saída do neurônio k
$\varphi(v_k)$	Função de ativação do neurônio k
δ	Gradiente local
η	Taxa de aprendizagem
e_j	Sinal de erro
ε	Erro total da rede
K	Ganho
t_d	Tempo morto
T	Constante de tempo

LISTA DE ABREVIASÕES

ECD	<i>Equivalent circulating density</i>
BHP	Pressão anular de fundo (<i>bottomhole pressure</i>)
UBD	<i>Underbalanced drilling</i>
MPD	Esquema de controle adaptativo (<i>Managed pressure drilling</i>)
IADC	<i>International Association of Drilling Contractors</i>
CBHP	<i>Constant bottom hole pressure</i>
PMCD	<i>Pressurized mud cap drilling</i>
DGD	<i>Dual gradient drilling</i>
RFC	<i>Return flow control</i>
NPT	<i>Non-Productive Time</i>
RNA	Redes neurais artificiais
BOP	<i>Blowout preventer</i>
BP	Algoritmo de retropropagação do erro (<i>back-propagation algorithm</i>)
MSE	Erro quadrático médio (<i>Mean Squared Error</i>)
SSE	Soma do erro quadrático (<i>Sum os Squared Error</i>)
RMSE	Raíz do erro quadrático médio (<i>Root mean square error</i>)
ROP	Velocidade de perfuração (<i>rate of penetration</i>)
SICP	<i>Shut In Casing Pressure</i>
SIDP	<i>Shut In Drill pipe Pressure</i>
PID	Controlador Proporcional – Integral – Derivativo
MPC	Controlador Preditivo (<i>Model predictive control</i>)
PI	Controlador Proporciona - Integral

SUMÁRIO

1	INTRODUÇÃO.....	1
2	REVISÃO BIBLIOGRÁFICA.....	5
2.1	O PROCESSO DE PERFURAÇÃO DE POÇOS	5
2.2	MODELO DO TUBO EM U	6
2.2	CONTROLE NA PERFURAÇÃO DE POÇOS	7
2.3	TRABALHOS DESENVOLVIDOS NA UNIDADE PILOTO DE PERFURAÇÃO DE POÇOS DE PETRÓLEO DO LEF/ UFRRJ.....	9
2.4	REDE NEURONAL ARTIFICIAL.....	10
2.4.1	Histórico	11
2.4.2	Arquitetura.....	11
2.4.3	Construção das redes neurais.....	13
2.4.4	Funções de ativação.....	14
2.4.5	Treinamento.....	14
2.4.6	Algoritmo Back-propagation	15
2.4.6.1	Algoritmo	16
2.5	NEURO-CONTROLADORES	20
2.5.1	Controle neuronal direto e indireto.....	20
2.6	APLICAÇÕES DE REDES NEURONais EM PROCESSOS DE PERFURAÇÃO	21
3	MATERIAL E MÉTODOS.....	24
3.1	UNIDADE PILOTO DE CONTROLE DA PRESSÃO ANULAR DE FUNDO	24
3.2	METODOLOGIA EXPERIMENTAL	35
3.3	DETERMINAÇÃO TOPOLOGICA	38
3.4	MODELAGEM	39
3.5	DETERMINAÇÃO DOS PARÂMETROS DO CONTROLADOR CLÁSSICO - PI.....	40
3.5.1	Método da curva de reação	40
3.5.2	Método de Sundaresan & Krishnaswamy	41
3.5.4	Estimação dos parâmetros do controlador PI	41
4	RESULTADOS E DISCUSSÕES.....	42
4.1	TREINAMENTO DA REDE NEURONAL	42
4.2	MODELAGEM DA REDE NEURONAL	45
4.3	MODELAGEM REDE NEURONAL INVERSA	49
4.3.1	ESTIMAÇÃO DOS PARÂMETROS DO CONTROLADOR PI.....	52
4.4	CONTROLE VIA REDE NEURONAL	52
4.4.1	Controlador via rede neuronal – método indireto.....	52
4.4.2	Controlador via rede neuronal inversa – método direto	65
5	CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS	72
6	REFERÊNCIA BIBLIOGRAFIA	73
	ANEXOS	80
	ANEXO A	81
	ANEXO B	83
	ANEXO C	97
	ANEXO D	111
	ANEXO E	115
	ANEXO F	127
	ANEXO G	132
	ANEXO H	135

1 INTRODUÇÃO

A perfuração de poços de petróleo é realizada através do movimento rotativo transmitido à broca pela coluna de perfuração. O fluido de perfuração, injetado através da coluna de perfuração, escoa pelos orifícios da broca, ascendendo à superfície pelo anular, pela linha do *choke*. Além de ser responsável por resfriar e lubrificar a broca, o fluido de perfuração tem como função carrear os cascalhos advindos do processo da perfuração para a superfície, reduzindo o atrito entre as paredes do poço e da coluna de perfuração; e estabilizar as paredes do poço mecânicamente e quimicamente. Além disso, é de suma importância que tal fluido exerça uma pressão no poço superior à pressão dos fluidos contidos nos poros da formação a fim de evitar a ocorrência de *kick* (THOMAS, 2001).

Durante a perfuração, a pressão anular de fundo ou *bottom hole pressure* (BHP) deve ser mantida dentro da janela operacional (Figura 1), definida por um valor mínimo (pressão de poros) e um valor máximo (pressão de fratura). Para os casos em que a pressão é menor que a pressão nos poros do reservatório, ocorrerá invasão dos fluidos nativos em direção ao poço. Se o influxo no sentido do reservatório para o poço for controlável o poço encontra-se no estado de *kick*, se incontrolável, diz-se que o poço está em *blowout*. De forma contrária, haverá a perda de circulação caracterizada pela perda de fluido de perfuração para a formação rochosa (GRACE, 1994; ROCHA & AZEVEDO, 2009; THOMAS, 2001).

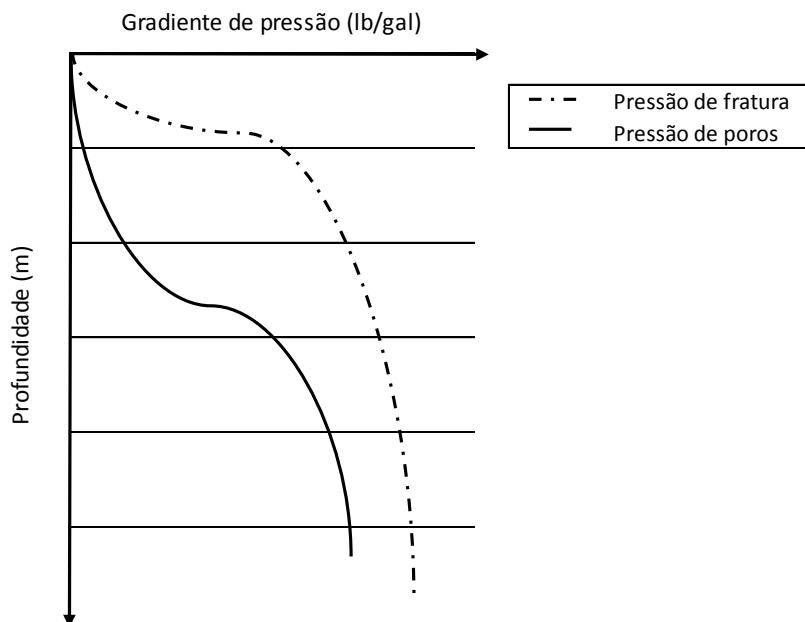


Figura 1 – Janela operacional. Fonte: Adaptado de Rocha & Azevedo, 2009.

O balanço da pressão entre o poço e o reservatório é uma condição de grande importância na fase da perfuração. Se a pressão no fundo do poço (*bottomhole pressure*) for maior que a pressão do reservatório, a perfuração é denominada *overbalanced*, também conhecida como perfuração convencional. Esse tipo de operação faz com que a lama de perfuração penetre nos poros da formação (perda de circulação), danificando-o. A perfuração *overbalanced* é o método mais utilizado visto que os riscos de influxos são minimizados. Quando um fluido é desenvolvido intencionalmente para ter um peso menor que a pressão da formação a ser perfurada a perfuração é considerada *underbalanced* (UBD). Este tipo de perfuração leva à minimização dos danos provocados ao reservatório, fazendo com que haja um aumento na taxa de produção do poço posteriormente. Esta técnica tem sido amplamente

empregada nos EUA e no Canadá. No Brasil, alguns poços foram perfurados empregando tal técnica, dentre os quais podemos citar as regiões do Nordeste, na Bacia do Paraná e na Região Amazônica (SHAYEGI & LOVORN, 2007; CUNHA, et al., 1999).

O *Managed Pressure Drilling* (MPD) é uma técnica utilizada para controlar a pressão no fundo do poço durante a perfuração; detectar rapidamente influxos da formação para o interior do poço; etc. Caso haja algum tipo de influxo este será circulado e a condição *overbalanced* será restaurada. O MPD é largamente aplicado para lidar com problemas de *kick* ou perda de circulação em regiões com fraturas, aumentar a taxa de penetração (ROP) e prolongar a vida útil da broca. Esse método apresenta alta aplicabilidade em sistemas que apresentam estreitas janelas operacionais onde é necessário manter a pressão de fundo constante (*Constant Bottom Hole Pressure - CBHP*) (NAS et al., 2010; GODHAVN, 2010; SHAYEGI & LOVORN, 2007).

A IADC (*International Association of Drilling Contractors*) define o MPD como processo de perfuração adaptado para controlar o perfil de pressão ao longo do poço para garantir que a pressão no fundo esteja entre os limites da janela operacional. Este pode ser subdividido nas seguintes classes: CBHP (*Constant Bottom Hole Pressure*), PMCD (*Pressurized Mud Cap Drilling*), DGD (*Dual Gradient Drilling*) e RFC (*Return Flow Control*). Dentre essas técnicas, o CBHP é a mais utilizada tendo como objetivo manter a pressão especificada constante em um dado ponto, denominado ponto de ancoragem (GREIN et al., 2017; SHAYEGI & LOVORN, 2007; NAS et al., 2010). A aplicação da técnica MPD necessita da utilização de equipamentos adicionais à operação de perfuração. O *Rotating Control Device* (RCD) é o principal deles, o qual é empregado para proporcionar um sistema fechado durante o processo de perfuração. O RCD proporciona a aplicação de uma leve contrapressão, resultando em uma pressão de fundo constante. Os equipamentos do MPD podem ser instalados tanto em unidades de perfuração marítimas quanto nas terrestres, desde que obedeçam os critérios recomendados para instalação desses equipamentos. Uma das principais razões que fazem com que essa técnica seja atrativa para o mercado, oferecendo maior eficiência e custo benefício é a capacidade do MPD de promover uma redução do tempo não-produtivo (*Non-Productive Time – NPT*) da sonda durante a construção de um poço, seja ele terrestre ou marítimo. Atualmente, com a construção de poços cada vez mais profundos, faz com que o MPD se torne uma opção mais comum e assertiva para garantir a viabilidade técnica e econômica de projetos, alcançando maior eficiência no controle de poços e oferecendo maior segurança à operação.

Diferentemente do MPD manual, onde a abertura da válvula *choke* é realizada por um operador manualmente, o MPD automático utiliza um sistema de controle para abrir ou fechar a válvula *choke* sem qualquer tipo de interação manual (NAS et al., 2010; GODHAVN, 2010). Outro ponto a ser considerado durante a etapa da perfuração é o procedimento recorrente de conexão de tubos. Neste procedimento, as bombas são desligadas e o bombeio de fluido é interrompido, assim o BHP reduz como resposta à redução do ECD (*equivalent circulatting density*). O processo de parada e retomada das bombas afeta severamente o perfil de pressão, fazendo com que haja flutuações de pressão que excedem os limites da janela operacional. Utilizando o MPD essa perda de pressão é compensada pela pressão na superfície. Uma vez retomado o bombeio, a pressão na superfície é reduzida, mantendo desta forma o BHP constante (NAS et al., 2010; MARTIN, 2006).

Com o intuito de aprimorar os processos de perfuração de poços de petróleo, cresce a demanda pelo desenvolvimento de novas tecnologias e metodologias capazes de otimizar e controlar tais procedimentos de forma eficaz. Neste cenário, Grein et al. (2017) desenvolveram um simulador MPD utilizando um modelo hidráulico explícito e uma estratégia de controle não linear que utiliza a abertura da válvula *choke* para regular o ECD no ponto de ancoragem. Com os testes de validação realizados em uma unidade piloto de perfuração, o modelo hidráulico

desenvolvido pelos pesquisadores, acoplado à estratégia de controle, fez com que o simulador apresentasse aplicação viável em tempo real. Além disso, a rede neuronal artificial (RNA) surge como uma técnica vantajosa quando comparada com os principais modelos de controle conhecidos. A RNA pode ser caracterizada como um modelo não linear, sendo esta, útil na representação de dados de entrada/saída, na realização de previsões temporais, na classificação de dados e no reconhecimento de padrões. Além disso, não necessita da especificação de sua estrutura *à priori*, apresentando modelos mais flexíveis (HIMMELBLAU, 2000).

De acordo com Irawan et al. (2009), o modelo de rede neuronal tem sido aplicado com sucesso a vários campos da engenharia de petróleo como: engenharia de reservatório, estimativa de permeabilidade, caracterização da heterogeneidade do reservatório, entre outros. As redes neurais artificiais são modelos computacionais inspirados no sistema nervoso central humano, e são utilizadas para estimar ou aproximar funções que dependem de muitas entradas (ZAHEDI & ROUNAGHI, 2015). Dashevskiy, Dubinsky & Macpherson (1999) apresentaram uma RNA para modelar o comportamento dinâmico do sistema de perfuração não linear com múltiplas entradas e saídas. Tal modelo juntamente com um algoritmo de otimização, forneceu recomendações apropriadas de ação corretiva para levar o sistema à uma condição ótima de perfuração. Ramgulam, Ertekin & Flemings (2007) em seu estudo de simulação e otimização, propuseram um aprimoramento no desenvolvimento e treinamento de uma rede neuronal artificial capaz de prever propriedades do reservatório a partir de dados históricos. Devido a falta de uma regra clara para realizar as previsões das propriedades do reservatório, os autores aplicaram o procedimento de tentativa e erro. Além disso, reportou-se que algumas das estruturas da rede desenvolvida mostraram-se eficientes ao serem aplicadas a um reservatório localizado no campo de Tahoe, no Golfo do México. Mohaghegh et al. (1995) desenvolveram uma rede neuronal artificial capaz de predizer com precisão a permeabilidade de formações rochosas utilizando dados provenientes de poços geofísicos. Para isto, fizeram uso de variáveis capazes de fornecer informações sobre a permeabilidade. Além disso, levaram em conta a existência de padrões entre as variáveis utilizadas e a permeabilidade da formação, condição crucial para a obtenção de resultado satisfatório. Ahmadi et al. (2015) desenvolveram novos métodos baseados em inteligência artificial atrelados à ferramenta de exame de partículas (PSO) para prever de maneira precisa a produtividade de poços horizontais em condições pseudo-estacionário. Os autores reportaram a obtenção de uma boa correspondência entre a saída da modelagem e os dados reais obtidos da literatura.

A partir dessa ótica, o presente trabalho busca sintetizar controladores baseados em rede neuronal para regular em linha o processo de perfuração frente os fenômenos de *kick* de gás, perda de circulação e procedimentos de conexão de tubos, empregando a variação CBHP do MPD. O índice de abertura da válvula *choke* foi empregado como variável manipulada no controle da pressão anular de fundo (BHP). A avaliação do procedimento de conexão de tubos será realizada considerando a interrupção da circulação da lama de perfuração para o interior do poço empregando uma contrapressão, assim como nas operações reais em que o MPD é utilizado para manter a pressão de fundo constante. Neste caso, não foram considerados os problemas de pistoneio e falta de reposição de lama no interior do poço, os quais também são problemas de grande relevância durante tal procedimento. O desenvolvimento do estudo do controle da pressão anular de fundo frente a uma situação de *kick* de gás baseia-se na manutenção da perfuração na presença do *kick* realizando o controle da pressão simultaneamente. Análogo ao *kick*, pretende-se mitigar a perda de circulação através da manutenção da pressão pelo controle via *choke*, sem a necessidade de ser realizar a troca de fluido de perfuração como nos procedimentos clássicos.

Modelos teóricos de escoamentos multifásicos que sofrem variação de padrão de fluxo ao longo do anular tem sido desenvolvidos (CARVALHO et al., 2018; LI et al., 2018; PATRÍCIO et al., 2018; SHAO et al., 2018; TURNEY et al., 2018; YOU e RAHNEMA, 2018;

ZHOU et al., 2018; GHOBADPOURI et al., 2017; KHEZRIAN et al., 2015; KHORIAKOV et al., 2012). Estudos que utilizam ferramentas inteligentes de interpretação de dados em tempo real podem ser vistos em AHMED et al, 2016; ALMEIDA et al., 2010; AZADPOUR et al., 2015; GANDELMAN et al., 2009; SANTOS et al., 2010; ZHAO et al, 2009; MAROOKA et al., 2009. Tendo em vista a disponibilidade de dados em tempo real estes serão empregados nas estratégias de identificação, controle e modelagem do processo de perfuração, em tempo real, empregando redes neurais. Além disso, as metodologias de modelagem e controle serão validadas em unidade experimental de perfuração de poços de petróleo.

2 REVISÃO BIBLIOGRÁFICA

2.1 O processo de perfuração de poços

Durante a perfuração de poços de petróleo, o fluido de perfuração é bombeado através da coluna de perfuração até a broca, e retorna para a superfície pela região anular formada pela coluna de perfuração e pelas paredes do poço. Dessa forma, os cascalhos formados pela perfuração retornam à superfície, sendo carreados pelo fluido de perfuração (lama). Uma vez na superfície, a mistura fluido-cascalho é submetida a um processo de separação a fim de viabilizar a reutilização do fluido (THOMAS, 2001). A Figura 2 ilustra um esquema simplificado de uma sonda de perfuração.

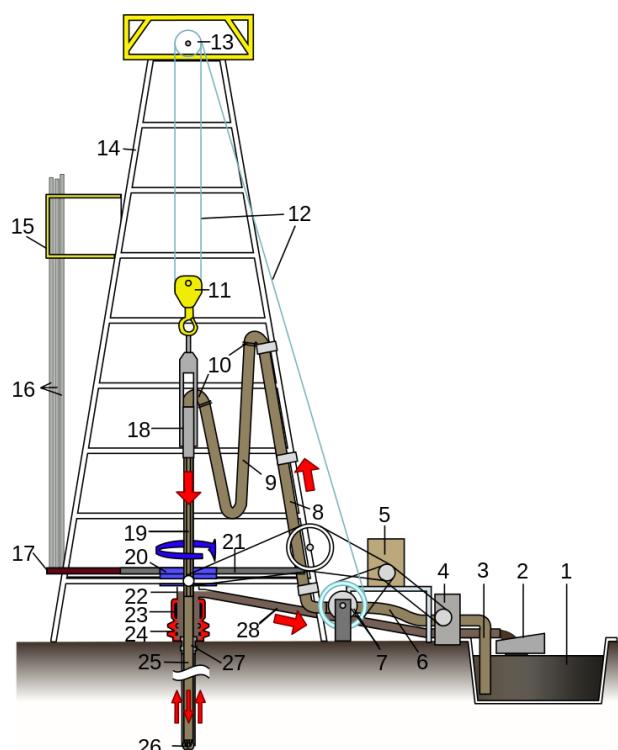


Figura 2 – Esquema simplificado de uma sonda de perfuração.

Onde:

- | | |
|----------------------------------|---------------------------------------|
| 1. Tanque de lama de perfuração; | 15. Monkey board; |
| 2. Agitadores; | 16. Stand do duto de perfuração; |
| 3. Linha de sucção de lama; | 17. Pipe rack; |
| 4. Bomba do sistema de lama; | 18. Cabeça de injeção ou Swivel; |
| 5. Motor; | 19. Kelly; |
| 6. Mangueira vibratória; | 20. Mesa rotativa; |
| 7. Draw-works; | 21. Superfície de perfuração; |
| 8. Standpipe; | 22. Bell nipple; |
| 9. Mangueira de perfuração; | 23. Anulo do Blowout preventer (BOP); |
| 10. Goose-neck; | 24. Dutos do blowout preventer; |
| 11. Travelling block ou Catarina | 25. Coluna de perfuração; |
| 12. Cabo de perfuração; | 26. Broca de perfuração; |
| 13. Bloco de coroamento; | 27. Cabeça do casing; |
| 14. Derrick; | 28. Duto de retorno da lama. |

A coluna de perfuração consiste de vários segmentos de tubos unidos entre si. Na medida em que se perfura o poço, novos segmentos de tubos são adicionados por meio do procedimento de conexão de tubos. Tal procedimento é realizado quando o topo do *Kelly*, responsável por transmitir o movimento rotativo à coluna de perfuração, atinge a mesa rotativa. A nova seção de tubo é então adicionada junto à mesa rotativa em um orifício auxiliar para a conexão. A próxima etapa envolve a elevação do *Kelly* até que o primeiro tubo de perfuração apareça. Neste momento coloca-se a cunha na coluna para que seu peso seja sustentado pela mesa rotativa. Em seguida, desconecta-se o *Kelly* da coluna e o conecta a seção de tubo a ser adicionado. Feito isso, eleva-se o conjunto *Kelly* / tubo conectando-os à coluna. Por fim, retira-se a cunha e desce o *Kelly* até que o mesmo atinja a mesa rotativa, retornando a perfuração. Durante este procedimento a circulação de fluido de perfuração é mantida para que seja mantida a pressão hidrostática do poço, entretanto se faz necessária a correção da densidade da lama (THOMAS, 2001).

Nygaard et al. (2006) descreve o procedimento de conexão de tubos em cinco etapas: inicialmente desliga-se a rotação da coluna, posteriormente interrompe-se o bombeio do fluido de perfuração. Em seguida, um novo segmento de tubo é adicionado. Retoma-se o bombeamento da lama de perfuração e, finalmente, a rotação da coluna. Este procedimento causa flutuações na quantidade de fluido que é bombeado, alterando a pressão anular de fundo (BHP) e, assim, atuando como fonte de distúrbios.

Os sistemas de perfuração de poços de petróleo podem ser caracterizados pelo balanceamento entre a pressão exercida pelo fluido de perfuração contra a parede do poço e a pressão de poros na área da formação. A atuação das respectivas pressões acontece na região anular compreendida entre a coluna de perfuração e a parede do poço. Diversos fenômenos impactam diretamente na pressão anular de fundo durante a perfuração, tais como: remoção ineficiente de sólidos; desmoronamento do poço; aumento do comprimento do poço; parâmetros do reservatório; e o procedimento de conexão de tubos.

Vieira et al. (2009) reporta que para compensar as flutuações de pressão, podem ser modificadas, entre outras, a densidade do fluido de perfuração; a vazão de entrada do fluido de perfuração e a velocidade de perfuração. Entretanto, a pressão no poço não é modificada instantaneamente, uma vez que existe um tempo para que as variações sejam sentidas ao longo de todo o poço. Para compensar tais flutuações de pressão, Vega et al. (2008) relataram que, modificar a abertura da válvula *choke*, situada na superfície, produz uma rápida resposta na variável controlada, ou seja, na pressão anular de fundo (VEGA et al., 2018; VEGA et al., 2012).

2.2 Modelo do tubo em U

No campo petrolífero, a configuração de tubo em U é utilizada para representar de maneira simplificada a perfuração de um poço. O sistema de circulação ilustrado na Figura 3 representa o sistema de perfuração baseado na configuração do Tubo em U. Pode-se observar que o lado esquerdo do tubo em U representa a coluna de perfuração enquanto o lado direito respesta a região anular. A união das duas seções realizadas no fundo do tubo em U é representada pela broca de perfuração (GRACE, 1994).

Em uma situação estática, a pressão de fundo (BHP) será dada pela soma das pressões exercida pelo fluido na coluna de perfuração e na região anular. Por outro lado, se as pressões da região anular e coluna de perfuração não forem iguais dois cenários são possíveis de ocorrer. No primeiro caso, se o poço estiver aberto, o fluido escoará para a região de mais baixa pressão até que o equilíbrio seja atingido. No segundo caso, quando o poço encontra-se fechado, a diferença de pressão aparecerá na superfície (GRACE, 1994).

Diferentes modelos tomando como base a configuração do tubo em U são empregados para descrever sistemas de circulação, como apresentado na Figura 3. Com isso Stamnes et al. (2008) desenvolveram um observador baseado em modelo não linear para estimar a pressão na broca (ou no fundo do poço) durante a perfuração. O desenvolvimento de tal modelo considerou uma única fase no fluido de perfuração.

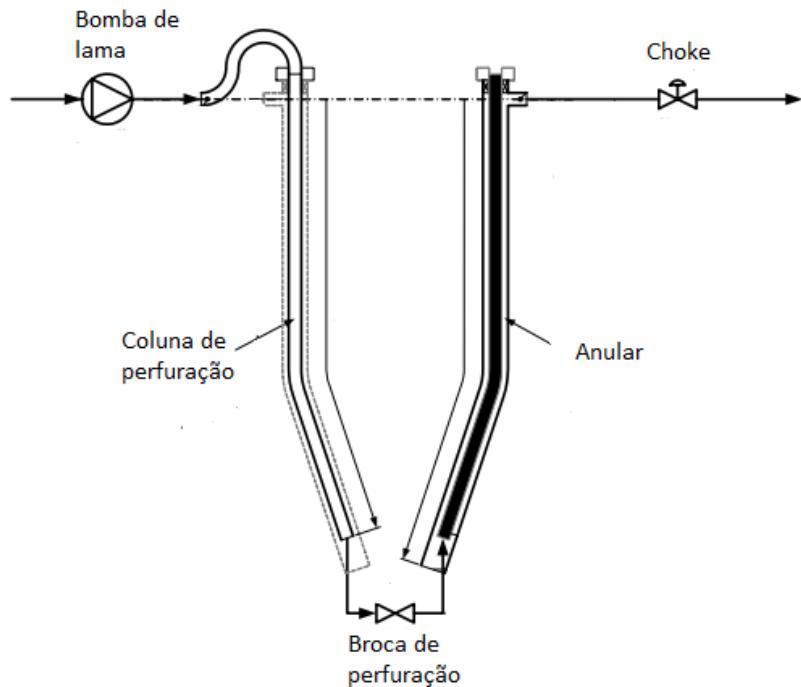


Figura 3 – Representação do modelo do tubo em U. Fonte: Adaptado de Stamnes et al., 2008.

2.2 Controle na perfuração de poços

O controle da pressão anular de fundo é de suma importância para que as trocas de fluido entre o anular e o reservatório sejam evitadas. Essa pressão pode ser manipulada pelo controle dos parâmetros físico-químicos do fluido, pela variação da frequência imposta à bomba ou pelo controle da abertura da válvula *choke*, posicionada na saída do anular (BOURGOYNE Jr. et al., 1991).

A fase de controle durante o processo de perfuração de poços é uma das fases que requerem uma maior atenção, visando a segurança de recursos humanos, ambientais e a segurança do próprio poço. Lyons (1996) reporta a existência de três níveis bem distintos de controle de poços, quais sejam: controle primário - exercido pela densidade da lama cuja pressão hidrostática deve ser mantida superior à pressão das formações; controle secundário - caso o controle primário sobre as formações seja perdido, a formação começa a produzir e o controle sobre o poço só é mantido com o fechamento das válvulas de segurança, vedando o espaço anular; e controle terciário - quando o controle do poço a nível secundário não pode ser mantido, o controle da formação só é alcançado através de medidas especiais. Grace (1994) reporta que, durante a perfuração de um poço, quando há incompatibilidade das pressões SICP (diferença de pressão entre a formação e a pressão hidrostática no anular quando um *kick* ocorre) e SIDP (diferença de pressão entre o fundo do poço e a pressão hidrostática no tubo de perfuração) procedimentos de controle clássicos não são aplicáveis, visto que o modelo de tubo em U não descreve mais a realidade. Normalmente, este tipo de discordância de pressões está

interligado com o fenômeno de *kick* ou perda de circulação durante a perfuração. Quando isto ocorre, manter a pressão da coluna de perfuração constante apresenta-se como uma das técnicas de maior sucesso, entretanto, nessas condições deve-se analisar e avaliar a situação em que o poço se encontra para que sejam tomadas ações apropriadas. No método clássico de controle de pressão, as pressões SICP e SIDP são registradas no momento em que se fecha o poço quando um *kick* é detectado.

Controlar a pressão anular de fundo durante o processo de perfuração é uma tarefa desafiadora. Grande esforço tem sido aplicado ao desenvolvimento de modelos mais avançados capazes de capturar, por exemplo, aspectos hidráulicos do fluido de perfuração. Rommetveit & Vefring (1991) realizaram um estudo de comparação entre os resultados de um simulador de kick de gás e dados em escala real. Com o objetivo de avaliar o desempenho do modelo, foram realizadas simulações de kick de gás em lama a base água e a base óleo. Além disso, foram empregados dados reais de superfície e fundo do poço na validação do simulador. Petersen, Rommetveit & Tarr (1998) apresentaram um trabalho de modelagem e simulação de um poço na presença de *kick* e perda de circulação em águas profundas como ferramenta para projetar situações complexas de controle de poços. Hansen et al. (1999) propuseram um modelo para prever a perda de pressão na perfuração poços estreitos. O modelo construído combinando uma abordagem numérica e experimental incorporou os efeitos de excentricidade, rotação da coluna de perfuração e reologia.

Bjorkevoll et al. (2000) realizaram uma análise de dados de perfuração utilizando um modelo avançado de pressão e temperatura. Tal modelo foi empregado no estudo detalhado da perfuração de dois poços no Mar do Norte. No mesmo ano Lage & Time (2000) desenvolveram um modelo para prever o comportamento da mistura bifásica para o fluxo ascendente em um anular concêntrico. As previsões do modelo desenvolvido foram validadas a partir de dados experimentais coletados da literatura. Além disso, foi realizada uma investigação experimental em grande escala em um poço vertical localizado no complexo de pesquisa da Petrobras, Brasil. Com isso pode-se concluir que o modelo apresentou desempenho satisfatório em relação aos dados experimentais.

Bjorkevoll et al. (2003) desenvolveram um modelo capaz de predizer a queda de pressão no anular tendo como informações de entrada as características do fluido obtidas através do reômetro. Além disso, o modelo desenvolvido foi integrado a um modelo transiente de transporte de massa para levar em conta os efeitos de compressibilidade do fluido e o comprimento do poço. Lage et al. (2003) apresentaram um modelo dinâmico para tratar fenômenos transitentes durante operações do tipo *underbalanced*. As previsões do modelo foram validadas através da comparação de dados experimentais aplicando-se situações transitentes distintas. Nygaard et al. (2004a) apresentaram uma metodologia para controlar a pressão anular de fundo durante o procedimento de conexão de tubos em poços predominantemente gasosos. A metodologia desenvolvida emprega o modelo dinâmico de escoamento de fluido no poço e a interação dinâmica poço-reservatório. A metodologia de controle empregada pelos autores baseou-se na estratégia de controle preditivo não linear baseado em modelo (NMPC – *Non-Linear Model Predictive Control*). Os autores reportaram que a estratégia de controle baseada em modelo pode ser utilizada no desenvolvimento de sistemas de controle automatizado e integrado à taxas de bombeio da bomba e à *choke* para perfurações em operação *underbalanced*. Já Nygaard et al. (2004b) investigaram a possibilidade de se utilizar uma metodologia de controle automático para manter a pressão do poço dentro dos limites críticos, a partir da aplicação de um modelo transiente poço/reservatório. A partir do exposto, os autores reportaram que a metodologia proposta é promissora como uma ferramenta para se controlar a pressão durante o procedimento de conexão de tubos. Nygaard (2006) e Nygaard et al. (2007) propuseram a utilização de um modelo de baixa ordem para estimar e controlar o BHP, onde um filtro de Kalman é avaliado

para a estimativa dos parâmetros do reservatório durante a perfuração de poços. Godhavn (2009) estudou a utilização do controle PID nos processos de perfuração. Breyholtz et al. (2009) propuseram a utilização do controlador preditivo (MPC – *Model Predictive Control*) para controlar a pressão utilizando a técnica DGD (*Dual Gradient Drilling*), onde a pressão de fundo foi considerada conhecida e desconsiderou-se a ocorrência de *kick*.

GODHAVN (2010) apresentou alguns resultados da aplicação do MPD no campo de Kvitebjorn no Mar do Norte além de levantar discussão a respeito da aplicação de controle automático nas operações de perfuração. Kaasa et al. (2011) estimaram a pressão de fundo utilizando um modelo hidráulico simplificado baseado em fluidodinâmica básica. Zhou & Nygaard (2011) desenvolveram um esquema de controle para estabilizar a pressão durante a perfuração utilizando a variação DGD (*Dual Gradient Drilling*) do MPD. Vega et al. (2012) apresentaram metodologias de controle e monitoramento da pressão anular de fundo, com o objetivo de evitar flutuações de pressão fora dos limites da janela operacional, garantindo desta forma condições de operação seguras. Nandan & Imtiaz (2017) propuseram um controlador preditivo não linear (NMPC) para sistema de perfuração do tipo MPD. O controle de vazão age automaticamente para regular a pressão anular de fundo frente a um kick através da variação CBHP (*Constant Bottom Hole Pressure*) do MPD. Além da mitigação do kick o controlador proposto mostrou bom desempenho em assegurar a pressão anular de fundo (BHP) durante o procedimento de conexão de tubos. Pedersen et al. (2018) avaliaram a utilização do controle preditivo não linear (NMPC) para controlar a pressão e vazão durante a perfuração *underbalanced*. O sistema de controle multivariado manipula a pressão na *choke*, a vazão da bomba e o *setpoint* simultaneamente para atingir a pressão desejada no fundo e no topo do poço. A estratégia de controle NMPC mostrou-se eficiente mesmo em face grandes mudanças no sistema até mesmo numa abordagem *overbalanced*.

2.3 Trabalhos desenvolvidos na unidade piloto de perfuração de poços de petróleo do LEF/ UFRRJ

O desenvolvimento de pesquisas sobre o estudo e controle da pressão anular de fundo durante a operação de perfuração de poços, utilizando a unidade piloto de perfuração de poços de petróleo do LEF/ UFRRJ (Laboratório de Escoamento de Fluidos – Giulio Massarani / Universidade Federal Rural do Rio de Janeiro), reportada neste trabalho, iniciou-se com Vieira (2009), seguido por Freitas (2013), Russano (2014), Patrício (2016), Costa (2016) e Carvalho (2018). Apesar de todos os trabalhos terem o objetivo comum de controlar a pressão anular de fundo, cada autor analisou os diversos fenômenos inerentes ao processo de forma distinta, caracterizando a evolução dos estudos desenvolvidos até o presente momento.

Vieira (2009), em seu trabalho, propôs o desenvolvimento de um modelo matemático fenomenológico monofásico tendo como objetivo a implementação de controle clássico PI, usando a vazão da bomba de lama como variável manipulada. Vieira observou que o controle da pressão anular de fundo (BHP) foi bem sucedido tanto para testes do tipo servo quanto para teste regulador. Além disso, foi identificada a natureza não linear da unidade experimental empregada. Dando continuidade, em 2013, Freitas desenvolveu uma metodologia dinâmica para controle de influxos de líquido (*kick*), durante a perfuração de poços de petróleo, dotada de um esquema de reconfiguração de controle, usando o índice de abertura da válvula *choke* como variável manipulada. O desenvolvimento da metodologia dinâmica proposta foi capaz de determinar eficientemente o valor da pressão da formação através do monitoramento da vazão de *kick* de líquido. Além disso, a metodologia desenvolvida mostrou-se vantajosa em relação aos métodos tradicionais visto que não há necessidade de adensamento da lama de perfuração uma vez que o aumento de pressão é realizado via abertura da válvula *choke*.

Russano (2014) implementou um esquema de controle empregando reconfiguração (*feedback-feedforward*), via manipulação da válvula *choke*, visando à rejeição de perturbação de

carga (perda de circulação). O controle da pressão anular de fundo ocorreu de forma satisfatória em todas as situações analisadas, demonstrando ser vantajoso o uso do esquema de reconfiguração da lei de controle para rejeição de distúrbio significativo de perda de circulação. Além disso, não houve necessidade de diminuição da densidade do fluido de perfuração, uma vez que a redução da pressão é efetuada via abertura da válvula *choke*, o que reduz o tempo necessário para controle do distúrbio.

Oliveira et al. (2015) sintetizaram uma estratégia de controle clássico *feedback* para estudar a dinâmica de perfuração de poços a fim de estabilizar a pressão anular de fundo tendo como variável manipulada a velocidade de injeção de fluido na coluna de perfuração. Levando em conta os atrasos inerentes ao processo, foi implementado um esquema de controle preditivo PI obtendo uma maior eficiência na estabilização da pressão frente ao controlador clássico PI.

Patrício (2016) desenvolveu uma estratégia com reconfiguração da lei de controle *feedback↔feedforward* para rejeitar o distúrbio de *kick* de gás além de realizar estudos de simulação a partir da construção de modelo matemático fenomenológico. Patrício observou que o controle de *kick* de gás através da estratégia de controle *feedback* não foi bem sucedido devido a dificuldade de se manter a pressão anular de fundo dentro da janela operacional uma vez que houve perda de circulação simultânea ao *kick*. Por outro lado, a estratégia por reconfiguração mostrou ser eficiente controlando o *kick* de gás mantendo a pressão anular de fundo dentro da janela operacional. Além disso, o emprego de tal estratégia fez com que não fosse observada perda de circulação como no emprego da estratégia *feedback*.

Costa (2016) a fim de controlar a pressão anular de fundo durante o processo de cimentação fez uso de uma estratégia de controle *feedback* clássico tendo como variável manipulada o índice de abertura da válvula *choke*. Em todos os tipos de cimentação avaliados a ação do controlador foi eficaz, mantendo a pressão anular de fundo no setpoint desejado mesmo na presença de perturbações.

Carvalho (2018) propôs um esquema de controle capaz de controlar as diversas etapas do ciclo Convencional/PMCD (*Pressurized Mud Cap Drilling*) através de um controlador por realimentação (*feedback*) com reconfiguração da variável manipulada (*choke*) e vazão de *bullheading* sendo capaz de adaptar-se às diferentes etapas inerentes ao processo de perfuração em zonas altamente fraturadas.

De fato, o desenvolvimento de pesquisas a respeito do controle da pressão na perfuração de poços de petróleo é amplamente explorado em trabalhos de modelagem e simulação. Entretanto, o emprego de uma unidade piloto de perfuração de poços capaz de representar diversos fenômenos, em tempo real, mostra-se de suma importância para o desenvolvimento de novas técnicas de controle.

2.4 Rede Neuronal Artificial

As redes neurais artificiais (RNA's) são sistemas de computação adaptativos inspirados nas características de processamento de informação encontradas nos neurônios biológicos. São formadas por um conjunto de neurônios artificiais que interagem entre si, assemelhando-se ao cérebro humano em dois fatores: primeiro, o conhecimento é adquirido pelas redes neurais através de um aprendizado do seu ambiente; o segundo fator diz respeito às forças das conexões entre os neurônios, denominadas pesos sinápticos, que são utilizadas para armazenar o conhecimento adquirido (ARBIB, 2003; HAYKIN, 2009).

O neurônio é a unidade básica de processamento de informação fundamental em uma rede neuronal. A Figura 4 ilustra esquematicamente um modelo de neurônio não linear. (HAYKIN, 2009; HUNT et al., 1992)

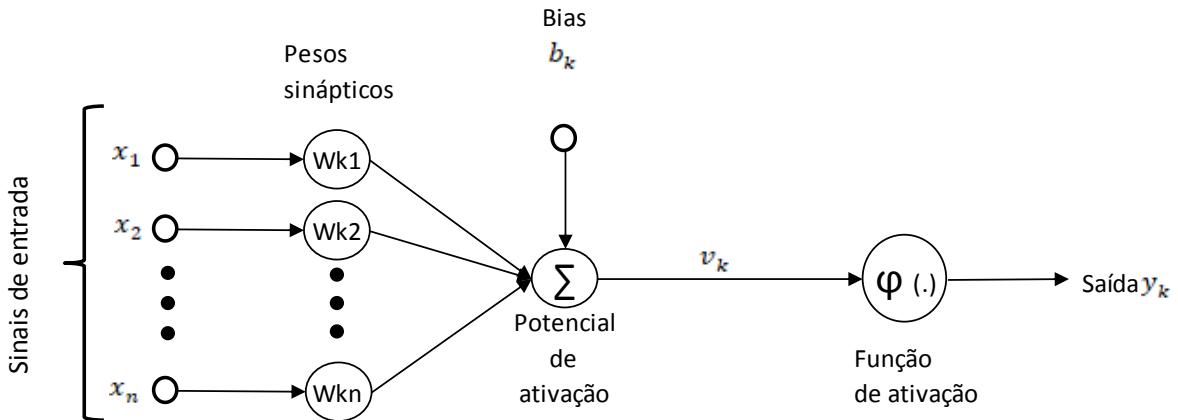


Figura 4 - Modelo não linear de um neurônio. Fonte: Adaptado de Haykin, 2009.

Matematicamente, este neurônio é descrito pelo potencial de ativação do neurônio (v_k) (Equação 1), sendo este calculado pelo somatório dos sinais de entrada (x_i) ponderados com os respectivos pesos (w_{ki}) e o valor do *bias* (b_k). A saída do neurônio (Equação 2) é definida pelo potencial de ativação aplicado à função de ativação $\varphi(v_k)$.

$$v_k = \sum_{i=1}^n x_i w_{ki} + b_k \quad (1)$$

$$y_k = \varphi(v_k) \quad (2)$$

2.4.1 Histórico

O estudo das redes neuronais teve início em 1943 com Warren McCulloch e Walter Pitts que propuseram um modelo matemático capaz de descrever o neurônio biológico. Em 1949, Donald Hebb desenvolveu a conhecida Regra de Hebb e Frank Rosenblatt, em 1958, desenvolveu e introduziu uma grande classe de RNA's denominadas PERCEPTRONS. Em 1960, Bernard Widrow e Marcian E. Hoff desenvolveram o Adaline, um rápido e preciso sistema de aprendizagem adaptativo sendo treinado pela Regra Widrow-Hoff, também conhecida como regra delta. Contudo, as análises matemáticas desenvolvidas por Minsky e Papert (1969) sobre o PERCEPTRON demonstraram que tal modelo não era capaz de representar problemas mais complexos fazendo com que as pesquisas na área fossem desacreditadas e consequentemente levando a um decaimento nas pesquisas sobre o tema. Entre 1972 e 1982, apesar da baixa popularidade das RNA's, estudos ainda eram realizados. Em 1972, Kohonen introduziu um modelo de associação linear e em 1982, descreveu os mapas de auto-organização, com capacidade de organizar dimensionalmente dados complexos em grupos, conhecido como mapas de Kohonen. Em 1974, Paul Werbos desenvolveu o procedimento de aprendizagem denominado retropropagação do erro (*back-propagation*) o qual mais tarde (1986) foi apresentado por Rumelhart, Hinton & Williams, fazendo com que os estudos das redes neuronais artificiais fossem retomados, sendo aplicadas às mais diversas áreas do conhecimento (HAYKIN, 2009).

2.4.2 Arquitetura

A arquitetura é determinante na capacidade de processamento de uma rede. Para que o treinamento seja bem sucedido é necessário realizar a correta escolha do número de conexões a serem utilizadas. Existem diversos tipos de redes neuronais, mas a que melhor se ajusta para modelar a dinâmica dos processos é a configuração *feedforward*. Além deste tipo de configuração têm-se, também, as redes de recorrência (HAYKIN, 2009; FAUSETT, 1994).

A configuração *feedforward* é assim denominada porque a informação flui da camada de entrada para a camada de saída. A camada de entrada não realiza nenhum tipo de

processamento, ela simplesmente contém os valores de entrada para rede. Elas podem ser subdividida em rede de camada simples ou rede de múltiplas camadas (ARBIB, 2003; HAYKIN, 2009).

A rede *feedforward* de camada simples é a forma mais simples de arquitetura, nela uma camada de entrada projeta-se diretamente em uma camada de saída de neurônios. Geralmente, neste tipo de configuração os neurônios são lineares. Na configuração *feedforward* de múltiplas camadas podem existir uma ou mais camadas ocultas, cujos nós de computação são denominados neurônios ocultos. Tais neurônios têm como função atuar entre a entrada de sinais externos e a saída da rede, capacitando-a a aprender tarefas complexas, extraíndo progressivamente as características mais significativas dos padrões de entrada. Com o aumento do número de neurônios ocultos a rede torna-se mais sensível, ou seja, aumenta-se o número de conexões sinápticas e de interações. Na Figura 5 é apresentada uma rede do tipo *feedforward* com uma camada de neurônios ocultos (ARBIB, 2003; HAYKIN, 2009; HUNT et al., 1992).

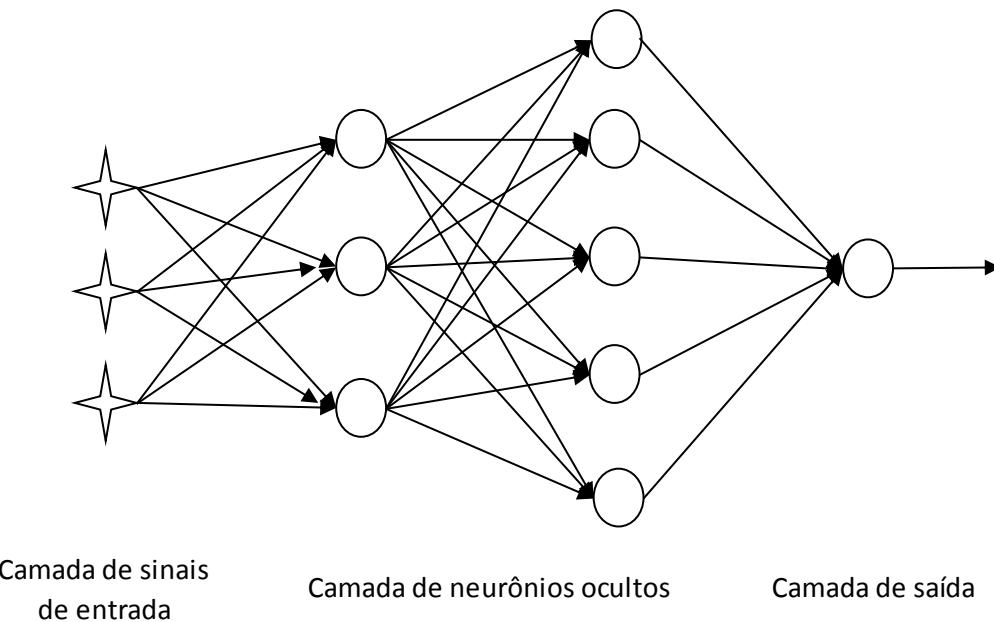


Figura 5 – Rede neuronal multicamada. Fonte: Adaptado de Haykin, 2009.

O vetor de dados externos inseridos na camada de entrada constitui os sinais de entrada para os neurônios da segunda camada. Os sinais de saída da segunda camada são utilizados como entrada na terceira camada e assim sucessivamente. Desta forma, os sinais de saída dos neurônios da última camada constituem a resposta da rede frente ao padrão de ativação fornecido pelos nós de entrada da primeira camada (ARBIB, 2003).

A maioria dos casos de aplicação de redes neurais requer o uso de redes de múltiplas camadas, onde cada saída é uma função não linear de funções não lineares admitidas pelos neurônios ocultos. As redes de múltiplas camadas modelam implicitamente os dados durante o treinamento, de modo que uma previsão válida seja realizada quando a rede, já treinada, for posteriormente apresentada a um novo valor de vetor de entrada. As redes podem aprender a partir dos exemplos fornecidos e até mesmo generalizar o conhecimento aprendido. Como dito anteriormente, a rede exibe altos níveis de conectividade, determinados pelas sinapses da mesma, assim uma mudança na sua conectividade exigirá, consequentemente, uma alteração nos seus pesos (VAZ et al., 2016).

As redes de recorrência, por possuírem realimentação, respondem a estímulos de forma dinâmica, ou seja, após aplicar uma nova entrada, a saída é calculada e então realimentada para modificar a entrada. Este tipo de rede é rotineiramente chamado de “rede com memória”. A sua

estrutura não é obrigatoriamente organizada em camadas e caso seja, podem apresentar interligações entre neurônios da mesma camada e entre camadas não consecutivas. A presença de *loops feedback* representa um alto impacto em sua capacidade de aprendizagem e performance. A Figura 6 ilustra a arquitetura de uma rede com recorrência sem *loops* do tipo *feedback* e sem neurônios ocultos (ARBIB, 2003; HAYKIN, 2009).

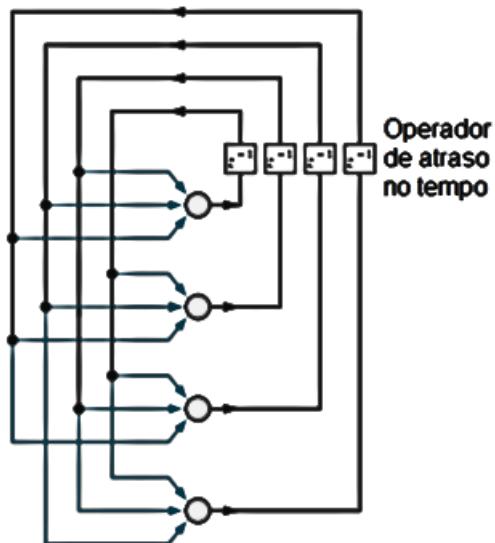


Figura 6 - Rede neuronal recorrente sem *loop feedback*. Fonte: Adaptado de Haykin, 2009.

2.4.3 Construção das redes neurais

A construção de uma rede neuronal requer que sejam levados em consideração pontos importantes para que o algoritmo de treinamento apresente uma boa performance. Dentre eles podemos destacar a forma como os pesos sinápticos são inicializados, a normalização dos dados de entrada e saída, o domínio dos pares de entrada-saída, a forma da superfície do erro e a forma da função erro (NGUYEN et al., 2013; VEGA, LIMA & PINTO, 2008).

- A inicialização dos pesos sinápticos deve ser feita de forma aleatória. A escolha de tais pesos influencia como a rede alcança o erro local ou global e quanto rápida é a convergência do método utilizado.
- Os dados de entrada e saída devem ser normalizados para que o aprendizado seja acelerado, a não normalização geraria acréscimos nas sinapses com ordens de grandeza distintos o que levaria à obtenção de mínimos locais;
- O domínio dos pares de entrada-saída deve caracterizar amplamente o domínio de operação do sistema físico que se deseja identificar. Um conjunto de pares de entrada-saída muito grande dificulta e torna lento o treinamento;
- Uma superfície de erro é definida pela relação da função custo versus os pesos das sinapses. Caso a RNA contenha apenas neurônios lineares, a superfície de erro será uma função quadrática, contendo um único mínimo global. Porém, se a RNA for formada por neurônios não lineares, a superfície de erro pode conter múltiplos mínimos locais. Caso a forma da função erro não seja quadrática, é possível a ocorrência de vários mínimos locais, além do mínimo global, para uma RNA típica contendo apenas uma camada oculta de neurônios. Deve-se atentar para o caso de uma superfície plana visto que esta produz uma derivada de pequena magnitude, levando a um pequeno ajuste dos pesos e consequentemente muitas iterações para a redução do índice de desempenho, fazendo com que o treinamento fique paralisado;

- Quando o valor numérico do erro é grande, a função erro pode apresentar oscilações, que podem ser reduzidas com a diminuição da taxa de aprendizado, indicando a obtenção de um mínimo local. Entretanto, quando o valor numérico do erro é pequeno a função erro se apresenta na forma de um decaimento exponencial, sem oscilações, indicando a obtenção de um mínimo global.

2.4.4 Funções de ativação

De acordo com Haykin (2009) e Fausett (1994), as funções de ativação mais amplamente aplicadas são do tipo *sigmoide* (logística ou tangente hiperbólica) isto porque apresentam a propriedade de serem diferenciáveis, característica relevante para o algoritmo de treinamento.

A função logística é a função de ativação mais utilizada na construção das RNA's, podendo assumir valores contínuos entre 0 e 1 (Equação 3). A função de ativação tangente hiperbólica, descrita pela Equação 4, é um tipo de função sigmoidal que apresenta vantagens analíticas em relação à logística por poder assumir valores negativos.

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (3)$$

$$\varphi(v) = \tanh(v) \quad (4)$$

2.4.5 Treinamento

Existem diversos algoritmos de treinamento que diferem entre si pela forma como os pesos sinápticos são ajustados (método do gradiente descendente, aprendizado de Hebbian, aprendizado competitivo, entre outros). Outro fator importante é a forma pela qual a rede se relaciona com o meio ambiente, podendo ser dividida em aprendizado supervisionado e não supervisionado (ARBIB, 2003; FAUSETT, 1994). No aprendizado supervisionado a rede neuronal não possui conhecimento sobre o meio ao qual está inserida, desta forma ela é exposta a um vetor de treinamento criado a partir do meio de inserção. Seus parâmetros são ajustados através da combinação do vetor de treinamento e o sinal de erro, sendo este definido como a diferença entre a resposta desejada e a resposta atual da rede. Este ajuste é realizado iterativamente, sendo todo “conhecimento” adquirido armazenado na forma de pesos sinápticos fixos. Já no aprendizado não supervisionado as saídas da rede não são conhecidas *a priori*, o treinamento acontece a partir da distinção das classes de padrões diferentes apresentados à rede (HAYKIN, 2009; ARBIB, 2003; FAUSETT, 1994).

A etapa de treinamento é realizada repetidamente para um conjunto de exemplos diversos, até que o estado estacionário seja atingido onde não ocorrerão alterações significativas dos pesos sinápticos. Assim, a fase de aprendizagem é considerada como a adaptação dos pesos sinápticos da rede a valores adequados.

O treinamento pode ser classificado em aprendizado em batelada ou por reconhecimento de padrões. No aprendizado em batelada, os pesos são ajustados depois de uma varredura completa de todos os dados de treinamento, enquanto que no aprendizado por reconhecimento de padrões os pesos são atualizados constantemente a cada passo no tempo, ou seja, *on-line*. Matematicamente, o aprendizado em batelada apresenta uma melhor validade frente ao aprendizado por reconhecimento de padrões, isto porque a primeira técnica implementa de forma exata o método de redução do gradiente. Em contrapartida, a segunda técnica é vantajosa por poder ser implementada *on-line* (GAO, WANG & LI, 2000).

A eficiência de cada um dos dois métodos de treinamento depende do problema avaliado. Como o processo de treinamento é mantido até que haja a estabilização dos pesos e o erro quadrático médio seja suficientemente pequeno para que o objetivo desejado seja atingido,

deve-se encontrar um ponto ótimo de parada do treinamento com erro mínimo e máxima capacidade de generalização.

Buscando-se a máxima capacidade de generalização e o menor erro para o treinamento, emprega-se a validação cruzada, uma técnica estatística clássica útil para determinar a capacidade de generalização de uma RNA. Para a aplicação de tal técnica, os dados de treinamento deverão ser subdivididos em dois conjuntos distintos, o conjunto de treinamento e o conjunto de validação. Segundo a metodologia clássica descrita por Haykin (2009), o conjunto de treinamento, utilizado para treinar a rede deverá ser composto por 50% das amostras disponíveis; e o conjunto de validação composto por 25% das amostras disponíveis. A divisão das amostras em dados para treinamento e validação garante que não haverá o problema de super treinamento, o que acarreta em uma má capacidade de generalização da rede.

A realização do treinamento é feita tomando-se um número de iterações (épocas) pré-definido. Ao fim do número de épocas, o treinamento é interrompido e a rede é testada com dados inéditos para sua validação. Este procedimento é repetido até que o desempenho da rede frente os dados de validação se estabilizem em um valor aceitável para o problema avaliado, neste caso observa-se o erro gerado, quanto menor os valores melhor será a resposta da rede frente aos novos dados apresentados a ela.

2.4.6 Algoritmo *Back-propagation*

O algoritmo de retro propagação do erro – *back-propagation* (BP) - também conhecido como a generalização da regra delta, utiliza a técnica de gradiente descendente para minimizar o erro quadrático médio entre a saída desejada e a obtida pela rede, através do ajuste dos pesos sinápticos. O treinamento pelo algoritmo BP envolve três estágios: alimentação dos padrões de treinamento; cálculo e retro propagação do erro associado; e ajuste dos pesos sinápticos (ARBIB, 2003; FAUSETT, 1994).

Durante a propagação do sinal de entrada, cada unidade de entrada recebe o sinal e o transmite para cada uma das unidades ocultas. Cada neurônio oculto, então, calcula seu nível de ativação. O sinal produzido por cada neurônio oculto é enviado para o neurônio da camada subsequente, neste caso para o neurônio da camada de saída. Assim como cada neurônio na camada oculta, os neurônios na camada de saída calculam seu sinal de ativação para formar a resposta da rede frente ao padrão de entrada fornecido.

Na fase de retro propagação do erro, os neurônios da camada de saída compararam o valor calculado do nível de ativação com o valor desejado para determinar o erro associado para aquele padrão alimentado. Baseado em tal erro, o fator δ (gradiente local) é calculado para todas as interconexões realizadas. Tal fator é utilizado para distribuir o erro da camada de saída para a camada de entrada através das camadas ocultas (neste caso será atualizado o peso entre a camada oculta e a camada de entrada). Depois que todos os δ foram determinados, os pesos (w) de todas as camadas são atualizados simultaneamente. A Figura 7 ilustra a etapa de propagação caracterizada pelas linhas cheias pretas e a etapa de retro propagação do sinal do erro, caracterizada pelas linhas pontilhadas em azul.

Tal algoritmo emprega uma taxa de aprendizagem (η), capaz de influenciar a velocidade de ajuste dos pesos durante a otimização. Quanto menor a taxa de aprendizagem, menores serão as modificações nos pesos das sinapses de uma iteração para a outra e mais suave será a trajetória de minimização da superfície de erro. Entretanto, se a taxa de aprendizagem for muito alta as mudanças nos pesos se tornarão altas o suficiente ao ponto de fazer com que a rede apresente oscilações, caracterizando um sistema instável. Desta forma, busca-se utilizar uma taxa de aprendizado capaz de aumentar a velocidade de aprendizado sem levar a oscilações. (HAYKIN, 2009)

Uma maneira de se aumentar a taxa de aprendizado evitando-se o perigo da instabilidade é incluir o termo momento na regra delta (Equação 5). A incorporação do termo momento (α) ao algoritmo de retro propagação leva a uma modificação mínima na atualização dos pesos. Contudo, sua incorporação fornece o benefício de prevenir que o processo de aprendizagem termine em um mínimo local na superfície de erro.

$$\Delta\omega_{ji}(n) = \alpha\Delta\omega_{ji}(n - 1) + \eta\delta_j(n)y_i(n) \quad (5)$$

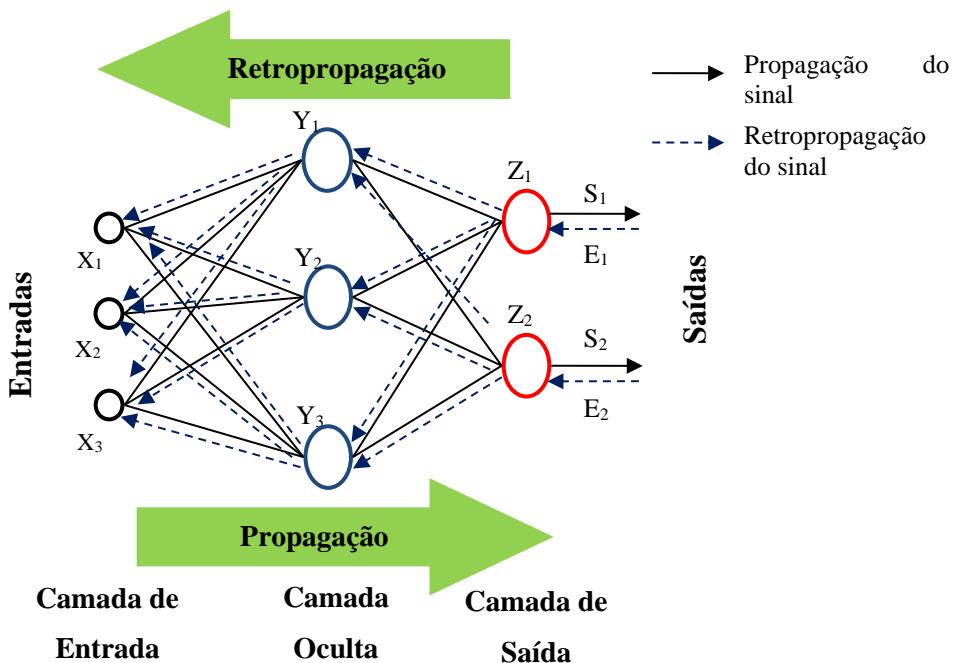


Figura 7 – Propagação e retro propagação do erro. Fonte: Adaptado de Haykin, 2009.

2.4.6.1 Algoritmo

- Neurônio na camada de saída

Tomando como base a Figura 8 que descreve o neurônio de saída j sendo alimentado por um conjunto de sinais produzidos por uma camada de neurônios dispostos a sua esquerda (neurônios ocultos), Haykin (2009) descreve o algoritmo de treinamento supervisionado *on-line* baseado na retro propagação do erro – *back-propagation*.

É importante frisar que o treinamento *on-line* possui como vantagem a redução das chances de obtenção de um mínimo local, devido a sua natureza estocástica.

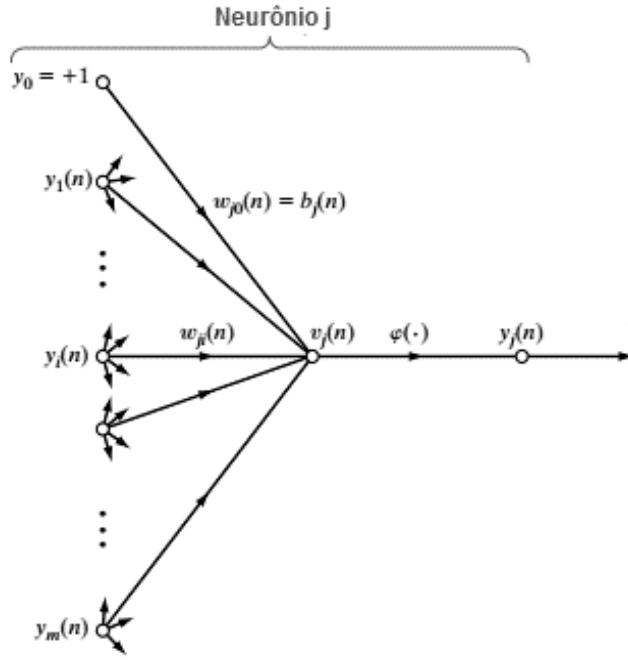


Figura 8 – Representação do neurônio de saída j . Fonte: Adaptado de Haykin, 2009.

O potencial de ativação associado ao neurônio j é dado por:

$$v_j(n) = \sum_{i=0}^m y_i(n)w_{ji}(n) \quad (6)$$

Onde m é o número total de entradas aplicadas ao neurônio j , excluindo-se a contribuição do *bias*. O peso sináptico w_{j0} corresponde a entrada fixa $y_0 = +1$, equivalente ao *bias* (b_j) aplicado ao neurônio j . Desta forma, o sinal de saída após a n -ésima iteração é dada por:

$$y_j(n) = \varphi_j(v_j(n)) \quad (7)$$

O algoritmo BP baseia-se na aplicação de uma correção do tipo $\Delta\omega_{ji}(n)$ (Equação 8) aplicada ao peso $\omega_{ji}(n)$, sendo esta proporcional a derivada parcial do erro em relação ao peso sináptico, $\frac{\partial \varepsilon(n)}{\partial \omega_{ji}(n)}$. O gradiente do erro em relação ao peso, representa o fator de sensibilidade que determina a direção da busca do peso sináptico $\omega_{ji}(n)$ na superfície de pesos. Com isso, as atualizações dos pesos sinápticos da rede são realizadas segundo a Equação 9.

$$\Delta\omega_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial \omega_{ji}(n)} \quad (8)$$

$$\omega(n+1) = \omega_{ji}(n) + \Delta\omega_{ji}(n) \quad (9)$$

Aplicando-se a regra da cadeia ao gradiente do erro em relação ao peso obtem-se

$$\frac{\partial \varepsilon(n)}{\partial \omega_{ji}(n)} = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial \omega_{ji}(n)} \quad (10)$$

O sinal de erro produzido na saída do neurônio j é definido por:

$$e_j(n) = d_j(n) - y_j(n) \quad (11)$$

Somando a contribuição do erro de todos os neurônios na camada de saída, obtém-se a expressão para o sinal de erro total da rede, caracterizado pela Equação 12. O termo C corresponde a todos os neurônios da camada de saída.

$$\varepsilon(n) = \sum_{j \in C} e_j(n)^2 \quad (12)$$

Assim,

$$\frac{\partial \varepsilon(n)}{\partial e_{ji}(n)} = 2e_{ji}(n) \quad (13)$$

$$\frac{\partial e_{ji}(n)}{\partial y_j(n)} = -1 \quad (14)$$

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi_j'(v_j(n)) \quad (15)$$

$$\frac{\partial v_j(n)}{\partial \omega_{ji}(n)} = y_i(n) \quad (16)$$

Substituindo as Equações 12, 13, 14, 15 e 16 em 10, obtém-se a seguinte expressão ilustrada na Equação 17.

$$\frac{\partial \varepsilon(n)}{\partial \omega_{ji}(n)} = -2e_j(n)\varphi_j'(v_j(n))y_i(n) \quad (17)$$

O gradiente local - $\delta_j(n)$ - é descrito pela Equação 18.

$$\delta_j(n) = e_j(n)\varphi_j'(v_j(n)) \quad (18)$$

Desta forma, o gradiente do erro em relação ao peso pode ser reescrito como ilustra a Equação 19.

$$\frac{\partial \varepsilon(n)}{\partial \omega_{ji}(n)} = -2\delta_j(n)y_i(n) \quad (19)$$

- Neurônio na camada oculta

Quando o neurônio está localizado na camada oculta, não existe uma resposta desejada para comparação. Admitindo-se que haja um neurônio de saída j imediatamente conectado ao neurônio oculto k (Figura 9), o gradiente local (δ) para o neurônio oculto será dado pela Equação 20, onde o índice j diz respeito ao neurônio de saída j .

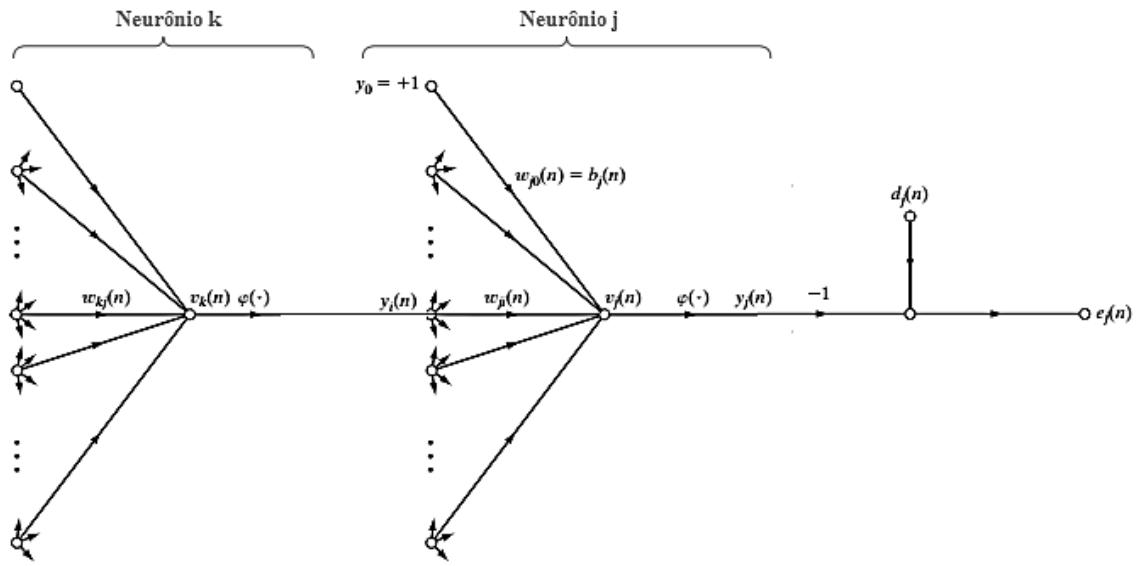


Figura 9 – Neurônio j conectado ao neurônio oculto k . Fonte: Adaptado de Haykin, 2009.

$$\delta_k(n) = -\frac{\partial \varepsilon(n)}{\partial y_k(n)} \frac{\partial y_k(n)}{\partial v_k(n)} \quad (20)$$

Reordenando e substituindo-se as equações de interesse podemos escrever as Equações 21- 26.

$$\delta_k(n) = -\frac{\partial \varepsilon(n)}{\partial y_k(n)} \varphi'_k(v_k(n)) \quad (21)$$

$$\varepsilon(n) = \sum_{j \in C} e_j(n)^2 \quad (22)$$

$$\frac{\partial \varepsilon(n)}{\partial y_k(n)} = 2 \sum_k e_j(n) \frac{\partial e_j(n)}{\partial y_k(n)} \quad (23)$$

$$\frac{\partial \varepsilon(n)}{\partial y_k(n)} = 2 \sum_j e_j(n) \frac{\partial e_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial y_k(n)} \quad (24)$$

$$e_j(n) = d_j(n) - y_j(n) \quad (25)$$

$$e_j(n) = d_j(n) - \varphi_j(v_j(n)) \quad (26)$$

Assim, define-se a Equação 27.

$$\frac{\partial e_j(n)}{\partial v_j(n)} = -\varphi'_j(v_j(n)) \quad (27)$$

Além disso, a partir das Equações 28-31.

$$v_j(n) = \sum_{k=0}^m y_k(n) w_{jk}(n) \quad (28)$$

$$\frac{\partial v_j(n)}{\partial y_k(n)} = w_{jk}(n) \quad (29)$$

$$\frac{\partial \varepsilon(n)}{\partial y_k(n)} = -2 \sum_j e_j(n) \varphi_j'(v_j(n)) w_{jk}(n) \quad (30)$$

$$\delta_j(n) = e_j(n) \varphi_j'(v_j(n)) \quad (31)$$

Define-se, o gradiente local para o neurônio oculto k pela Equação 32.

$$\delta_k(n) = 2\varphi'_k(v_k(n)) \sum_j \delta_j(n) \omega_{jk}(n) \quad (32)$$

2.5 Neuro-controladores

Um neuro-controlador é caracterizado pelo uso de uma RNA localizada no sistema de controle, apresentando-se como o próprio controlador ou como modelo do processo utilizado para realizar uma ação de controle (Nguyen et al., 2003).

Um controlador neuronal pode ser aplicado quando estão disponíveis dados do comportamento de uma planta, expressos como dados de entrada-saída. Este tipo de aplicação pode ser definido como um modelo de caixa preta, isto porque não se tem disponível um modelo que descreva o comportamento da planta frente a diferentes condições. Além disso, controladores baseados em redes neuronais são beneficiados com a capacidade de aprendizagem sendo útil para o controle adaptativo, visto que neste método é necessária a adaptação frente às mudanças do ambiente (Nguyen et al., 2003).

A construção de um controlador baseado em rede neuronal requer que os parâmetros sejam ajustados a partir dos erros observados entre a saída da planta e a saída desejada. Tal ajuste é realizado pelo método de retro propagação de tal erro através da arquitetura da rede, entretanto este procedimento só apresenta aplicação eficaz se um modelo matemático da planta está disponível. Quando não se tem tal disponibilidade, os dados de entrada-saída utilizados para a treinar a rede geram um modelo aproximado sendo este caracterizado como **modelo identificado pela rede neuronal**, apresentando aplicação no projeto de controle neuronal indireto (Nguyen et al., 2003).

2.5.1 Controle neuronal direto e indireto

O controlador neuronal direto é desenvolvido pela aplicação da modelagem inversa da dinâmica da planta, ou seja, a rede neuronal age diretamente como um controlador. O projeto do controlador neuronal indireto baseia-se no modelo neuronal do sistema a ser controlado. Neste caso, o controlador é desenvolvido a partir da modelagem da planta pela rede neuronal. O desenvolvimento do controlador neuronal indireto envolve duas etapas: a identificação da dinâmica da planta pela rede neuronal utilizando dados de treinamento, caracterizando a identificação do sistema; e o projeto de controle derivado do modelo de identificação neuronal (Nguyen, 2003; Haykin, 2009).

O desenvolvimento de um sistema autônomo requer que o controlador a ser utilizado no processo apresente uma relação inversa com a planta (controle direto). Assim, a identificação do sistema é necessária para que haja estabilização do modelo no qual o controlador a ser desenvolvido estará baseado. O processo de identificação busca produzir um modelo do sistema dinâmico sem conhecimento *a priori* do sistema dinâmico em análise, este procedimento

realizado “às cegas” é denominado modelagem do tipo caixa preta (*black box*). O treinamento realizado a partir desta metodologia produz uma função erro a qual é utilizada no treinamento de uma rede neuronal para captar a saída da planta. Esta função erro deve ser capaz de aproximar o comportamento inverso da planta. A Figura 10 ilustra a identificação do sistema, o erro produzido pela diferença entre a resposta gerada pela planta e pela saída da rede é utilizado para ajustar os parâmetros da rede buscando minimização do erro (Nguyen, 2003; Haykin, 2009).

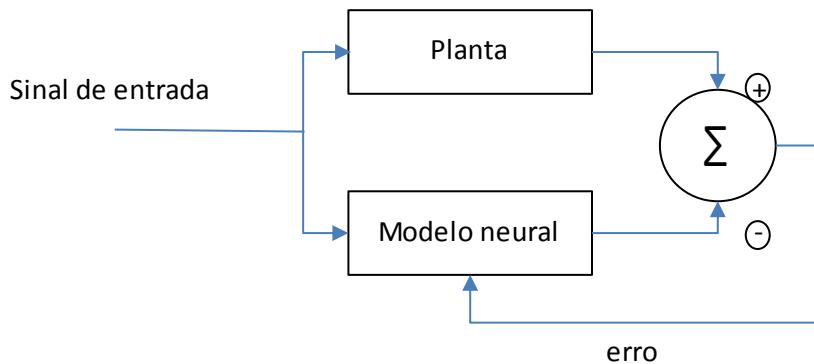


Figura 10 - Diagrama de blocos da identificação de sistemas. Fonte: Adaptado de Haykin, 2009.

A implementação da metodologia de identificação de sistemas engloba quatro etapas. A primeira etapa requer que sejam desenvolvidos experimentos na planta para que sejam coletadas informações a serem utilizadas no treinamento da rede. Em seguida, um modelo de rede deve ser selecionado (sinais de entrada e topologia). O modelo, então, é treinado com os dados adquiridos da planta; após o treinamento, o modelo deve passar pela etapa de validação. Caso os resultados não sejam satisfatórios, diferentes modelos de rede podem ser testados. Por outro lado, se o conjunto de dados coletados não for suficiente, o desenvolvimento satisfatório de um modelo se tornará uma tarefa difícil de se realizar, assim novos experimentos na planta deverão ocorrer para que dados adicionais sejam computados. Quando a identificação de sistemas é implementada como parte de um controlador, este é definido como controlador adaptativo. Tais controladores são desenvolvidos para sistemas cuja dinâmica varia no tempo (Nguyen, 2003; Haykin, 2009).

2.6 Aplicações de redes neurais em processos de perfuração

Uma pesquisa na literatura mostra que não há trabalhos desenvolvidos empregando-se redes neurais artificiais com o intuito de controlar a pressão anular de fundo (BHP) durante o processo de perfuração de poços de petróleo. Além disso, não foi encontrado trabalhos empregando uma unidade piloto de perfuração de poços de petróleo capaz de reproduzir fenômenos reais, o que evidencia o caráter inédito deste trabalho de dissertação de mestrado. Assim, são apresentados trabalhos em que são empregadas redes neurais como modelos de predição nas mais diversas áreas que englobam o processo de perfuração.

O desenvolvimento de atividades de perfuração em águas profundas e ultraprofundas tem aumentado os desafios inerentes ao processo visto a dificuldade de se obter importantes parâmetros, como, por exemplo o gradiente de fratura da rocha. Desta forma, Akin et al (2006) propuseram um método rápido e preciso para a predição de funções de fluxo multifásico ao longo do intervalo produtivo de um reservatório a fim de predizer propriedades petrofísicas. Neste trabalho, a técnica proposta combinava medidas com escalas de comprimento. Além

disso, os tipos de poros da formação rochosa foi predito usando uma rede neuronal artificial retro-propagada treinada com dados de poros medidos. Zhang et al. (2016) apresentaram uma rede neuronal com algoritmo de aprendizagem baseado na retropropagação do erro utilizando algoritmo de otimização genético (BPNN-GA – *backpropagation neural network with genetic algortihm*) na predição do estresse geológico, baseado na pressão do poço, em teste de fraturamento hidráulico durante a perfuração. O modelo híbrido proposto mostrou ser superior ao modelo básico nas predições realizadas. Okpo et al. (2016) desenvolveram um estudo de predição de parâmetros geomecânicos, utilizando redes neurais, a fim de determinar a estabilidade de poços. O modelo neuronal desenvolvido empregou uma rede do tipo *feedforward* com uma única camada oculta onde esta era dotada de dez neurônios. O estudo desenvolvido mostrou-se eficiente em ajudar os engenheiros de perfuração a estimar a estabilidade/instabilidade de poços não somente durante o planejamento da perfuração mas também durante a perfuração empregando uma análise em tempo real. Alizadeh et al. (2015) desenvolveram um nova técnica de predição de fraturas empregando redes neurais. Neste trabalho os autores desenvolveram uma rede do tipo *feedforward* com algortimo *backpropagation* de aprendizagem a qual foi capaz de predizer dados de fratura satisfatoriamente. Além disso, os autores reportaram que o modelo foi capaz de simular a relação entre as fraturas de três poços distintos localizados no campo de Gachsaran.

Ardekani e Shadizadeh (2013) desenvolveram um modelo de estimativa do tempo de perfuração no campos de petróleo ao sul do Irã. Neste estudo os autores utilizaram um modelo baseado em redes neurais artificiais e o compararam a um modelo de regressão linear múltipla, o qual é mais utilizado. Os resultados demonstraram a acurácia do modelo neuronal em relação ao modelo de regressão linear múltipla apesar deste ser o mais utilizado. Esim e Yildirim (2016) apresentaram uma investigação a respeito da condição da coluna de perfuração durante o processo de perfuração utilizando redes neurais para testar e solucionar problemas de vibração decorrentes dos cascalhos gerados no processo. Os resultados apontaram que a predição realizada pelas redes radiais apresentaram performance superior quando comparadas às redes por *backpropagation*.

A hidráulica no processo de perfuração é um fator de grande relevância para o processo, uma vez que tais informações permitem o cálculo dos perfis de pressão ao longo do poço além de contribuir para a segurança e integridade do mesmo. Assim, Rooki (2016) empregou uma rede neuronal de regressão genérica (GRNN – *general regression neural network*) para predizer a perda de pressão relacionada à utilização de fluido não - Newtoniano do tipo Herschel – Bulkley em anulares com geometrias concêntricas e excêntricas. Neste estudo foi implementada uma rede com três camadas, sendo uma camada de entrada, uma camada de neurônios ocultos e uma camada de saída. Frente aos resultados apresentados pode-se observar que a rede apresentou bom desempenho na predição da perda de pressão no escoamento em anulares com geometrias distintas. Bassam et al. (2015) determinaram quedas de pressão em poços geotérmicos utilizando rede neurais e ferramentas de simulação de poço. Neste trabalho, uma nova abordagem de predição baseada em redes neurais e simulação numérica de poços foi realizada com sucesso. Vale ressaltar que os modelos neurais desenvolvidos empregaram o algoritmo de otimização Levenberg – Marquardt, além das funções tangente hiperbólica e linear como funções de ativação para as redes desenvolvidas.

Acerca dos sistemas de controle empregando redes neurais, Hunt et al. (1992) discutem sobre a aplicação das redes neurais artificiais no âmbito da modelagem, identificação de sistemas, além de apresentar discussão sobre as técnicas de controle não-linear e adaptativo de sistemas empregando uma abordagem teórica. Outras discussões acerca da aplicação de redes neurais na área de controle podem ser encontradas em Narendra (1996), Himmelblau (2000), Gao et al. (2000)

Com respeito a modelagem empregando redes neuronais artificiais, Hayajneh et al. (2009) desenvolveram um estudo de modelagem da usinabilidade de compósitos híbridos autolubrificantes de alumínio / alumina / grafite sintetizados por metalurgia do pó. No presente trabalho, foi empregada uma rede neuronal do tipo *feedforward* com algoritmo de aprendizagem *backpropagation* para avaliar a influência de certos parâmetros na força de empuxo e torque no processo de perfuração. Com os resultados os autores puderam concluir a excelência das redes neurais como uma ferramenta analítica de predição. Spesivtsev et al. (2018) desenvolveram um modelo preditivo para a pressão anular de fundo em poços de escoamento multifásico, utilizando o aprendizado de máquina (*machine learning*). Neste trabalho, a rede neuronal desenvolvida foi treinada utilizando dados gerados por um simulador numérico. A partir dos resultados percebe-se que a rede neuronal proposta, dotada de duas camadas ocultas, demonstrou ser capaz de predizer a pressão anular de fundo satisfatoriamente.

3 MATERIAL E MÉTODOS

3.1 Unidade piloto de controle da pressão anular de fundo

A unidade piloto utilizada para retratar o processo de perfuração de poços de petróleo, está localizada no Laboratório de Escoamento de Fluidos – Giulio Massarani – LEF - na Universidade Federal Rural do Rio de Janeiro (UFRRJ) nas dependências do Departamento de Engenharia Química. A unidade experimental possui sensores em linha de vazão, densidade, nível e pressão. Para o controle da pressão anular de fundo, podem ser empregadas, como variáveis manipuladas, a rotação da bomba (acionada via inversor de frequência) e o índice de abertura da válvula *choke*.

Experimentalmente podem ser retratados diversos fenômenos que ocorrem durante o processo de perfuração. A estrutura da tubulação, que contém as seções de perfuração e anular, é representada através da configuração do tubo em U, separada através de uma válvula que impõe a restrição ao escoamento típica de uma broca de perfuração. A tubulação em “U”, representando a coluna de perfuração, possui 5,73 m, com trecho de escoamento descendente, onde o fluido escoa verticalmente até o fundo do poço. O trecho de escoamento ascendente representa a região anular com diâmetro hidráulico igual ao diâmetro da coluna. Na extremidade superior da região anular encontra-se a linha do *choke*, onde está instalada uma válvula de controle pneumática, representando-a. A unidade experimental possui, ainda, um tanque de pressão, retratando a rocha reservatório, acoplado ao anular, através do qual é possível estudar o fenômeno de *kick* pelo influxo de líquido ou gás do reservatório para o anular e o problema de perda de circulação pela invasão de fluido no reservatório. Água foi utilizada como fluido de perfuração em todos os experimentos realizados. A Figura 11 ilustra a adaptação da unidade experimental a fim de representar o processo real de perfuração. Como pode ser observado a configuração do tubo em U foi utilizada mantendo a similaridade com o processo real. A Figura 12 ilustra um esquema da unidade experimental. Na Figura 13 é apresentado um diagrama da unidade de perfuração que representa o aparato experimental utilizado neste trabalho de dissertação de mestrado.

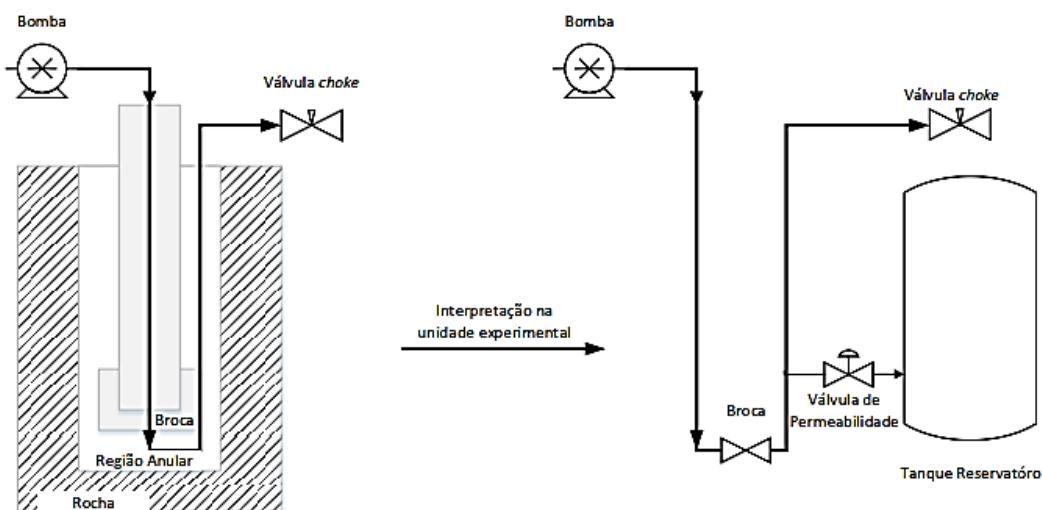


Figura 11 – Esquema de adaptação da unidade experimental em relação ao processo de perfuração de poços. Fonte: Russano, 2014.



Figura 12 – Esquema da unidade experimental de controle.

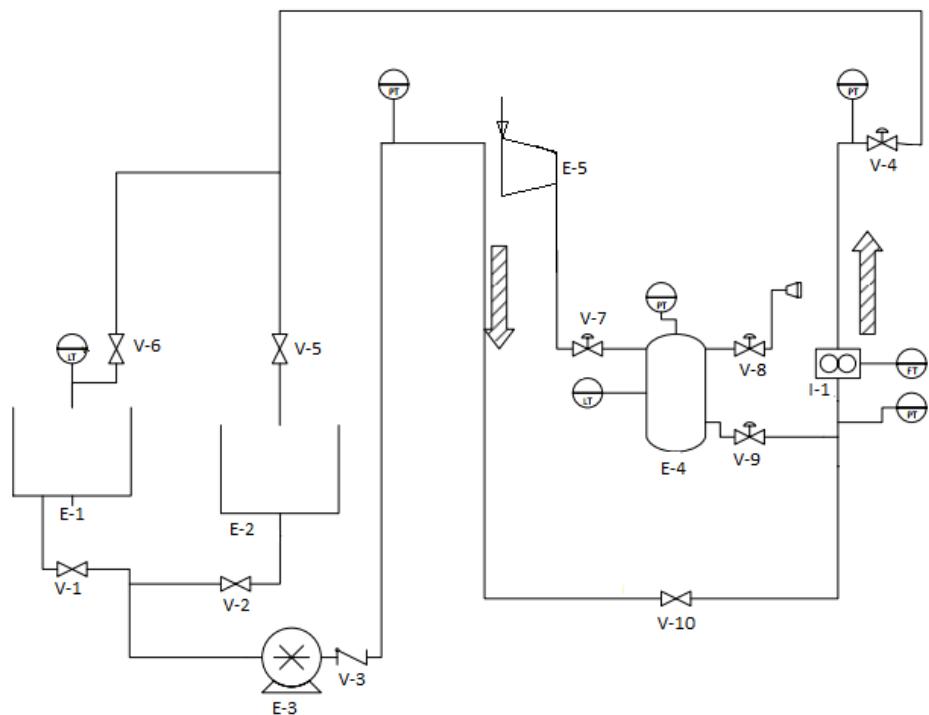


Figura 13 – Diagrama P&ID da unidade experimental de perfuração de poços: E-1: Tanque de nível; E-2: Tanque de água; E-3: Bomba principal; E-4: Tanque reservatório; E-5: Compressor de ar; I-1: Medidor de vazão e densidade; V-1, V-2, V-5, V-6: Válvulas esfera; V-3: Válvula de retenção; V-4: Válvula choke (válvula de controle acionada pneumaticamente); V-7, V-8: Válvula de entrada/ saída de ar; V-9: Válvula de permeabilidade; V- 10: Válvula gaveta (Broca); PT: Sensor/Transmissor de pressão; LT: Sensor/Transmissor de nível; FT: Sensor/Transmissor de vazão.

A unidade de perfuração (Figura 12) é dotada de duas bombas helicoidais de deslocamento positivo, modelo Weatherford de 6 HP e pressão de recalque de 12 kgf/cm². A velocidade de rotação dos motores é manipulada através de inversores de frequência, marca WEG modelo CFW08. A primeira bomba (Figura 14), denominada bomba principal, é responsável por alimentar a coluna de perfuração. A segunda bomba ou bomba secundária (Figura 15), denominada bomba de lama, possibilita a alimentação de cascalhos (lama pesada/leve) na região anular (indicado pela seta em destaque na Figura 12), representando os cascalhos produzidos durante a fase de perfuração. A montante das bombas foram instalados manômetros para a leitura da pressão de descarga das mesmas.



Figura 14 - Bomba helicoidal de deslocamento positivo (Bomba principal).



Figura 15 - Bomba helicoidal de deslocamento positivo (Bomba secundária).

A leitura de pressão da unidade é realizada através do transdutor de pressão manométrica da SMAR modelo LD301-M, ilustrado na Figura 16. São coletados dados de pressão para o fundo do poço (após o acoplamento coluna/ tanque reservatório), para a bengala e para a linha do choke.

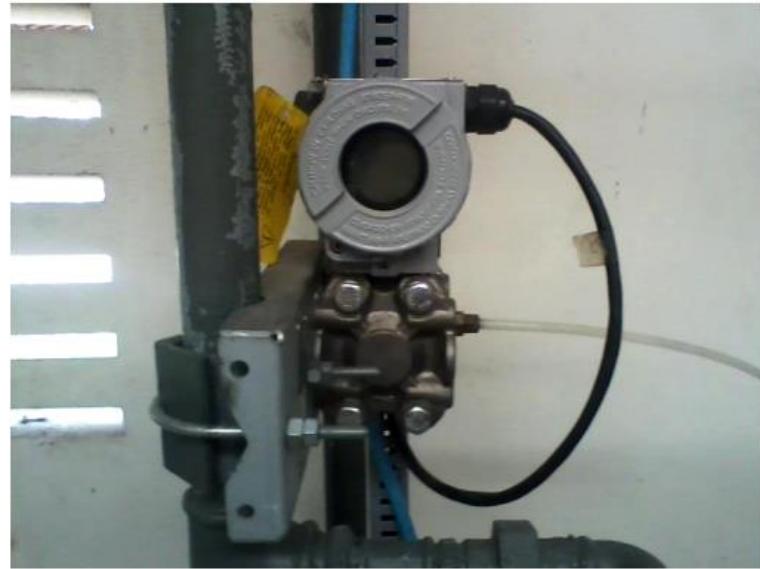


Figura 16 – Transdutor de pressão.

A Figura 17 ilustra a válvula de controle proporcional ASCO, modelo 290PD-25MM, equipada com um posicionador de alimentação pneumática, que representa a válvula *choke*.



Figura 17 – Válvula *choke*.

A leitura da vazão é realizada através do medidor de vazão da *Micro Motion* com saída analógica (Figura 18), modelo 2700, instalado no anular. Este equipamento é capaz de detectar os fenômenos de *kick* e perda de circulação por diferença de vazão registrada no anular.



Figura 18 – Medidor de vazão Micro Motion com saída analógica.

O sensor de nível, ilustrado na Figura 19, modelo Sitrans Probe LU 7ML5221-28A11 da Siemens é um dispositivo que emite dados de nível através de um sinal de 4 a 20 mA, funcionando através da emissão de ultrassom. O sensor é acoplado ao tanque através de uma conexão rosqueável e fornece dados de nível através do *display* ou por aquisição de dados. O tanque com sensor de nível (Figura 20) possui 96 cm de diâmetro e 130 cm de altura, com capacidade para armazenamento de 500L, sendo fabricado em polipropileno pela GRABE.



Figura 19 - Sensor de nível.



Figura 20 – Tanque de nível.

O tanque reservatório, utilizado para representar a rocha reservatório, possui válvulas de entrada e saída de ar comprimido que controlam a pressão interna do tanque. Para reduzir a pressão do tanque reservatório, a válvula de saída libera ar comprimido para a atmosfera. Desse modo, manipulando-se as válvulas de entrada/saída de ar comprimido, a pressão do tanque reservatório (monitorada em linha através de um transdutor de pressão) é controlada em tempo real. O acoplamento reservatório/anular permite estudar o comportamento do sistema frente aos fenômenos de *kick* e perda de circulação. O tanque reservatório, ilustrado na Figura 21, possui volume máximo de 50L com 5 entradas/saídas de $\frac{1}{2}$ " no topo do tanque, 2 entradas/saídas de $\frac{1}{2}$ " na base e uma entrada/saída com flange de 1" no fundo, suportando até 300 psi.



Figura 21 - Tanque reservatório.

A injeção de ar comprimido no tanque, através da válvula de entrada, é realizada pelo compressor de ar (Figura 22). O compressor apresenta capacidade de 350L, potência de 7,5 HP, vazão máxima de 50,97 m³/h e pressão máxima de 175 *psi*. O equipamento está configurado para iniciar a pressurização quando sua pressão interna estiver próxima a 130 *psi* e encontra-se instalado externamente ao LEF/DEQ/IT/UFRRJ.



Figura 22 – Compressor de ar.

Nas entradas superiores do tanque reservatório (Figura 23), um manômetro e um transdutor de pressão foram instalados para o monitoramento e controle da pressão, além de uma válvula de segurança, sendo esta acionada caso o tanque atinja pressões superiores a 300 *psi*.



Figura 23 – Instrumentação no tanque reservatório. Fonte: Patrício, 2016.

Para governar a entrada e a saída de ar comprimido foram instaladas uma válvula de controle proporcional e uma válvula solenoide (corpo dourado) utilizadas para controlar a pressão do tanque (Figura 24). As válvulas solenoides da marca ASCOVAL, com diâmetro de $\frac{1}{4}''$, são do tipo *on/off*, suportam até 284,47 *psi* de pressão diferencial (mínimo 4,84 *psi*) e

podem trabalhar em temperaturas que vão de -20°C à 80°C, com acionamento elétrico (220V) e são normalmente fechadas (NC). Os posicionadores das válvulas proporcionais, utilizados no controle do tanque de pressão, são da marca BRAY, trabalham com sinal ativo 4 a 20 mA e alimentação 24 V DC. O corpo da válvula é da FLOW TEK, suporta até 1000 psi para água, óleo ou gás (WOG). A configuração da válvula é normalmente fechada (NC). Todas as válvulas de controle proporcional presentes na unidade possuem posicionadores pneumáticos alimentados por pressão média de 6 bar, trabalham com sinal ativo de 4 a 20 mA, são normalmente fechadas (NC) e são alimentadas por 24 V DC.



Figura 24 - Válvulas reguladoras de entrada e saída de ar do reservatório. Fonte: Patrício, 2016.

Para fixar a pressão máxima admitida pelos equipamentos, foram instalados filtros reguladores (Figura 25) que também possuem a capacidade de reduzir a umidade do ar.



Figura 25 – Filtro regulador de ar. Fonte: Patrício, 2016.

A válvula que efetua o acoplamento do tanque reservatório com o anular (válvula de permeabilidade) é apresentada na Figura 26. Esta é especificada assim como as válvulas que realizam o controle da pressão no tanque reservatório (Figura 24), entretanto o diâmetro interno é de $\frac{1}{2}$ " e o tipo do interno é porta fenda customizada (em destaque na Figura 26). Vale ressaltar que esta válvula é empregada para simular a permeabilidade da formação rochosa.



Figura 26 - Válvula de permeabilidade. Fonte: Patrício, 2016.

Para o monitoramento e controle das variáveis de interesse na unidade experimental, foi desenvolvido um programa em linguagem C++. A interface gráfica para monitoramento e controle do poço e do tanque reservatório são ilustrados nas Figura 27 e 28, respectivamente. Tal programa permite estudar o acoplamento coluna/ tanque reservatório, ou ainda cada sistema isoladamente, monitorando vazão, pressão e abertura das válvulas em linha. É possível realizar o controle da pressão anular de fundo, introduzindo parâmetros e selecionando variáveis manipuladas (abertura da válvula *choke* ou vazão da bomba), e controlar a pressão do tanque reservatório (pressão de poros). Na interface de controle do tanque reservatório, além da pressão no poço, vazão lida no anular e abertura da válvula *choke*, monitora-se a abertura das válvulas de entrada e saída de ar para o tanque reservatório bem como a pressão no interior do mesmo.

A interface de treinamento da rede neuronal é ilustrada na Figura 29, onde pode-se observar a resposta da rede frente aos dados de entrada apresentados à mesma. A Figura 30 ilustra a janela de inserção de dados, onde é possível inserir a quantidade de dados passados de pressão e neurônios ocultos que a rede utilizará em seu treinamento.

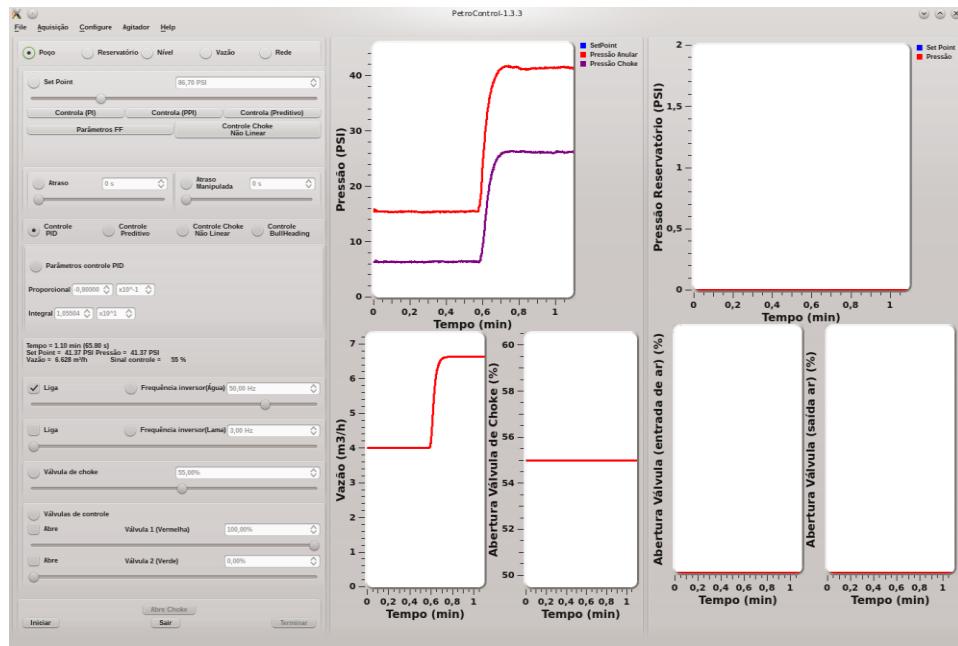
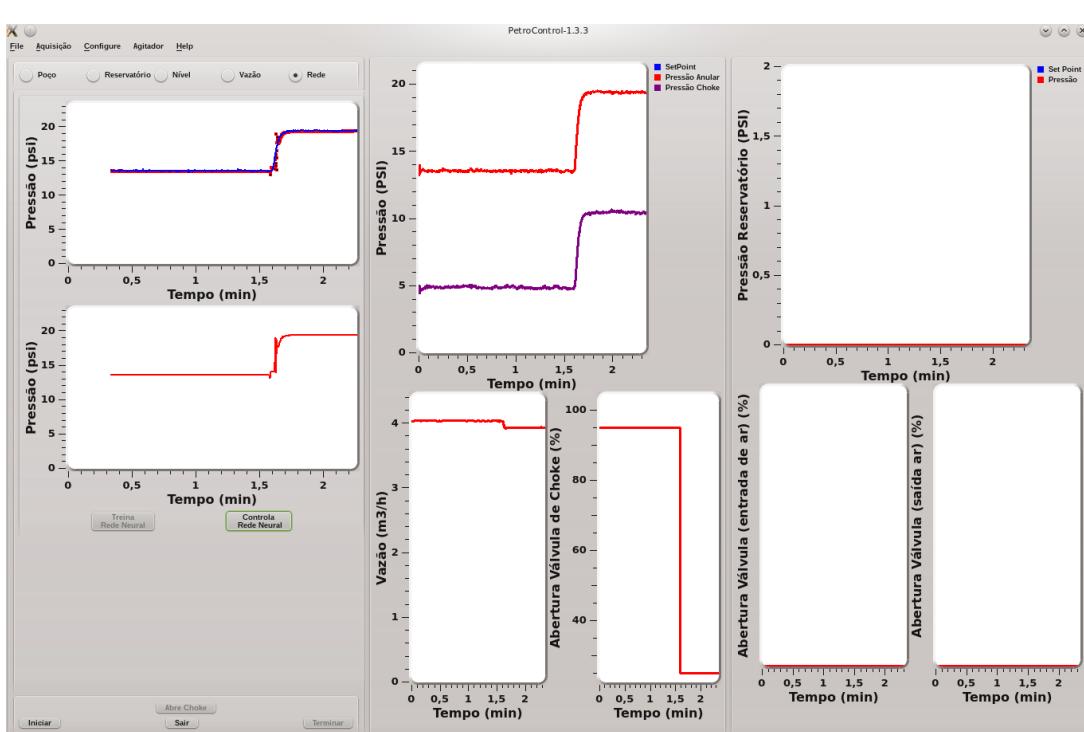
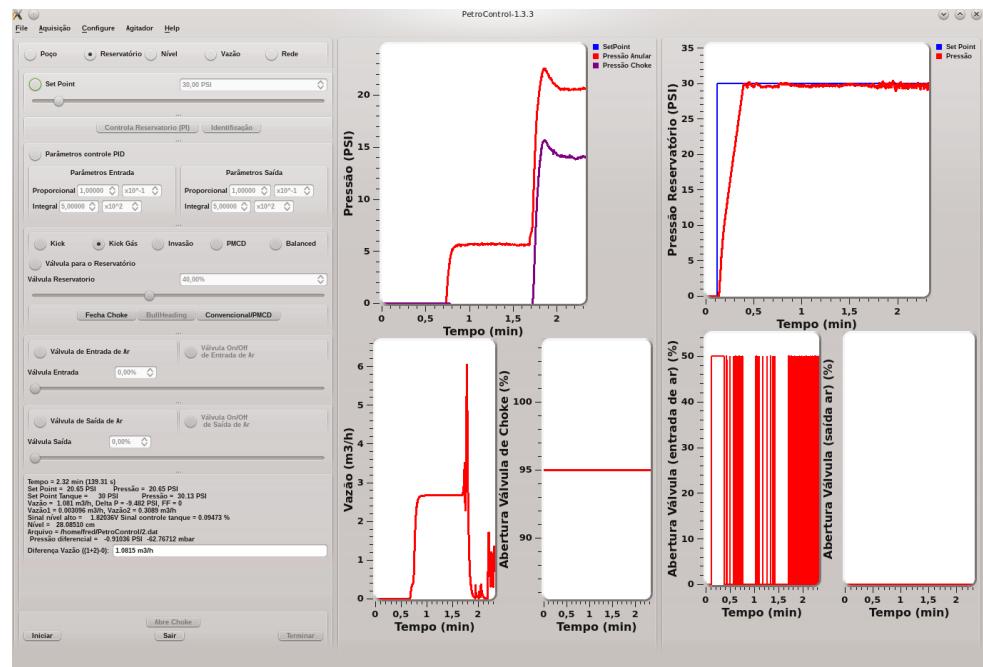


Figura 27 - Interface do programa para controle do poço.



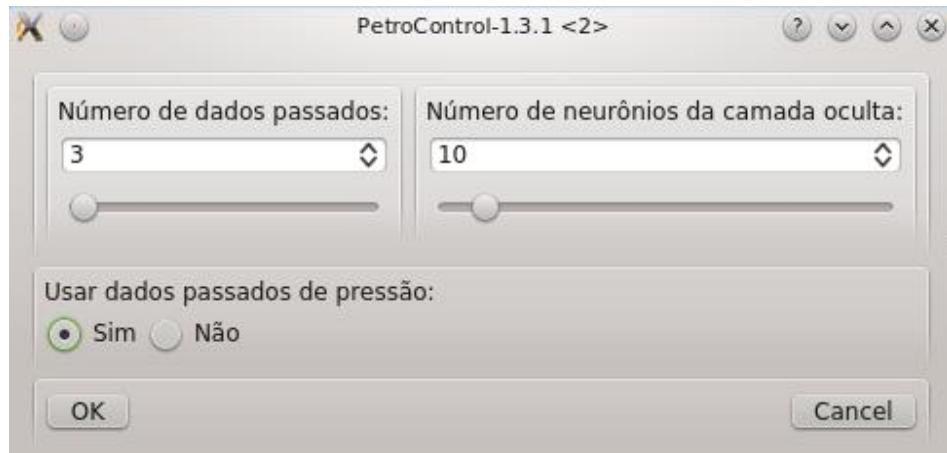


Figura 30 – Janela de inserção de dados de treinamento.

A Figura 31 ilustra uma topologia representativa da rede neuronal adotada neste trabalho. Tal rede é dotada de sete sinais de entrada, um neurônio de saída e uma camada de neurônios ocultos com todas as conexões de propagação entre as camadas adjacentes. Os sinais de entrada utilizados pela rede são: dados passados da pressão anular de fundo, pressão lida a montante da válvula choke, a frequência da bomba de água (bomba principal), a frequência da bomba de lama (bomba secundária), o índice de abertura da válvula choke, a vazão lida no anular e o tempo. Além disso, a rede apresenta dois limiares (bias), sendo um para a camada oculta e um para a camada de saída. Como pode ser observado (Figura 31), a rede apresentada possui caráter preditor, ou seja, a partir de dados passados apresentados como sinais de entrada, a estrutura neuronal é capaz de prever o comportamento futuro. Desta forma, a rede neuronal prediz dados de pressão anular de fundo (BHP) em um instante de tempo futuro com base nos dados passados (instante de tempo passado) de pressão anular de fundo. Para o caso da construção do controlador não linear baseado em rede neuronal inversa, a rede apresentará previsões para valores do índice de abertura da válvula choke e set point da pressão anular de fundo (Figura 32). Neste caso, além das entradas já mencionadas utiliza-se, adicionalmente, o set point da pressão anular de fundo como sinal de entrada.

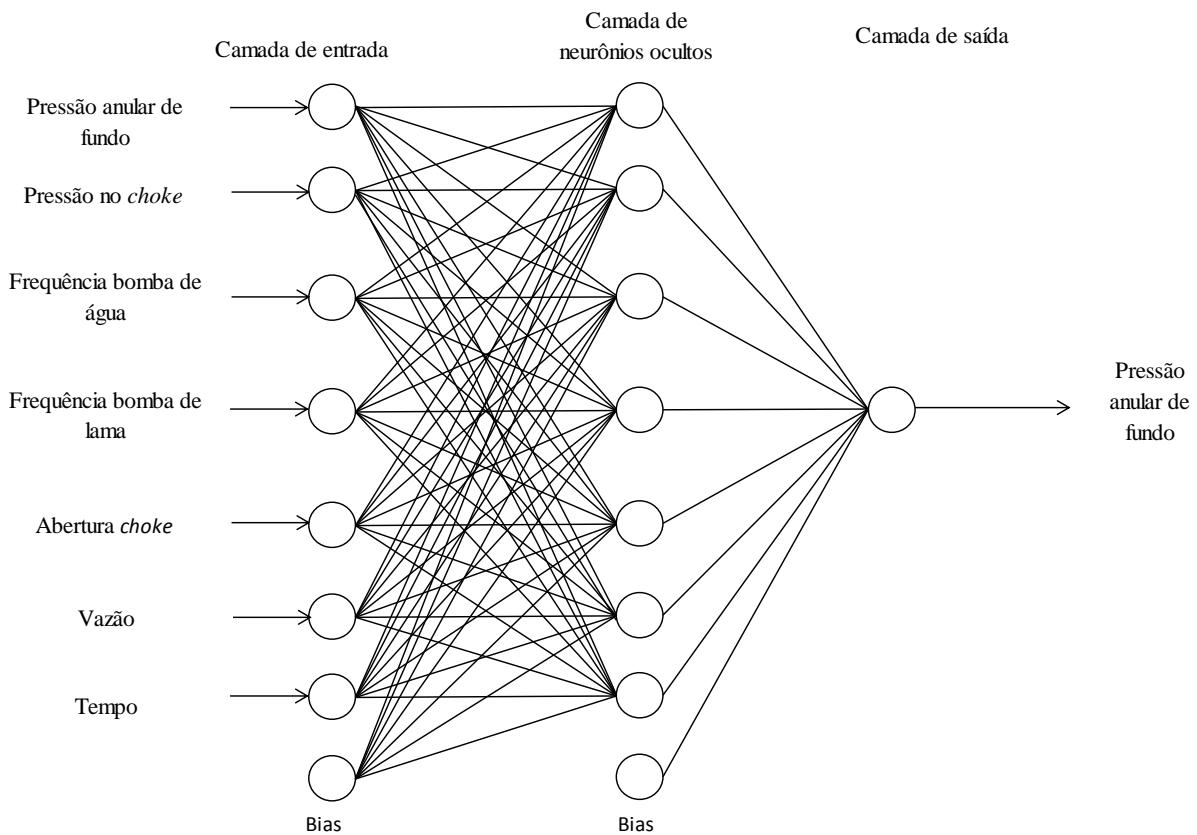


Figura 31 – Rede com uma camada oculta do tipo 7-7-1.

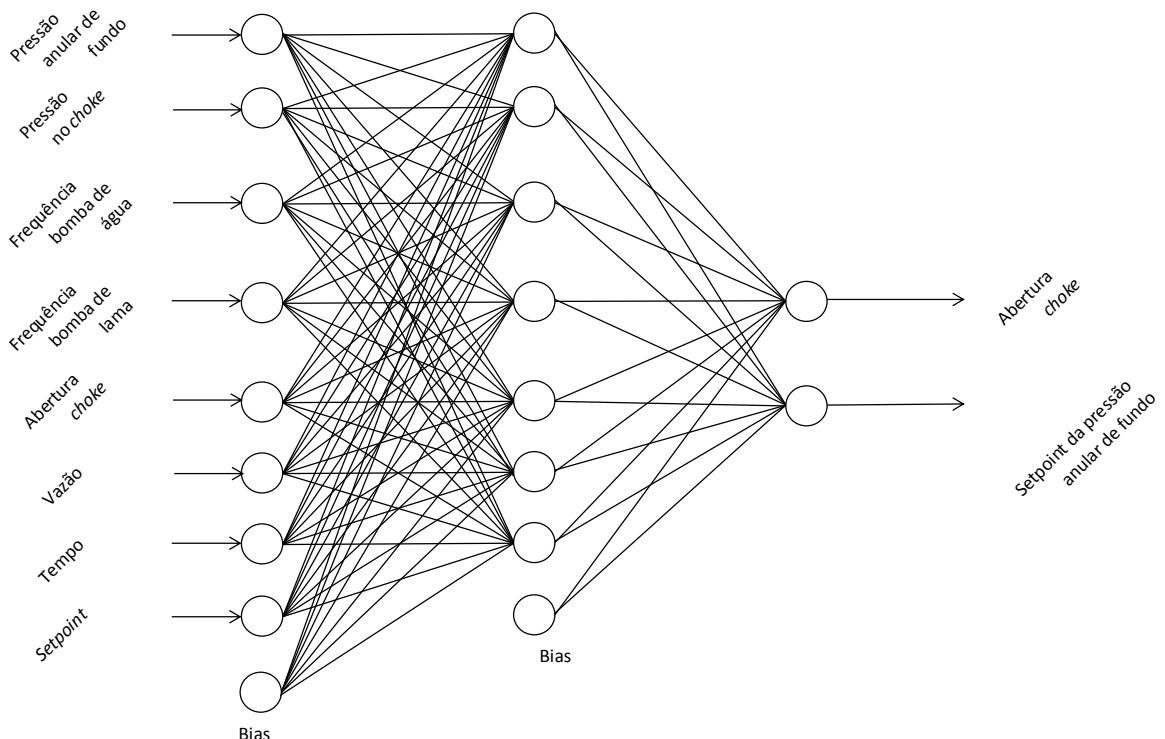


Figura 32 – Rede para o controlador não linear, do tipo 8-7-2.

3.2 Metodologia experimental

A fim de retratar o controle da pressão anular de fundo, levando em conta alguns dos distúrbios que ocorrem durante o processo de perfuração (*kick*, perda de circulação e

procedimento de conexão de tubos), foram realizados experimentos tendo como variáveis manipuladas o índice de abertura da válvula *choke* e a frequência da bomba de alimentação da coluna de perfuração. A seguir serão apresentados separadamente as seções da unidade piloto aplicadas em cada análise.

A Figura 33 ilustra a configuração experimental básica para o controle da pressão anular de fundo. Esta configuração foi utilizada para avaliar o comportamento da pressão anular de fundo frente às manipulações da vazão da bomba (mantendo-se o índice de abertura da válvula *choke* fixo) e do índice de abertura da válvula *choke* (mantendo-se a vazão da bomba fixa), apresentando desta forma padrões de aprendizagem para a rede neuronal. Nesta configuração o fluido armazenado no tanque de nível é bombeado, circulando por toda unidade, retornando para o mesmo.

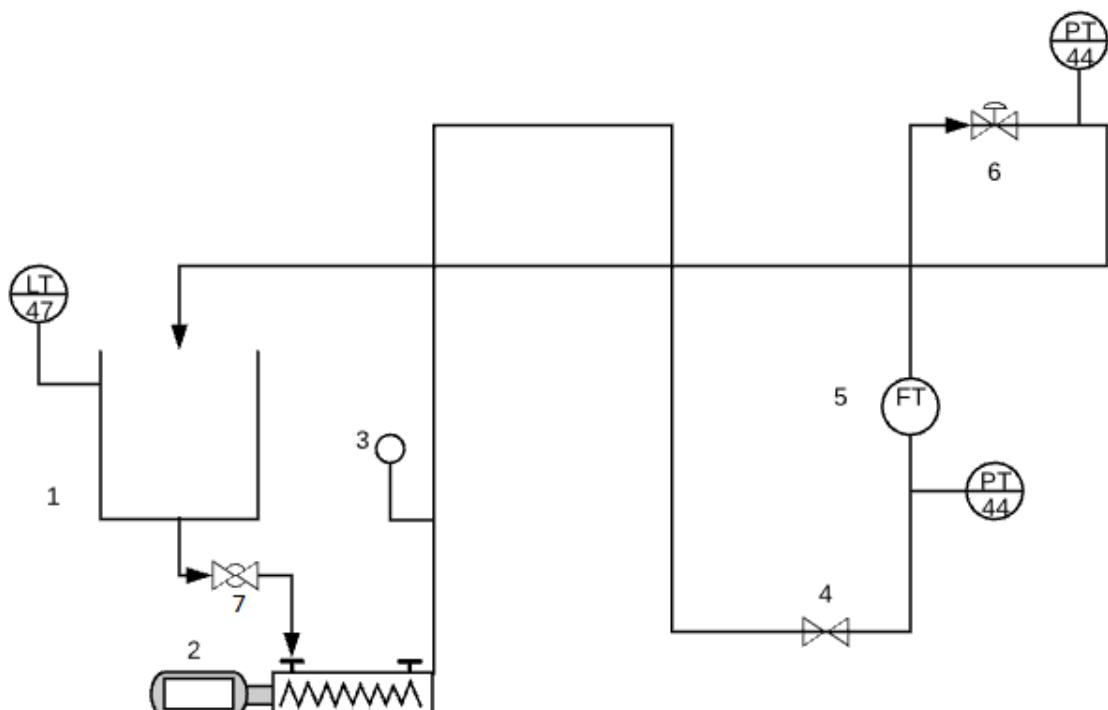


Figura 33 – Diagrama da unidade experimental: 1 – Tanque de nível; 2 – Bomba de deslocamento positivo (bomba de alimentação da coluna de perfuração); 3 – Manômetro; 4 – Válvula de restrição representando a broca de perfuração; 5 – Sensor de vazão e densidade; 6 – Válvula *choke*; 7 – Válvula esfera; LT – Transmissor de nível; PT – Transmissor de pressão.

Aumentando-se a complexidade do sistema a ser identificado pela rede neuronal em treinamento, empregou-se a unidade representada na Figura 34, onde os fenômenos de *kick* e perda de circulação puderam ser avaliados. O fluido armazenado no tanque de nível é bombeado através da coluna de perfuração, passando pela linha do *choke*, em um sistema fechado. Considerando o processo de perfuração real de poços, a pressão no interior da rocha reservatório sofre alterações ao longo da perfuração. Entretanto, para serem realizados experimentos de *kick* e perda de circulação na unidade piloto a pressão do reservatório (pressão de poros) foi mantida em um valor constante, mantendo-se o controlador do tanque reservatório em modo automático. A válvula que realiza o acoplamento coluna / tanque é denominada válvula de permeabilidade. Através de índices de abertura distintos (diferentes permeabilidades), perdas maiores ou menores de fluido do anular para o tanque (no caso da perda de circulação) ou maiores ou menores influxos de gás do reservatório para o anular (no caso do fenômeno de *kick*) podem ser retratados. Para que haja a perda de circulação, a pressão no interior do tanque reservatório (pressão de poros) deverá ser obrigatoriamente menor que a pressão no anular, garantindo,

assim, que o fluido circulante invada o tanque. Para a realização do *kick* de gás o procedimento é análogo, entretanto, a pressão no interior do tanque deverá ser maior que a pressão do anular para garantir que haja influxo de gás para o mesmo. Ambos os fenômenos podem ser detectados pela redução (perda de circulação) e aumento (*kick*) de vazão aferida pelo medidor localizado no anular (fundo do poço).

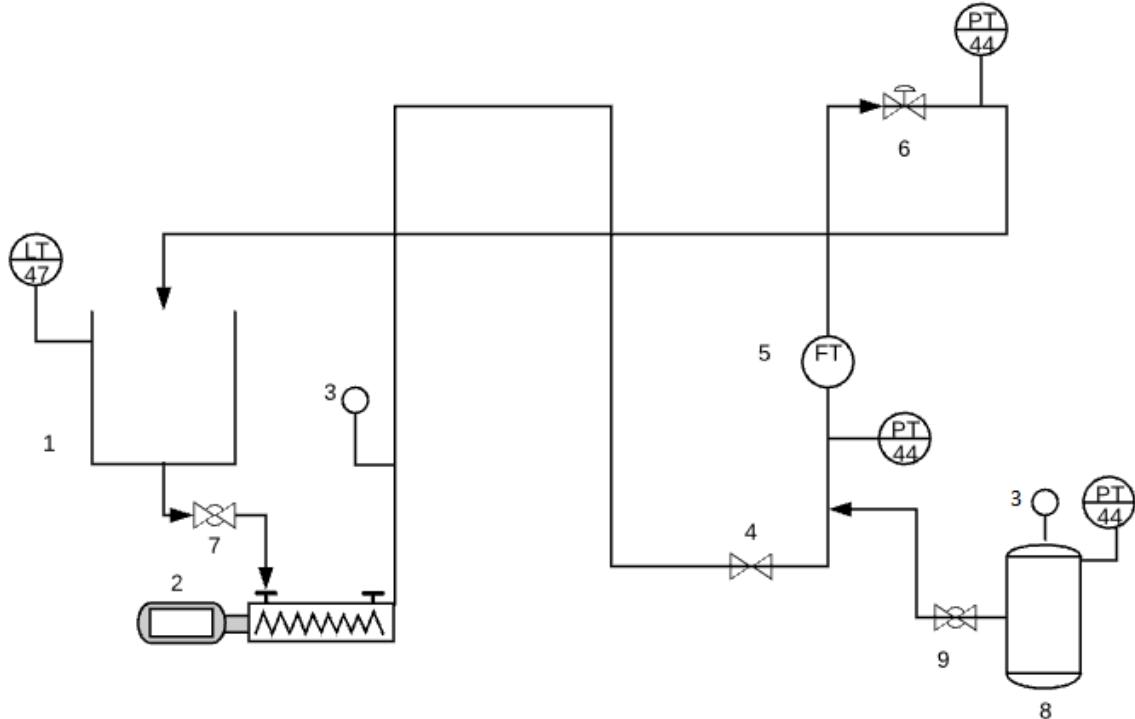


Figura 34 – Configuração para *kick* e perda de circulação: 1 – Tanque de nível; 2 – Bomba de deslocamento positivo (bomba de alimentação da coluna de perfuração); 3 – Manômetro; 4 – Válvula de restrição representando a broca de perfuração; 5 – Sensor de vazão e densidade; 6 – Válvula *choke*; 7 – Válvula esfera; 8 – Tanque reservatório; 9 - Válvula de permeabilidade; LT – Transmissor de nível; PT – Transmissor de pressão.

Buscando-se retratar a operação de conexão de tubos, a configuração experimental apresentada na Figura 35 foi adotada. Os fluidos armazenados no tanque de nível e tanques de lama são bombeados através da coluna de perfuração e região anular, respectivamente, escoando pela linha do *choke* e retornando ao tanque de nível.

Devido as limitações físicas da unidade experimental o procedimento de conexão de tubos foi realizado reduzindo-se a vazão de bombeio da bomba de água, responsável por alimentar a coluna de perfuração. Em todos os experimentos utilizou-se água para representar o fluido de perfuração.

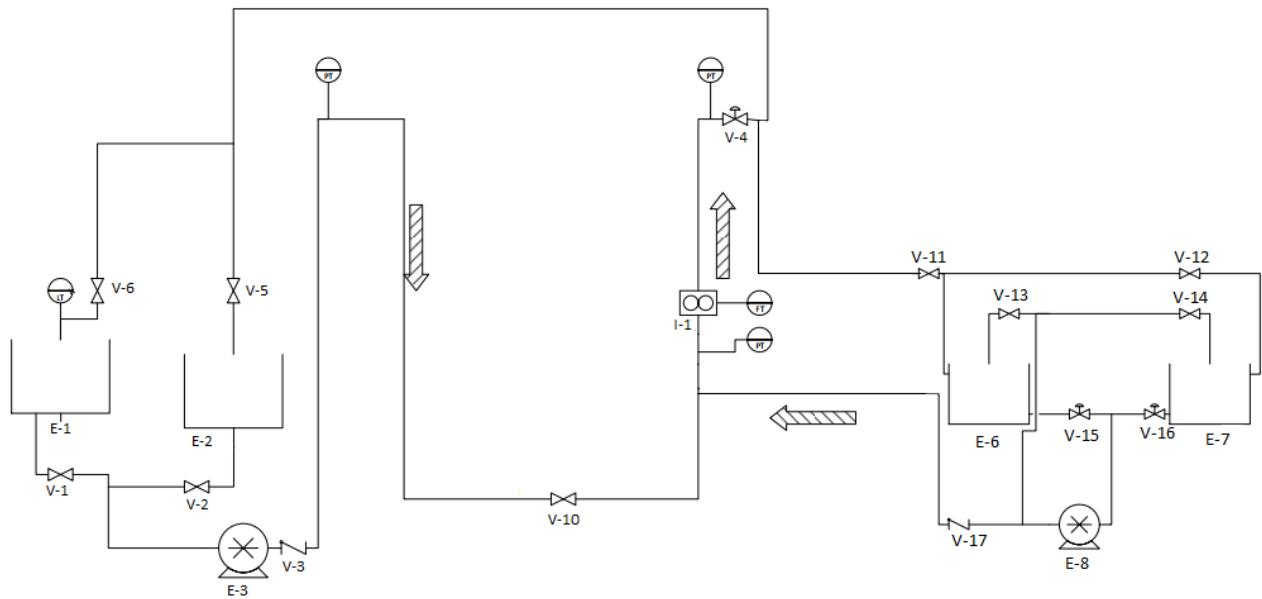


Figura 35 – Configuração para o procedimento de conexão de tubos: E-1: Tanque de nível; E-2: Tanque de água; E-3: Bomba principal; E-4: Tanque reservatório; E-5: Compressor de ar; E-6 e E-7: Tanques de lama; E-8: Bomba secundária; I-1: Medidor de vazão e densidade; V-1, V-2, V-5, V-6, V-11, V-12, V-13 e V-14: Válvulas esfera; V-3, V-17: Válvulas de retenção; V-15, V-16: Válvulas borboleta; V-4: Válvula *choke* (válvula de controle acionada pneumáticamente); V-10: Válvula gaveta (Broca); PT: Sensor/Transmissor de pressão; LT: Sensor/Transmissor de nível; FT: Sensor/Transmissor de vazão.

3.3 Determinação topológica

Para determinar a topologia da rede neuronal a ser utilizada nos testes de controle da pressão anular de fundo, foram implementados na planta testes de treinamento utilizando três conjuntos de dados passados, cada qual com três conjuntos de neurônios distintos na camada oculta (Tabela 1). Esta configuração foi aplicada em todas as situações analisadas neste trabalho.

Para cada sistema avaliado (variação de vazão, variação do índice de abertura da válvula *choke* e fenômenos de *kick* e perda de circulação) um procedimento experimental foi desenvolvido. Cabe ressaltar que para se obter uma boa precisão é necessário que haja a repetibilidade dos dados, assim, cada teste foi realizado em triplicata.

Tabela 1 – Configuração para o treinamento neuronal.

Dados passados de pressão	Número de neurônios na camada oculta
3	5 7 9
5	5 7 9
7	5 7 9

O treinamento da rede neuronal tendo como variável manipulada a vazão da bomba de alimentação da coluna de perfuração acionada via inversor de frequência, foi realizado para três índices de abertura da válvula *choke* distintos, quais sejam 25, 55 e 95%. Buscando-se fazer uma varredura dos níveis de pressão, a frequência de bombeio foi modificada de 30 a 60 Hz aplicando-se um delta de 10 Hz na frequência da bomba.

O treinamento da rede utilizando como variável manipulada o índice de abertura da válvula *choke* foi realizado aplicando-se uma vazão constante para a alimentação da coluna de perfuração. Neste caso, foi avaliado o comportamento da rede frente a três frequências de bombeio distintas, 30 Hz, 45 Hz e 60 Hz. Este treinamento foi realizado tomando valores aleatórios para a abertura da válvula *choke*.

A configuração adotada para o treinamento de *kick* de gás e perda de circulação é ilustrada na Tabela 2. Para cada índice de abertura válvula *choke* avaliou-se a magnitude da resposta para cada índice de abertura da válvula de permeabilidade, sendo esta uma perturbação imposta ao sistema.

Tabela 2 – Configuração para treinamento de *kick* de gás e perda de circulação.

Índice de abertura da válvula <i>choke</i> (%)	Índice de abertura da válvula de permeabilidade (%)
25	40
55	50
95	60

3.4 Modelagem

A partir da coleta dos dados experimentais em planta, os mesmos foram divididos randômicamente em três conjuntos distintos: 50% dos dados para treinamento, 25% dos dados para validação e os demais 25% para a fase de teste da rede. Para eliminar valores discrepantes, dados inválidos ou até mesmo a falta de dados, procedimentos de pré-processamento são comumente aplicados antes de realizar qualquer cálculo. Esta etapa garante que os dados a serem utilizados na modelagem sejam perfeitamente ajustados. Em vista de suavizar o procedimento de treinamento e promover a precisão da predição da resposta pela rede, todas as amostras são normalizadas dentro do intervalo [-1, 1]. (FATTAHI & BAZDAR, 2017)

Para verificar a performance do modelo da rede (RNA-BP – rede neuronal artificial com algoritmo de aprendizagem *back-propagation*) pode-se empregar como critérios de desempenho o erro quadrático médio (MSE – *Mean Squared Error*), a raiz quadrada do erro médio, (RMSE – *Root Mean Square Error*), a soma do erro quadrático (SSE – *Sum of Squared Error*), o coeficiente de determinação (R^2), entre outros. As equações 33, 34 e 35 ilustram a obtenção do MSE, RMSE e SSE, respectivamente. O MSE expressa o erro médio entre a saída da rede (y_j) e o valor desejado da saída (y_{dj}), onde N é o número de amostras de treinamento ou validação. A soma do erro quadrático é determinado pela diferença entre os dados observados e aqueles preditos pelo modelo, sendo expresso pela fórmula onde y_k é o dado observado, f é o dado obtido pelo modelo e N é o número de amostras. O R^2 avalia a qualidade da similaridade apresentada entre os dados observados e modelados, ou seja, avalia quanto o modelo consegue explicar os valores observados. Conforme o valor de R^2 se aproxima de 1, mais precisa se torna a predição do modelo.

$$MSE = \frac{1}{N} \sum_{j=1}^{N} (y_j - y_{dj})^2 \quad (33)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (y_j - y_{dj})^2} \quad (34)$$

$$SSE = \sum_{k=1}^N (y_k - f)^2 \quad (35)$$

3.5 Determinação dos parâmetros do controlador clássico – PI

Neste trabalho de dissertação de mestrado redes neurais foram empregadas para identificação da pressão de perfuração de poços de petróleo. Tais redes foram empregadas como modelos treinados em tempo real (controlador neuronal indireto) fazendo parte de um esquema de controle adaptativo, empregando um controlador PI. Vale ressaltar que o esquema de controle adaptativo é empregado para os sistemas dinamicamente transientes, neste caso a etapa de identificação do sistema é realizada como parte do controlador. Esse tipo de abordagem é empregada especificamente no desenvolvimento do controlador indireto. Além disso, um controlador neuronal direto foi desenvolvido segundo a metodologia proposta por Nguyen (2003) e Haykin (2009).

A identificação dos parâmetros da unidade experimental foi realizada empregando - se a metodologia desenvolvida por Sundaresan & Krisnaswany (1977). O ajuste dos parâmetros para diferentes níveis operacionais foi realizado através da implementação das estratégias de Ziegler-Nichols (1942) e Cohen-Coon (1953). Os parâmetros obtidos por tais metodologias, após ajuste fino em campo, foram aplicados à estratégia de controle clássico PI.

3.5.1 Método da curva de reação

O método da curva de reação baseia-se na aplicação de uma perturbação degrau (M) na variável de entrada do processo, em malha aberta. A resposta da variável de saída frente a essa perturbação é denominada curva de reação do processo. Através da curva de reação do processo estima-se o ganho (K), o tempo morto (t_d) e a constante de tempo (T), traçando-se uma reta tangente ao ponto de inflexão. A Figura 36 ilustra tal abordagem. (INGHAM et al., 2007, SEBORG, 2003)

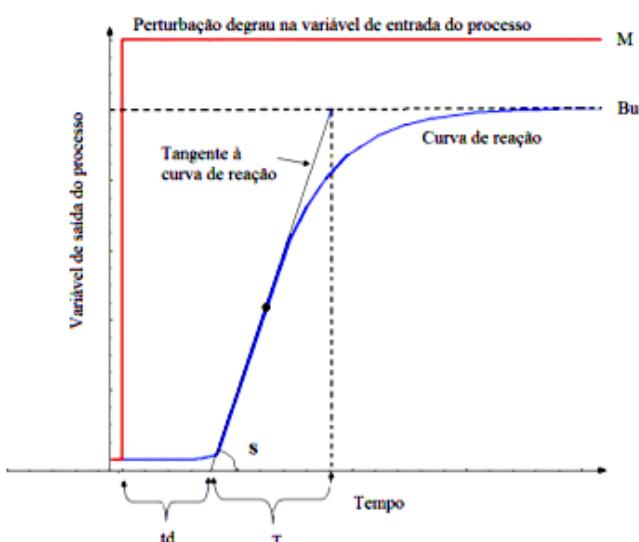


Figura 36 – Curva de reação do processo. Fonte: Freitas, 2013.

3.5.2 Método de Sundaresan & Krishnaswamy

Para determinar o tempo morto (t_d) e a constante de tempo (τ) do processo, o método de Sundaresan & Krishnaswamy (1977) emprega o tempo no qual a variável de saída atinge 35,3% (t_1) e 85,3% (t_2) do seu valor final. Tais relações são apresentadas nas Equações 36 e 37.

$$t_d = 1,3t_1 - 0,29t_2 \quad (36)$$

$$\tau = 0,67(t_2 - t_1) \quad (37)$$

3.5.4 Estimação dos parâmetros do controlador PI

No presente trabalho, o ajuste do controlador clássico PI foi realizado empregando-se os métodos de Ziegler-Nichols (1942) e Cohen-Coon (1953). As relações de sintonia dos dois métodos são apresentadas na Tabela 3.

Tabela 3 - Estimação de parâmetros do controlador.

	K_c	τ_I	τ_D
Ziegler-Nichols			
P	$\frac{1}{t_d S}$	-	-
PI	$\frac{0,9}{t_d S}$	$3,33t_d$	-
PID	$\frac{1,2}{t_d S}$	$2t_d$	$0,5t_d$
Cohen-Coon			
P	$\frac{1}{K_p} \frac{\tau}{td} \left(1 + \frac{td}{3\tau}\right)$	-	-
PI	$K_p \frac{\tau}{K_p \cdot td} \left(0,9 + \frac{td}{12\tau}\right)$	$\frac{td \left(30 + \frac{3td}{\tau}\right)}{9 + \frac{20td}{\tau}}$	-
PID	$\frac{\tau}{K_p \cdot td} \left(\frac{4}{3} + \frac{td}{12\tau}\right)$	$\frac{td \left(32 + \frac{6td}{\tau}\right)}{13 + \frac{8td}{\tau}}$	$td \frac{4}{12 + \frac{2td}{\tau}}$

Fonte: Adaptado de Ingham et al, 2007.

4 RESULTADOS E DISCUSSÕES

4.1 Treinamento da rede neuronal

A etapa de treinamento de uma RNA é aquela que requer o maior investimento de tempo. Para que o treinamento seja realizado de forma eficiente é necessário que padrões sejam apresentados à rede visando aquisição suficiente de informações do processo em análise. A cada treinamento uma solução distinta foi obtida a partir dos valores iniciais de pesos e *bias* fornecidos à rede. Assim, para garantir a repetibilidade dos resultados e, consequentemente, resultados confiáveis, realizou-se cada treinamento em triplicata. Neste trabalho de dissertação de mestrado, RNA's foram treinadas frente aos distúrbios frequentemente encontrados durante o processo de perfuração, quais sejam: distúrbios de vazão, *kick*, perda de circulação e variação do índice de abertura da válvula *choke*.

O treinamento da rede na planta piloto, tendo como variável de perturbação (entrada) a vazão da bomba de alimentação da coluna de perfuração, foi realizado mantendo-se o índice de abertura da válvula *choke* fixo. Foram avaliados três índices distintos de abertura para a válvula, quais sejam 25%, 55% e 95%. Os experimentos foram realizados tendo como faixa de operação de 30 Hz a 60 Hz. A Figura 37 apresenta um resultado típico para o treinamento da rede para variação da vazão de bombeio, utilizando três dados passados de pressão e sete neurônios na camada oculta. Os demais resultados são apresentados no Anexo A.

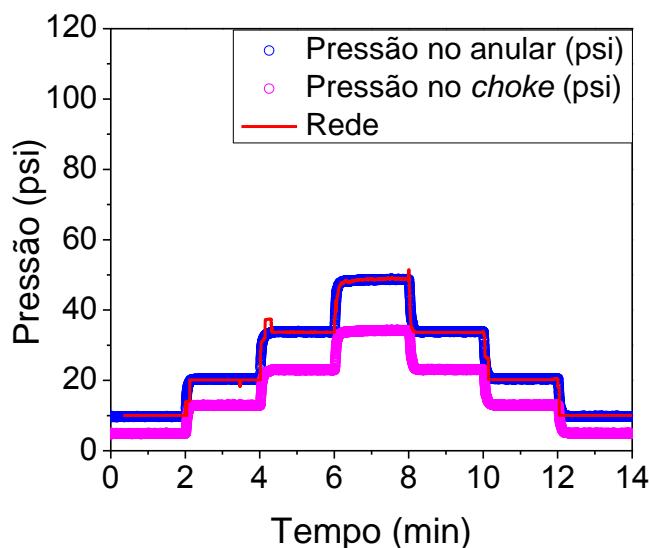


Figura 37 – Treinamento da rede neuronal manipulando a frequência da bomba de alimentação da coluna de perfuração com válvula *choke* 95% aberta.

Para avaliar os fenômenos de *kick* e perda de circulação, foram realizados testes de treinamento da rede para três índices de abertura da válvula *choke*, aplicando como perturbação o índice de abertura da válvula de permeabilidade. Neste tipo de experimento é necessário que a pressão do tanque reservatório seja controlada para que não ocorra a despressurização do mesmo. O experimento para o fenômeno de *kick*, difere da perda de circulação no delta de pressão empregado entre a região anular e o tanque reservatório, onde para os testes de *kick* empregou-se, para o tanque de pressão, uma pressão de 20 psi acima da pressão registrada no fundo do anular, para cada condição analisada. Na análise da perda de circulação, a pressão do tanque foi fixada 20 psi abaixo da pressão registrada no fundo anular. A Figura 38 ilustra um resultado típico para o treinamento de uma rede neuronal para o fenômeno de *kick* com sete dados passados de pressão anular de fundo e cinco neurônios na camada oculta, utilizando

índice de abertura para a válvula *choke* de 95%, índice de permeabilidade de 60% e frequência da bomba em 30 Hz. O treinamento típico para a perda de circulação, com três dados passados de pressão anular de fundo e sete neurônios na camada oculta é ilustrado na Figura 39, adotando-se índice de abertura para a válvula *choke* de 25%, índice de permeabilidade de 60% e frequência da bomba em 60 Hz. Os demais resultados para o treinamento de *kick* e perda de circulação são apresentados nos Anexos B e C, respectivamente. A Tabela 4 apresenta a condição operacional utilizada para os experimentos de *kick* e perda de circulação para cada abertura da válvula *choke*.

Tabela 4 – Condição operacional para fenômeno de *kick* e perda de circulação.

Índice de abertura da válvula <i>choke</i>	Índice de abertura da válvula de permeabilidade
25%	40%
	50%
	60%
55%	40%
	50%
	60%
95%	40%
	50%
	60%

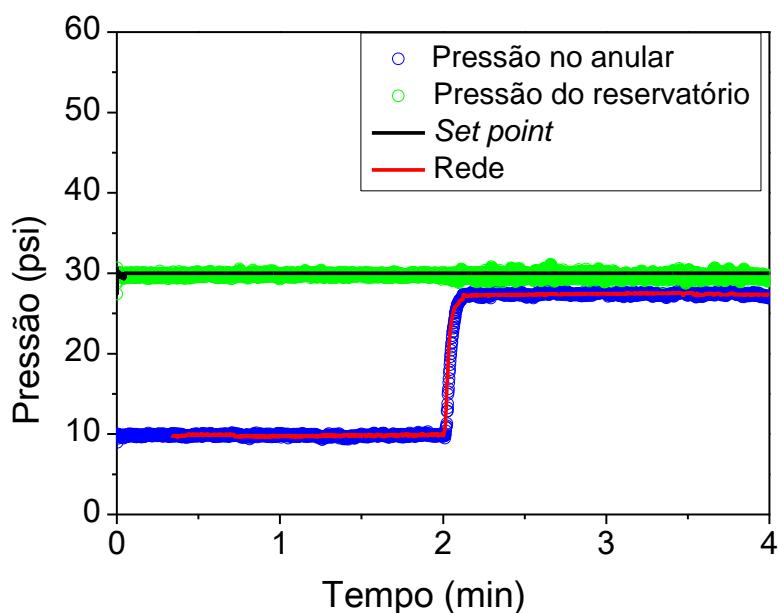


Figura 38 – Treinamento de *kick* com válvula de permeabilidade em 60%, abertura da válvula *choke* em 95% com sete dados passados de pressão e cinco neurônios na camada oculta.

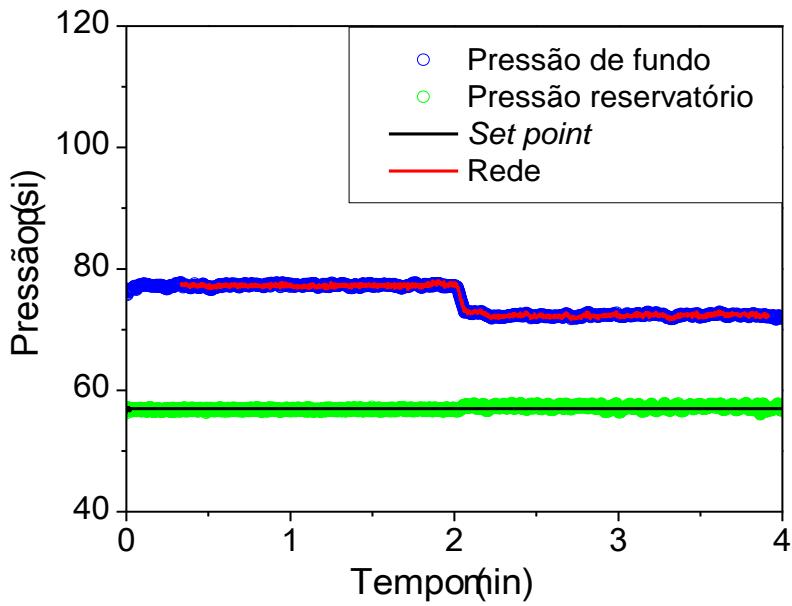


Figura 39 – Treinamento perda de circulação com válvula de permeabilidade em 60%, abertura da válvula *choke* em 25%, com três dados passados de pressão e sete neurônios na camada oculta.

O treinamento da rede, tendo como variável de perturbação (entrada) a abertura da válvula *choke*, foi realizado para três frequências da bomba quais sejam 30 Hz, 45 Hz e 60 Hz, não fazendo uso dos dados passados de pressão anular, visto que tal recursividade gerou altos índices de não linearidade durante o treinamento previamente empregado, dificultando o aprendizado por parte da rede neuronal. Assim, valores de abertura da válvula *choke* foram determinados de forma aleatória para valores na faixa de 25 e 95%. Um resultado típico deste treinamento, utilizando frequência de 45 Hz para a bomba principal e sete neurônios na camada oculta, pode ser observado na Figura 40. Os demais resultados são apresentados no Anexo D.

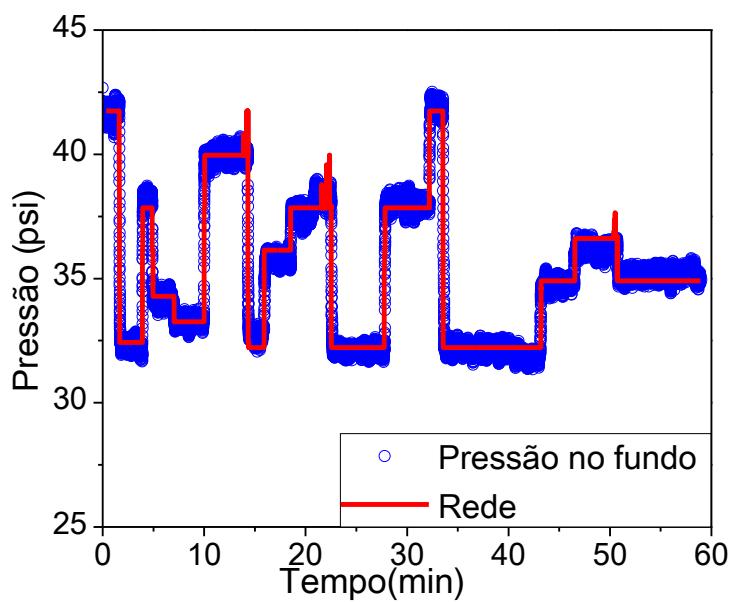


Figura 40 – Treinamento variando índice de abertura da *choke*, para frequência de 45 Hz para a bomba principal, com sete neurônios na camada oculta.

4.2 Modelagem da rede neuronal

Seguindo as abordagens mais clássicas disponíveis na literatura, para o particionamento do conjunto de dados, 50% dos dados disponíveis foram empregados para a realização do treinamento, 25% para a validação e os demais 25% para o teste da rede neuronal. A Tabela 5 apresenta o quantitativo de experimentos realizados na unidade piloto durante a etapa de aquisição de dados, bem como o particionamento dos dados em treinamento, validação e teste. O treinamento da rede consiste das seguintes etapas:

- Alimentam-se os dados de entrada-saída obtidos dos testes realizados na planta;
- Realiza-se a normalização dos dados;
- Aplica-se o algoritmo de treinamento para cada um dos conjuntos de neurônios ocultos, neste caso 5, 7 e 9 neurônios. Os pesos e bias da rede em treinamento são inicializados de forma aleatória visando aumentar a velocidade de aprendizagem pela rede;

O treinamento foi realizado empregando-se o algoritmo de retropropagação do erro com taxa de aprendizagem adaptativa (HAYKIN, 2009), até que o erro desejado fosse obtido ou o número máximo de épocas (iterações), pré-determinado para o treinamento, fosse alcançado. Vale ressaltar que a rede é testada com os dados de validação para assegurar que seu desempenho seja considerado aceitável. Para que a rede treinada não apresente uma baixa capacidade de generalização e não se torne especialista nos dados de treinamento apresentados à ela, realiza-se a validação a partir de um conjunto de dados distinto do conjunto de treinamento. Foram empregadas a função de ativação tangente hiperbólica (tansig) entre a camada de entrada e a camada de neurônios ocultos, sendo esta uma escolha apropriada para se trabalhar com funções não lineares. Já entre a camada de neurônios ocultos e a de saída empregou-se a função de ativação linear (purelin). Por fim, a rede já treinada e validada é testada para aferir se os parâmetros da rede (pesos e bias) respondem eficientemente ao problema, conferindo e garantindo a boa generalização do conhecimento obtido pela mesma.

Tabela 5 – Quantitativo de dados para a realização da validação cruzada.

Treinamento experimental	Total de experimentos	Dados para treinamento	Dados para validação	Dados para teste
<i>Kick</i>	729	364	182	182
Perda de Circulação	729	364	182	182
Bomba	81	40	20	20
<i>Choke</i>	27	13	7	7
Total	1566	781	391	391

Após a partição dos conjuntos de dados, a rede neuronal foi modelada para os casos de perda de circulação, *kick* de gás, variação do índice de abertura da válvula *choke* e variação da frequência de bombeio do fluido de perfuração (distúrbio de vazão). Em todos esses testes a resposta é dada através dos níveis de pressão anular de fundo, caracterizando o modelo da rede neuronal direta. Para o caso da rede neuronal inversa foram modelados resultados obtidos a partir da implementação do controlador clássico PI.

É importante ressaltar que os procedimentos de treinamento, validação e teste da rede neuronal visaram melhor desempenho para a planta piloto durante a etapa de aquisição de dados. Cada rede foi treinada dez vezes, adotando-se a rede com o menor valor da raiz do erro quadrado médio (RMSE), calculado usando os dados de teste.

A capacidade da rede neuronal em reproduzir o fenômeno de perda de circulação é representada nas Figuras 41 - 45; as Figuras 42, 44 e 46 ilustram os ajustes realizados com o resultado gerado pelo modelo da rede frente aos dados experimentais. A modelagem neuronal do fenômeno de *kick* é apresentada nas Figuras 47 - 52 ilustram a resposta da rede para o

fenômeno de *kick* de gás; e as Figuras 48, 50 e 52 ilustram os ajustes empregados entre os dados observados e estimados pela rede. Em ambos os testes, perda de circulação e *kick* de gás, foram empregadas as aberturas de 25, 55 e 95% para a válvula *choke* e para a válvula de permeabilidade 40, 50 e 60%, respectivamente. Pode-se observar que o modelo da rede foi eficiente em predizer a pressão anular de fundo frente o problema de perda de circulação e *kick* de gás apresentando coeficiente de correlação satisfatório. Além disso, o erro quadrático médio (MSE), a raiz do erro quadrático (RMSE) e o coeficiente de determinação (R^2) confirmam a boa generalização por parte da rede testada.

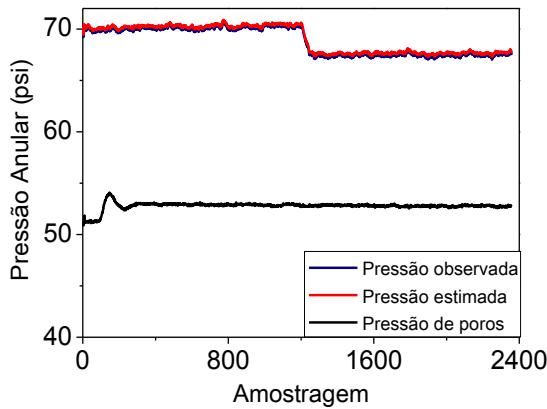


Figura 41 – Perda de circulação com sete dados passados de pressão e cinco neurônios na camada oculta.

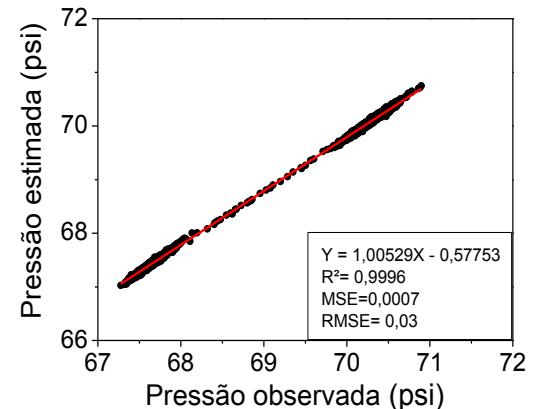


Figura 42 – Ajuste dos dados estimados pelo modelo versus o valor observado.

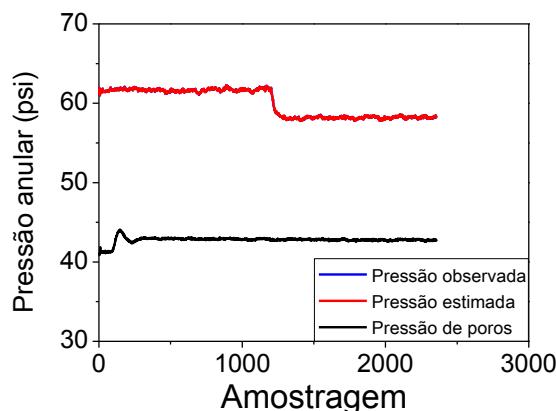


Figura 43 – Perda de circulação com cinco dados passados de pressão e sete neurônios na camada oculta.

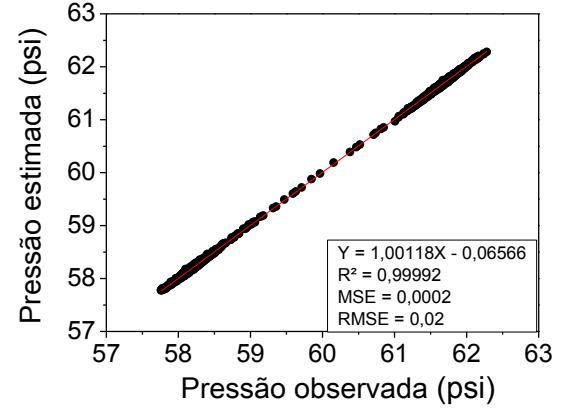


Figura 44 – Ajuste dos dados estimados pelo modelo versus o valor observado.

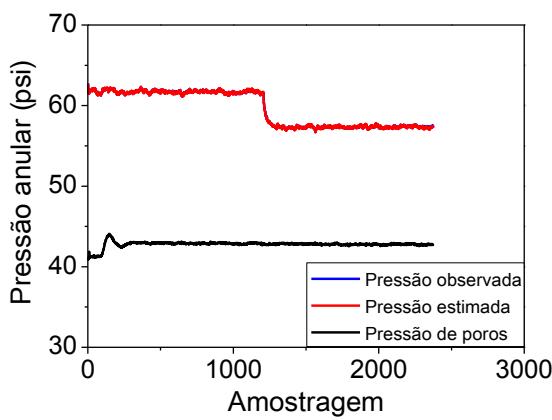


Figura 45 – Perda de circulação com cinco dados passados de pressão e cinco neurônios na camada oculta.

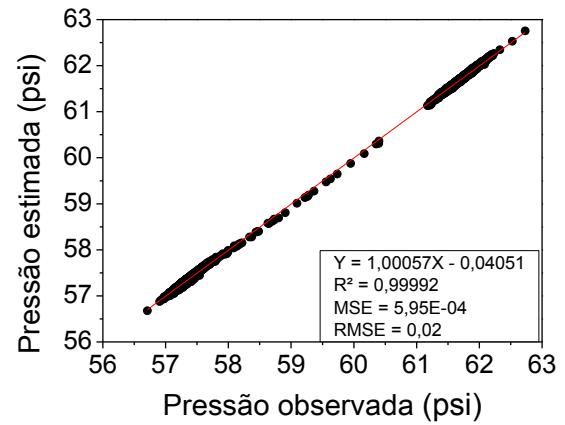


Figura 46 – Ajuste dos dados estimados pelo modelo versus o valor observado.

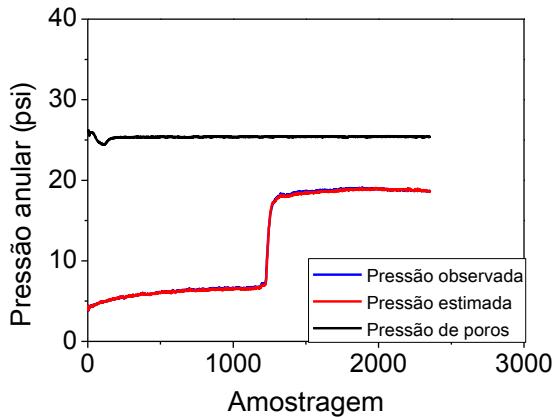


Figura 47 – Kick de gás com cinco dados passados de pressão e sete neurônios na camada oculta.

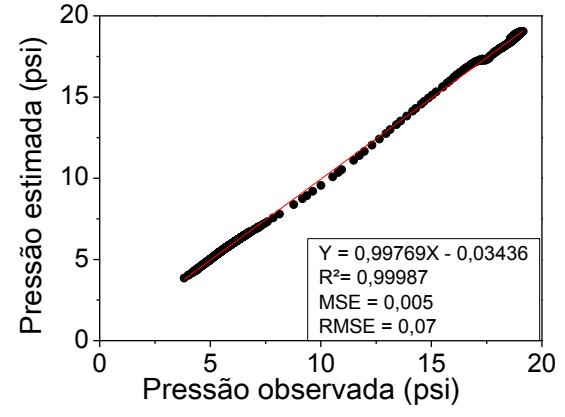


Figura 48 – Ajuste dos dados estimados pelo modelo versus o valor observado.

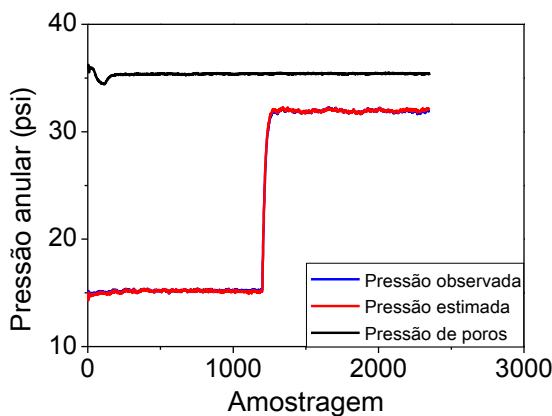


Figura 49 – Kick de gás com sete dados passados de pressão e cinco neurônios na camada oculta.

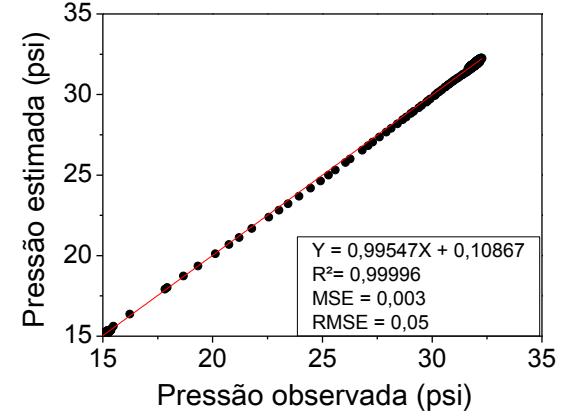


Figura 50 – Ajuste dos dados estimados pelo modelo versus o valor observado.

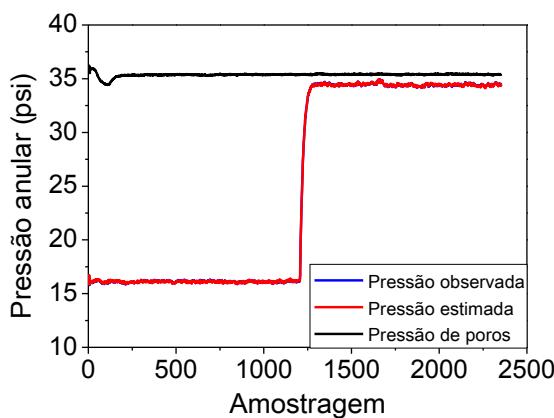


Figura 51 – *Kick* de gás com sete dados passados de pressão e nove neurônios na camada oculta.

Distúrbios de vazão são muito frequentes durante o processo de perfuração de poços de petróleo, principalmente na etapa de conexão de tubos. As Figuras 53 e 55 ilustram a capacidade do modelo neuronal em reproduzir este distúrbio. As Figura 54 e Figura 56 ilustram os ajustes realizados com o resultado gerado pelo modelo da rede frente aos dados experimentais. Ambos os resultados foram satisfatórios.

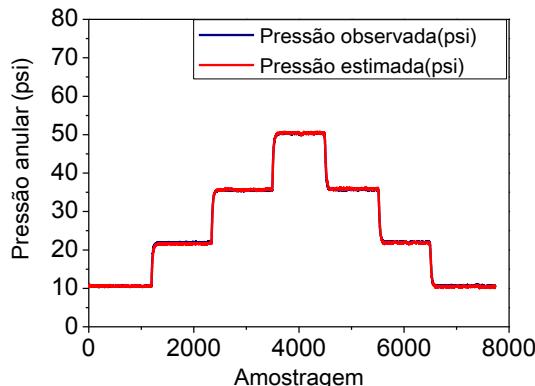


Figura 53 – Teste da rede neuronal para variação de vazão com sete neurônios na camada oculta.

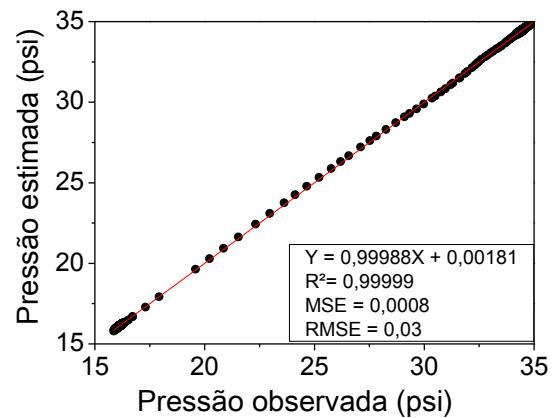


Figura 52 – Ajuste dos dados estimados pelo modelo versus o valor observado.

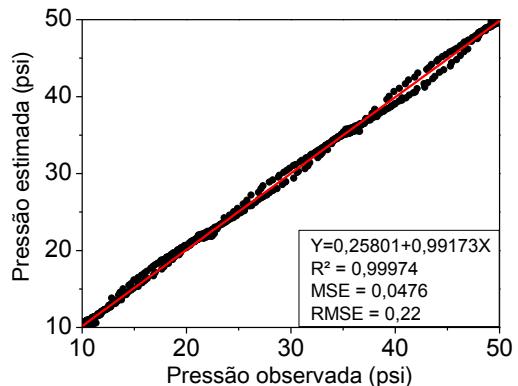


Figura 54 - Ajuste dos dados estimados pelo modelo da rede versus o valor observado da pressão anular.

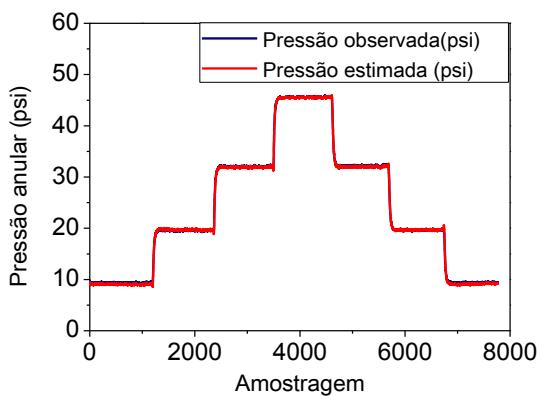


Figura 55 – Teste da rede neuronal para variação de vazão com cinco neurônios na camada oculta.

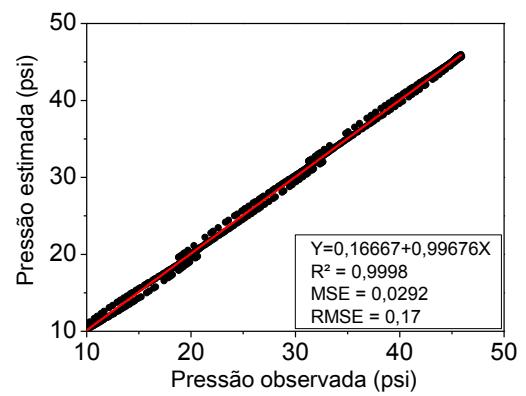


Figura 56 - Ajuste dos dados estimados pelo modelo da rede versus o valor observado.

4.3 Modelagem rede neuronal inversa

A modelagem da rede neuronal inversa gera como resultado a resposta da variável manipulada frente à distúrbios inerentes ao processo. Neste caso, são validadas a resposta do índice de abertura da válvula *choke* e a frequência da bomba, que atuam como possíveis variáveis manipuladas para as aplicações em malha fechada.

As Figuras 57 - 61 ilustram a resposta da modelagem neuronal para dados de treinamento na planta experimental em malha aberta, ou seja, durante a aquisição de dados foram implementadas perturbações no índice de abertura da válvula *choke*. A frequência de bombeio empregada foi de 30, 45 e 60 Hz, respectivamente. Como pode ser observado, a estimação dos índices de abertura da válvula *choke* pela rede foram bem sucedidas, apresentando bons índices de correlação.

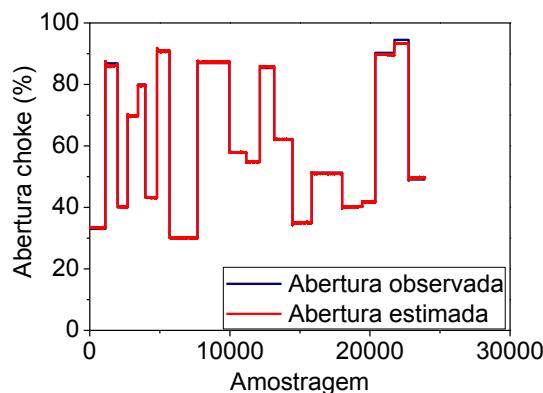


Figura 57 – Estimação da abertura da válvula *choke* com nove neurônios na camada oculta.

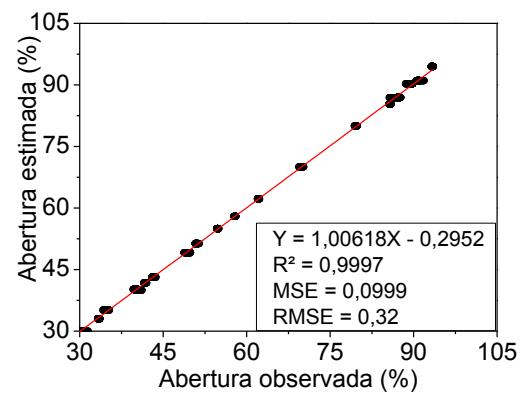


Figura 58 - Ajuste dos dados estimados pelo modelo da rede versus o valor observado da abertura da válvula *choke*.

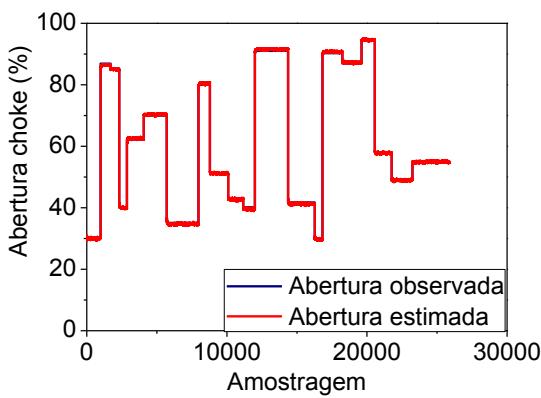


Figura 59 - Predição da abertura da válvula *choke* com nove neurônios na camada oculta.

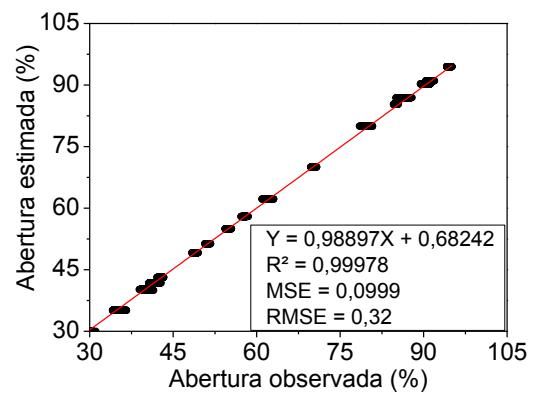


Figura 60 - Ajuste dos dados preditos pelo modelo da rede versus o valor medido da abertura da válvula *choke*.

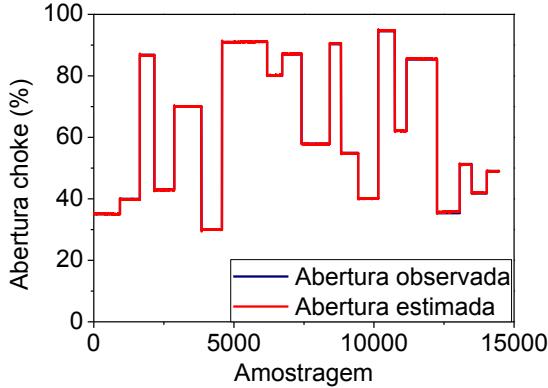


Figura 61 – Predição da abertura da válvula *choke* com cinco neurônios na camada oculta.

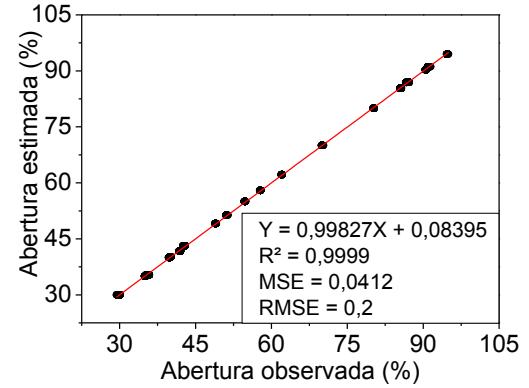


Figura 62 – Ajuste dos dados preditos pelo modelo da rede versus o valor medido da abertura da válvula *choke*.

As Figuras 63 - 65 ilustram os resultados dos testes da rede para os casos em que se avalia, como saída, a frequência da bomba e o índice de abertura da válvula *choke* (Figuras 66 - 67). Neste tipo de abordagem, foram apresentados dados obtidos através de testes de controle empregando o controlador clássico PI. Assim, para cada mudança de *set point* empregada, a variável manipulada agia de forma a rastrear o valor desejado para a pressão anular de fundo. O modelo neuronal, mais uma vez se mostrou eficiente em captar a dinâmica do processo, apresentando resposta satistafória para ambos os casos. Para a aquisição de dados visando a modelagem neuronal, implementou-se uma mudança de *set point* onde a variável manipulada, frequência da bomba de alimentação e a abertura da válvula *choke*, era responsável por fazer com que a pressão atingisse a pressão determinada pelo *set point*, pré-estabelecido.

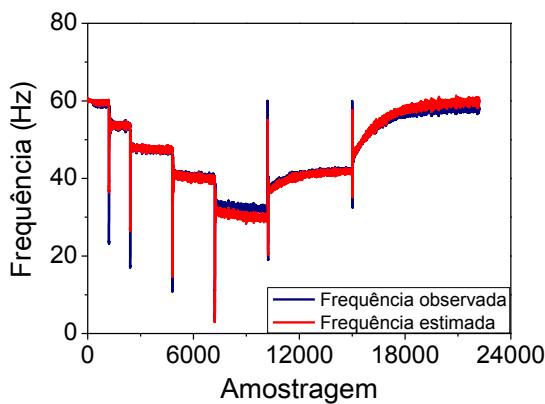


Figura 63 – Saída da rede para dados de entrada em malha fechada, variável manipulada: frequência da bomba de água.

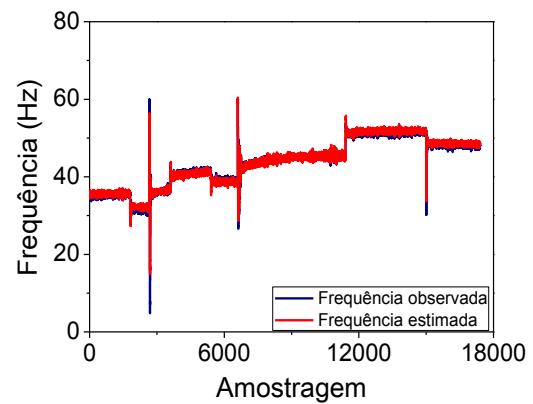


Figura 64 – Saída da rede para dados de entrada em malha fechada, variável manipulada: frequência da bomba de água.

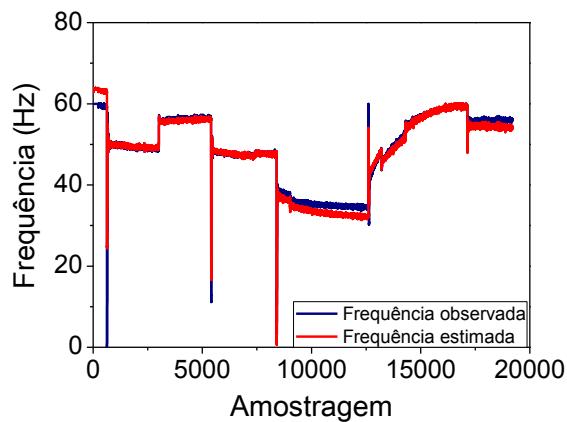


Figura 65 – Saída da rede para dados de entrada em malha fechada, variável manipulada: frequência da bomba de água.

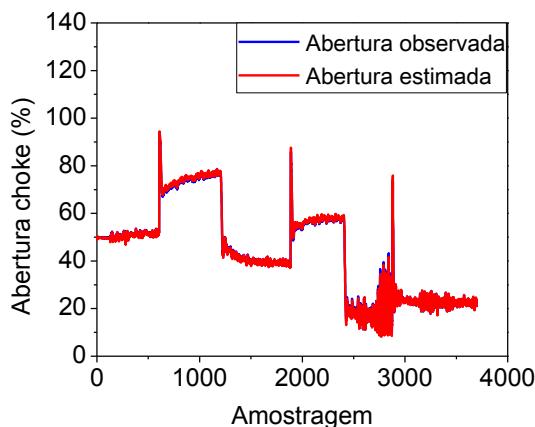


Figura 66 – Saída da rede para dados de entrada em malha fechada, variável manipulada: válvula choke.

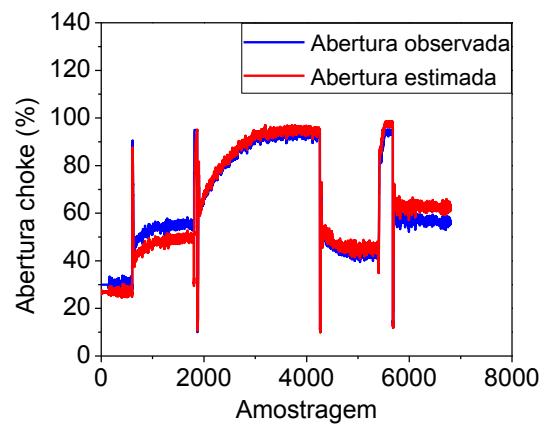


Figura 67 – Saída da rede para dados de entrada em malha fechada, variável manipulada: válvula choke.

4.3.1 Estimação dos parâmetros do controlador PI

Os parâmetros do controlador PI foram calculados adotando-se as metodologias de Ziegler-Nichols (ZN - 1942) e Cohen-Coon (CC - 1953). As tabelas com os parâmetros calculados pelo método da curva de reação de Sundaresan-Krishnaswamy, para os experimentos de *kick*, perda de circulação, variação de vazão e variação da abertura da válvula *choke* são apresentadas no Anexo E. Os parâmetros calculados pelos métodos de ZN e CC (K_c e τ_i) para os testes de *kick*, perda de circulação, variação de vazão e variação do índice de abertura da *choke* são apresentados no Anexo F. Os parâmetros calculados por tais metodologias foram utilizados após ajuste fino em campo, esta etapa é crucial para que a resposta do controlador seja a mais adequada possível.

4.4 Controle via rede neuronal

Neste trabalho de dissertação de mestrado foram utilizados dois controladores neuronais: controlador neuronal (método indireto) e controlador neuronal inverso (método direto). Os controladores aqui estudados captam a dinâmica da planta e, a partir de treinamento neuronal em tempo real agem no processo atuando sob a variável manipulada (índice de abertura da válvula *choke*) para regular a resposta sob a variável controlada, neste caso a pressão anular de fundo. Contudo, o emprego do controlador com ação direta emprega valores de ajuste fixo enquanto o controlador de ação indireta atualiza seus ajustes ao longo de todo o processo.

Cada controlador apresenta uma saída distinta. No caso do controlador direto, a saída da rede é apresentada como a pressão anular de fundo. Já o controlador neuronal inverso utiliza o índice de abertura da válvula *choke* e o *set point* da pressão anular de fundo como saída. Para ambos os controladores, foram implementados testes de distúrbio de vazão, mudança de *set point*, *kick* de gás e perda de circulação. A válvula *choke* foi escolhida como variável manipulada para retratar a técnica de perfuração do tipo MPD, além de apresentar rápida influência na variável controlada. Vale ressaltar que a vazão de bombeio também poderia ser adotada como variável manipulada, entretanto não pode ser utilizada durante o procedimento de conexão de tubos.

4.4.1 Controlador via rede neuronal – método indireto

O controlador via rede neuronal acoplado ao controlador PI foi utilizado no controle da pressão anular de fundo, empregando como variável manipulada o índice de abertura da válvula *choke*. Neste esquema em malha de fechada, a rede neuronal é utilizada como um modelo não linear identificado em tempo real que atualiza os parâmetros do controlador PI configurando portanto o uso da técnica de *gain scheduling* (LEITH & LEITHEAD, 2010). A seguir serão apresentados os resultados dos testes do controlador proposto para o procedimento de conexão de tubos, para os fenômenos de *kick* de gás e perda de circulação e variações de *set point* na pressão anular (teste servo). Para avaliar o comportamento do controlador de forma mais abrangente, realizou-se um teste onde são empregadas todas as perturbações anteriormente analisadas de forma isolada.

O procedimento de conexão de tubos é um dos processos que ocorrem ao longo de toda operação de perfuração de poços, envolvendo distúrbios de vazão que levam a oscilações de pressão ao longo do poço. Na unidade experimental, este procedimento foi realizado empregando-se duas condições distintas. Na primeira, utilizou-se apenas a bomba de alimentação da coluna de perfuração; na segunda condição, fez-se o uso das bombas de água e de cascalhos. Devido às limitações físicas, as bombas tiveram suas vazões reduzidas para representar a parada da bomba, visando retratar a hidrostática de um poço real.

A Figura 68 ilustra um resultado típico do controle da pressão anular de fundo frente ao distúrbio de vazão operando-se com uma bomba. Este tipo de teste é realizado a partir do emprego de uma perturbação na frequência da bomba que alimenta a coluna de perfuração,

neste caso reduziu-se a frequência da bomba de 35 Hz para 30 Hz. Antes de iniciar a ação do controlador neuronal, a rede é apresentada à dados de treinamento da dinâmica do processo. Para isso, foram implementadas duas variações na frequência de bombeio do sistema em malha aberta, gerando desta forma dados de aprendizagem. Tais perturbações são necessárias para que haja a captação dos possíveis níveis de pressão que o sistema pode apresentar frente a distúrbios de vazão para o qual o sistema está sujeito.

Com o ínicio da ação do controlador pode-se observar que a válvula *choke* começa a alterar seu índice de abertura para manter a pressão no *set point* estipulado (Figura 69). Com a queda de vazão, oriunda da redução na frequência de bombeio, a variável manipulada responde restringindo sua abertura, para fazer com que a pressão do sistema retorne ao valor desejado. Nota-se que a pressão do sistema é restabelecida rapidamente através da ação do controlador que age recalculando seu ganho. Neste teste, foram empregados como parâmetros iniciais $K_c = -0,03$ e $\tau_i = 0,2$.

A Figura 70 ilustra a variação do ganho do controlador frente ao distúrbio de vazão implementado. No momento em que a vazão é reduzida, o ganho reduz drasticamente fazendo com que a pressão seja restabelecida rapidamente. No segundo momento de perturbação da vazão, quando a frequência original de bombeio é retomada, a variação do K_c se mostra menos pronunciada, fazendo com que a retomada da pressão no *set point* pré-estabelecido se torne mais suave. O controlador utilizado só emprega o cálculo de novos ganhos para controlar a pressão anular de fundo caso haja, no sistema, alguma perturbação que faça com que a pressão saia do *set point*.

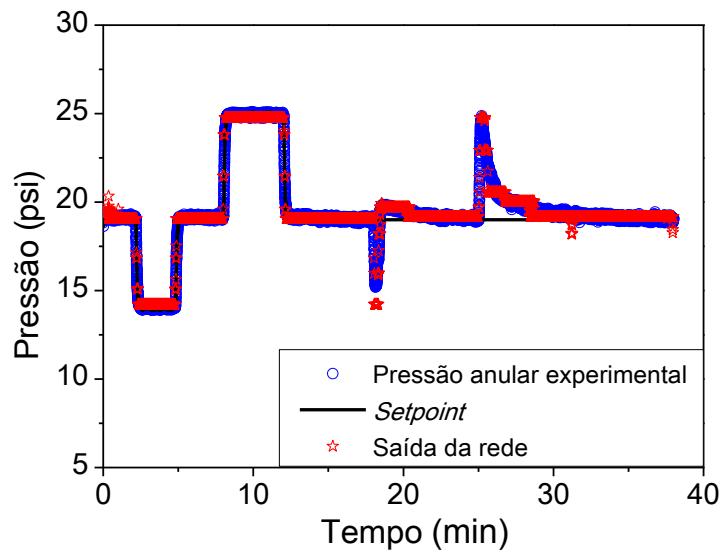


Figura 68 – Distúrbio de vazão.

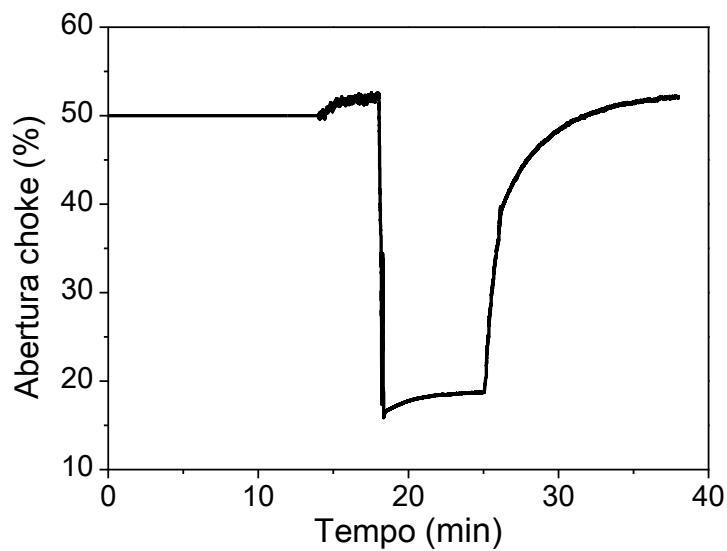


Figura 69 – Variável manipulada.

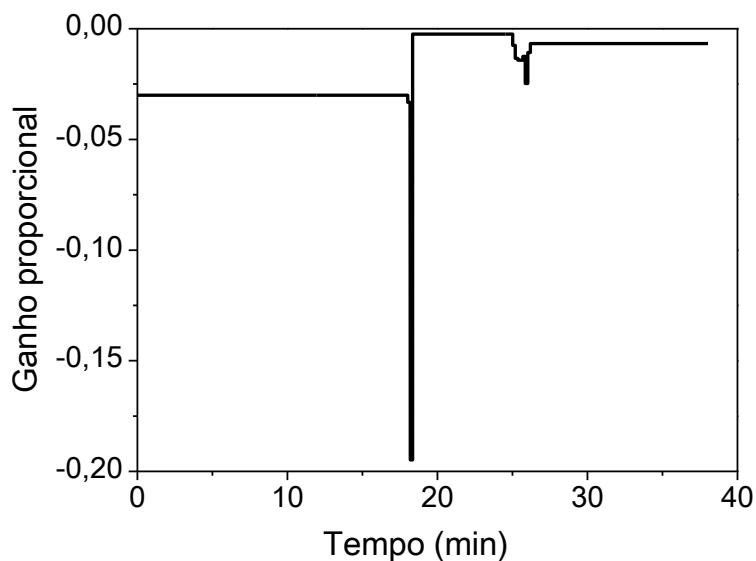


Figura 70 – Variação do ganho do controlador frente a distúrbio de vazão.

A Figura 71 ilustra o resultado do teste de conexão de tubos empregando-se as bombas de água e de cascalhos da unidade experimental. Tal experimento foi realizado com as duas bombas a 30 Hz. Após a apresentação de dados de distúrbios de vazão iniciou-se o controle da pressão via rede neuronal. A partir do momento em que o sistema atinge o estado estacionário, emprega-se a perturbação na frequência da bomba de água, simulando a parada da bomba (frequência da bomba foi reduzida em 10Hz). Enquanto isso, a outra bomba é mantida com a frequência constante. Com a queda de pressão, devido à redução da vazão, a válvula *choke* restringe sua abertura para garantir que a pressão do sistema retorne ao *set point* determinado. Observa-se que neste primeiro momento, a pressão é restabelecida rápida e eficientemente. Quando o sistema atinge o estado estacionário, na nova condição, retorna-se a frequência da bomba para o valor inicial (30 Hz), representando o religamento da bomba, quando isto acontece, uma elevação de pressão no anular é sentida. Desta forma, a válvula *choke* age aumentando sua abertura, aliviando a pressão do sistema.

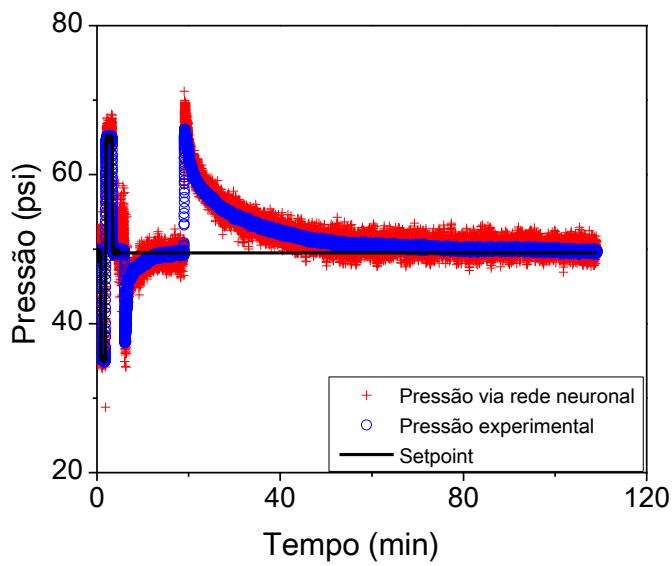


Figura 71 – Controle da pressão para o procedimento de conexão de tubos.

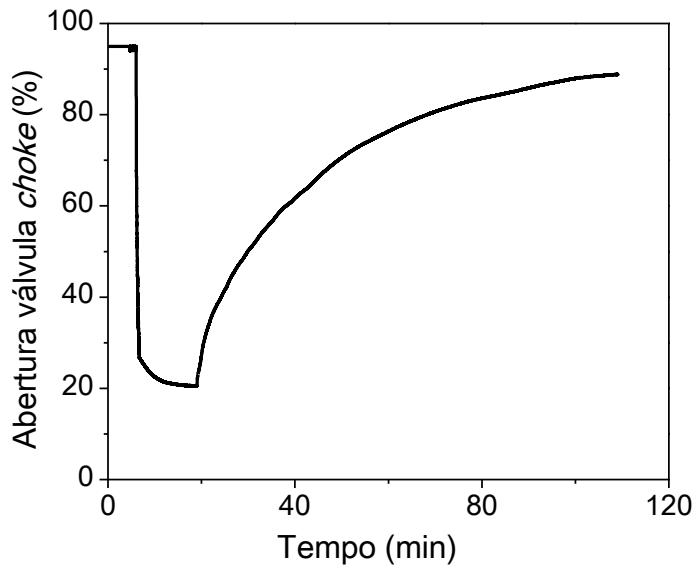


Figura 72 – Variação do índice de abertura da válvula *choke*.

Experimentos de *kick* de gás, na unidade experimental, são realizados por meio de um influxo do reservatório, injeção de gás, na região anular. Experimentalmente, o *kick* de gás pode ser observado pelo aumento da vazão lida no anular como ilustrado na Figura 73. Para que o *kick* de gás seja controlado, é necessário que a pressão anular de fundo seja maior que a pressão nos poros do reservatório, restabelecendo o equilíbrio entre as pressões e, assim, inibindo o *kick* de gás.

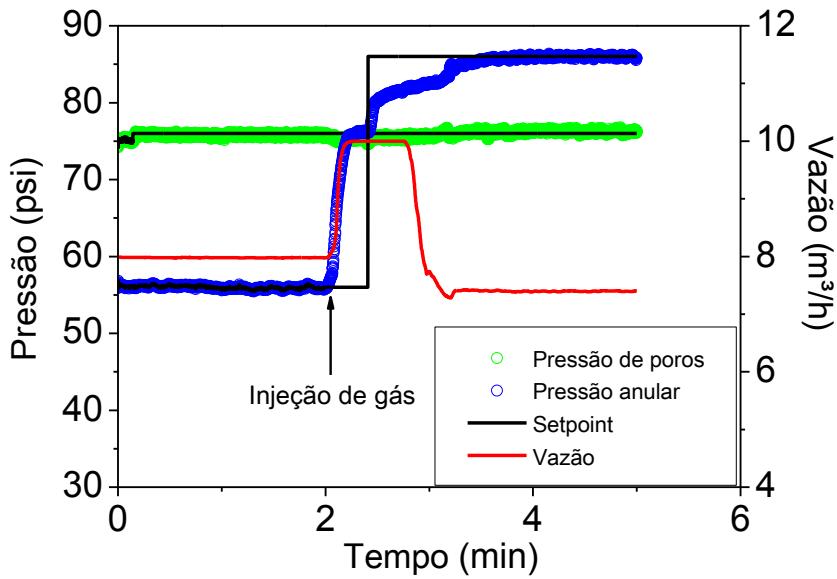


Figura 73 – Kick de gás.

Para o caso da perda de circulação (Figura 74), fluido é perdido para o reservatório, sendo tal distúrbio detectado pela queda de vazão no anular. Diferentemente do kick de gás, para se controlar uma perda de circulação, a pressão anular de fundo deve ser reduzida para restabelecer o equilíbrio entre as pressões. Como pode ser observado, a redução da pressão anular de fundo faz com que a vazão inicialmente utilizada seja retomada, levando à redução da perda de circulação.

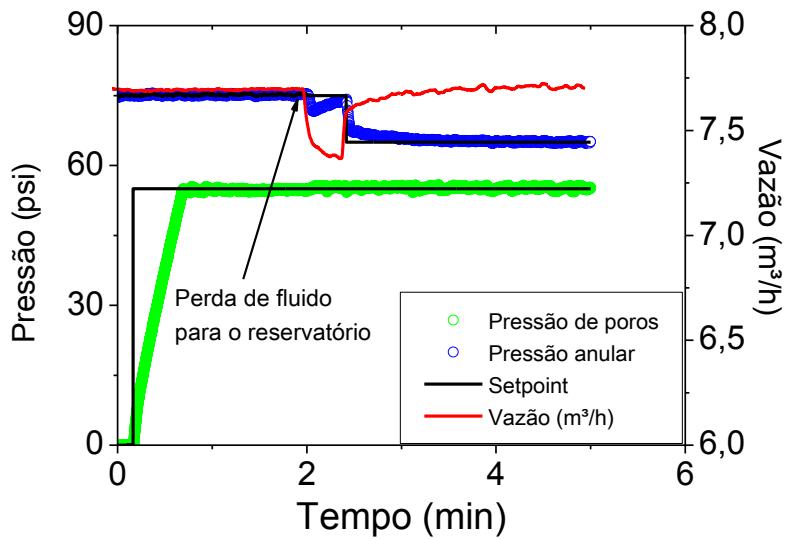


Figura 74 – Perda de circulação.

Assim como nos experimentos em que são empregados distúrbios de vazão, o teste de kick, utilizando o controlador neuronal, é realizado implementando-se, inicialmente, uma perturbação análoga a perturbação de interesse. Neste caso, para a implementação do teste de kick, a rede neuronal é treinada aplicando-se uma restrição no índice de abertura da válvula choke. Tal restrição faz com que a pressão do sistema aumente consideravelmente como se houvesse ocorrido um kick de gás (ponto 1). Em seguida, retorna-se o sistema para o estado

operacional inicialmente estabelecido (ponto 2). Esta etapa gera dados de aprendizagem para a rede neuronal sendo esta, posteriormente, capaz de atualizar os parâmetros do controlador atuando como um modelo não linear.

Tendo sido a etapa de treinamento bem sucedida inicia-se a ação do controlador (ponto 3). O controlador neuronal é acionado mantendo-se o sistema em estado estacionário. Em seguida, implementa-se uma perturbação no sistema (ponto 4) através da válvula de permeabilidade, a qual realiza acoplamento entre o anular e o reservatório. Uma vez que a pressão de poros é superior a pressão anular (BHP), fluido do reservatório (ar comprimido) migra para o interior do anular fazendo com que a pressão no interior do mesmo aumente, caracterizando a ocorrência do *kick*. Para que o *kick* seja controlado é necessário que haja uma modificação do *set point* da pressão anular de fundo, desta forma foi estipulado para a pressão anular de fundo um valor de *set point* 10 psi acima da pressão do reservatório. A Figura 75 ilustra os resultados para a implementação de *kick* de gás com 40% do índice de abertura da válvula de permeabilidade. A Figura 74 ilustra o comportamento da variável manipulada frente o controle da pressão para ocorrência de *kick* de gás. Os pontos 1 e 2 indicam a etapa de treinamento realizado por parte da rede neuronal. A partir do ponto 3 a variável manipulada relaciona-se com o controlador buscando o controle efetivo da pressão anular de fundo. A Figura 75 ilustra a variação do ganho proporcional, atualizado ao longo do processo

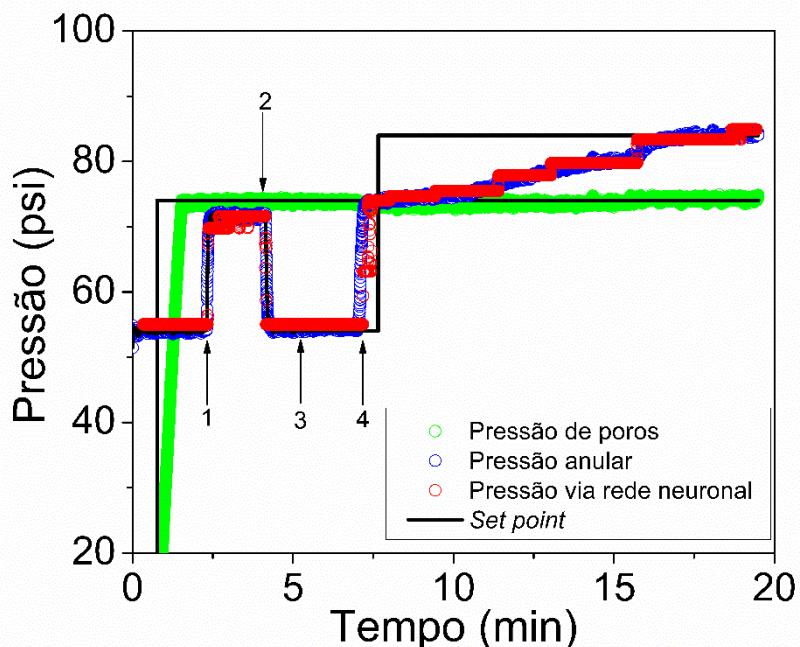


Figura 75 – Kick de gás com 40% de permeabilidade da rocha reservatório.

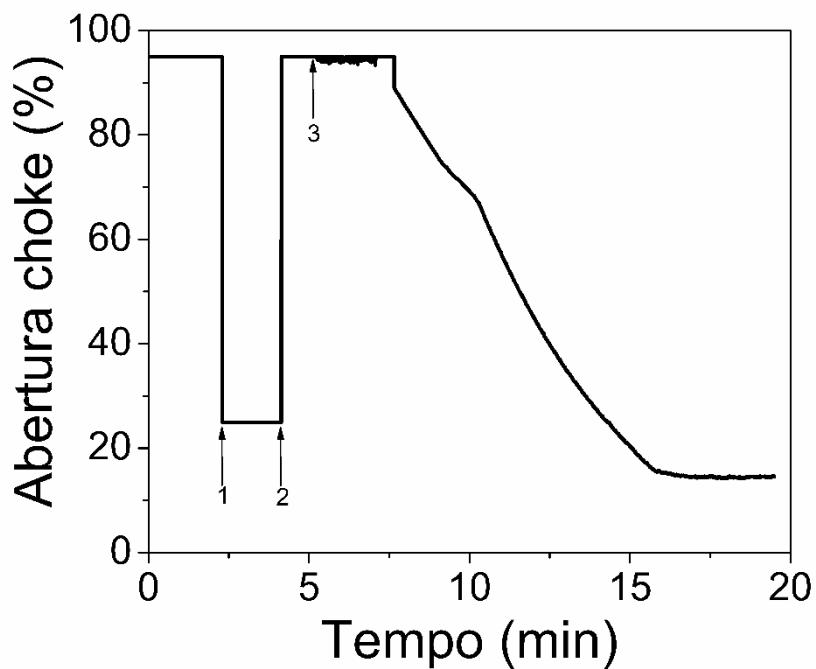


Figura 76 – Resposta da variável manipulada.

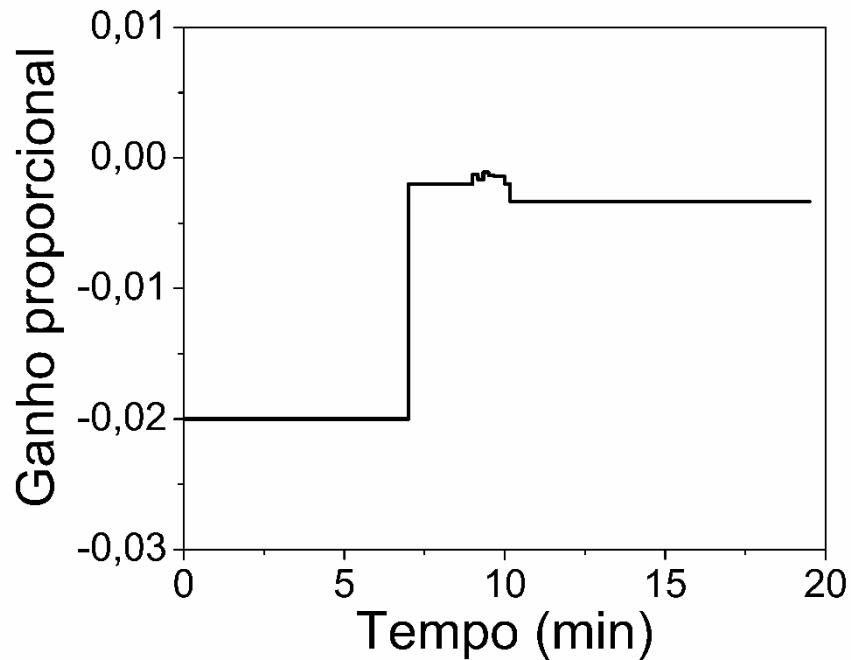


Figura 77 – Ganho do controlador.

A Figura 78 ilustra o resultado para a perda de circulação, empregando 40% para o índice de abertura da válvula permeabilidade do tanque reservatório como perturbação. Além da pressão do sistema, são apresentadas as respostas do comportamento da válvula *choke* e a variação do ganho (k_c) recalculado pelo controlador. Assim como no caso anterior, para realizar o controle da pressão frente a perda de circulação é necessário que seja realizado o treinamento prévio da rede. O ponto 1 ilustra a etapa de treinamento, onde pelo alívio no índice de abertura da válvula *choke* ocorre queda na pressão anular de fundo análoga à uma perda de circulação. Em seguida, retorna-se o sistema para o estado operacional inicialmente estabelecido (ponto 2).

Tendo sido a etapa de treinamento bem sucedida inicia-se a ação do controlador (ponto 3) mantendo – se o sistema em estado estacionário. Em seguida, implementa-se uma perturbação no sistema (ponto 4) através da válvula de permeabilidade. Uma vez que a pressão de poros é inferior a pressão anular (BHP), fluido de perfuração invade o reservatório fazendo com que a pressão no anular decaia. Desta forma, para que a perda de circulação seja controlada é necessário que haja uma modificação do *set point* da pressão anular de fundo, assim foi estipulado para a pressão anular de fundo um valor de *set point* 10 psi acima da pressão do reservatório.

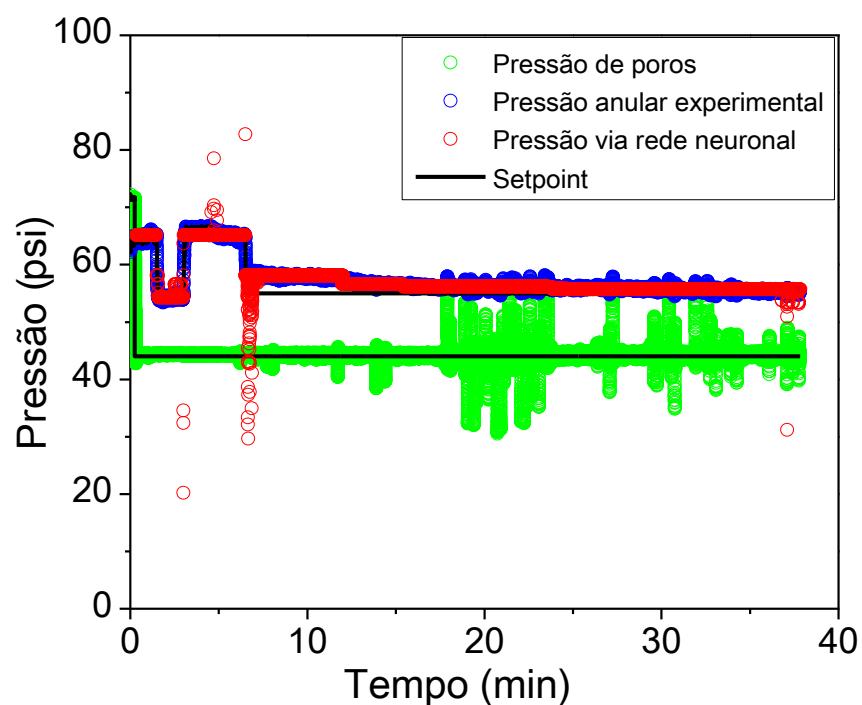


Figura 78 – Perda de circulação com 40% de permeabilidade da rocha reservatório.

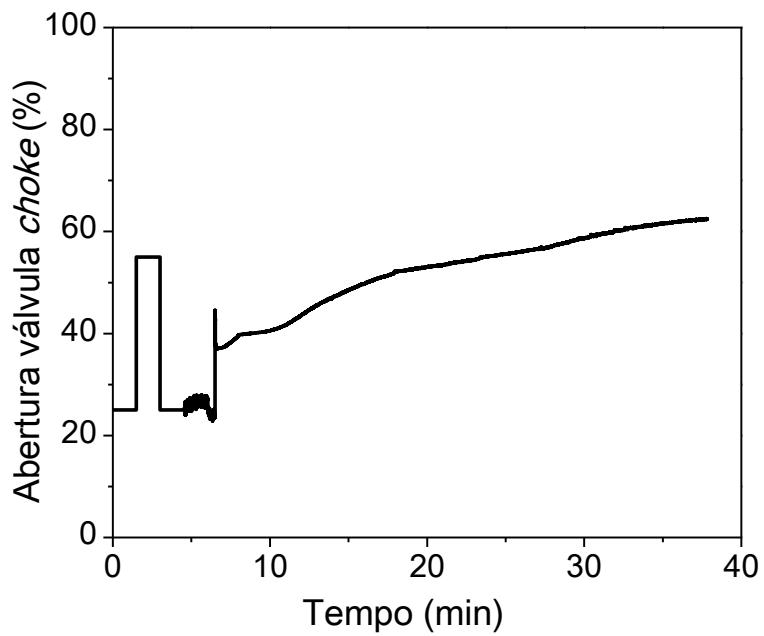


Figura 79 – Resposta da variável manipulada.

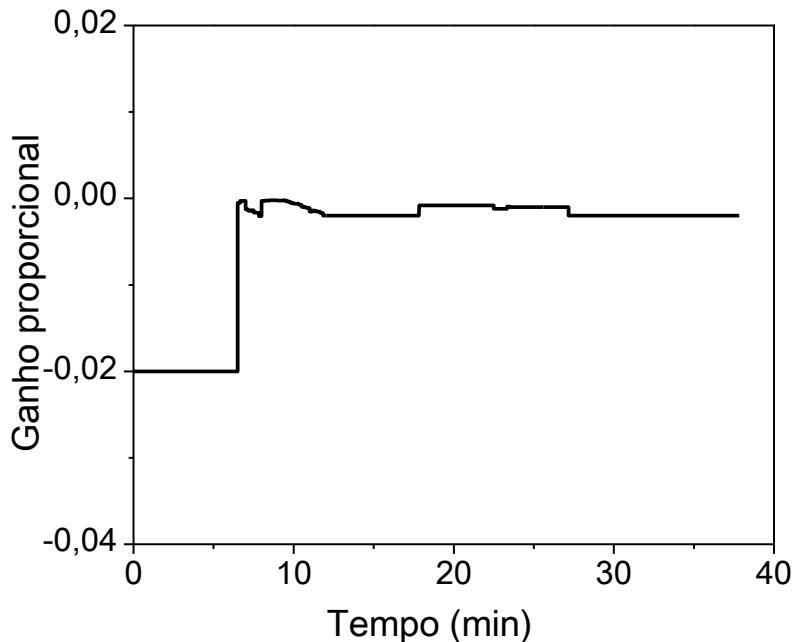


Figura 80 – Ganho do controlador.

A rede neuronal empregada nos testes de controle para *kick* de gás e perda de circulação utilizou três dados passados de pressão anular de fundo e nove neurônios na camada oculta. Com os resultados apresentados pode-se observar que o controlador apresentou uma boa resposta frente aos distúrbios implementados, mostrando-se eficiente ao controlar a pressão anular de fundo (BHP). No Anexo G são ilustrados os demais resultados para o controle de *kick* de gás e perda de circulação pra aberturas da válvula de permeabilidade em 50 e 60%.

Com o decorrer do processo de perfuração, as pressões aumentam com o aumento da profundidade sendo fundamental assegurar perfuração dentro da janela operacional (acima da pressão de poros e abaixo da pressão de fratura) registrando de forma eficiente os *set points* de pressão anular de fundo apropriados. Assim, foram implementados testes para mudança de *set point* para avaliar o comportamento do controlador (teste servo).

Foram implementados quatro mudanças de *set point* na pressão anular de fundo (pontos 1, 2, 3 e 4). Com o aumento da pressão, a válvula *choke* restringe gradativamente seu índice de abertura, fazendo com que a pressão seja controlada rapidamente. Os parâmetros iniciais foram ajustados em $K_c = -0,02$ e $\tau_i = 0,2$. A Figura 81 ilustra a resposta do controlador neuronal frente as mudanças de *set point*, mostrando-se eficiente. As Figura 82 e Figura 83 ilustram, respectivamente, a variação do índice de abertura da válvula *choke* e o valor do ganho proporcional atualizado via rede neuronal.

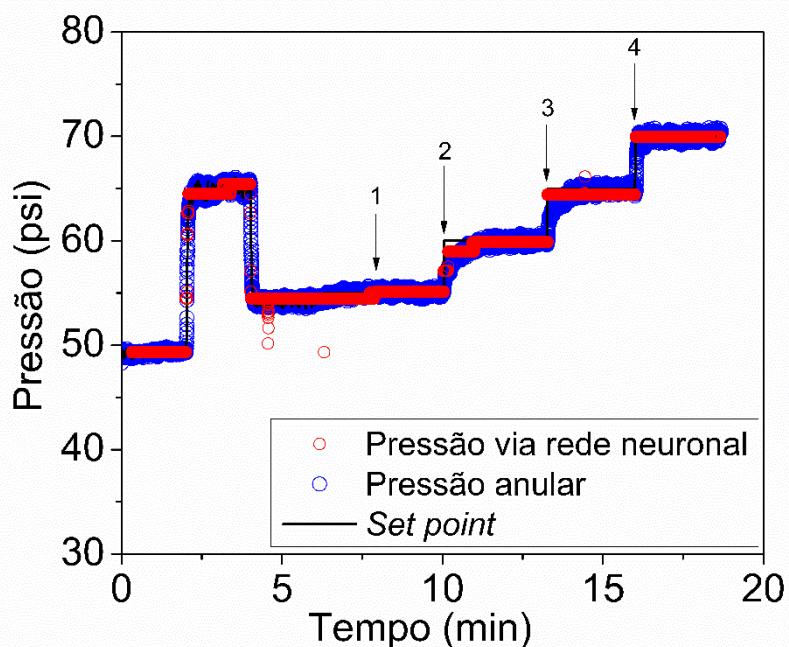


Figura 81 – Controle via rede neuronal da pressão anular de fundo.

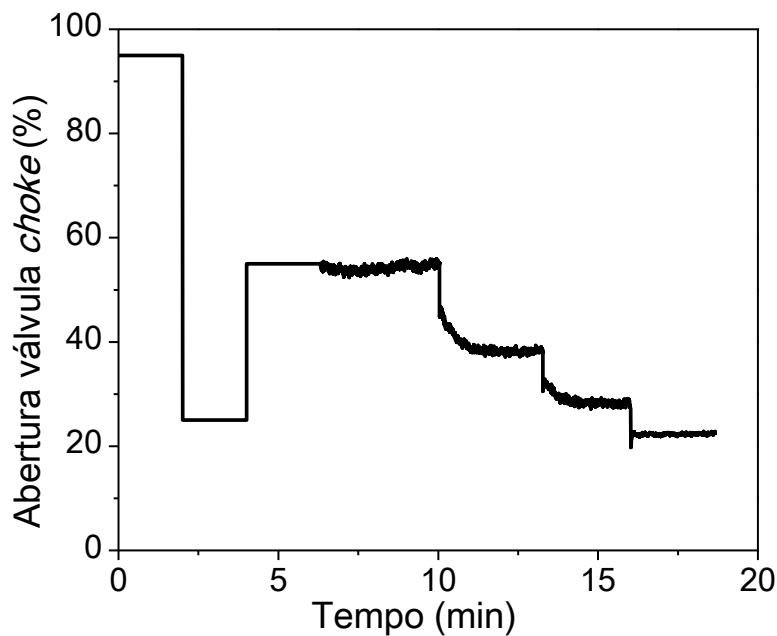


Figura 82 – Comportamento da variável manipulada para mudança de *set point*.

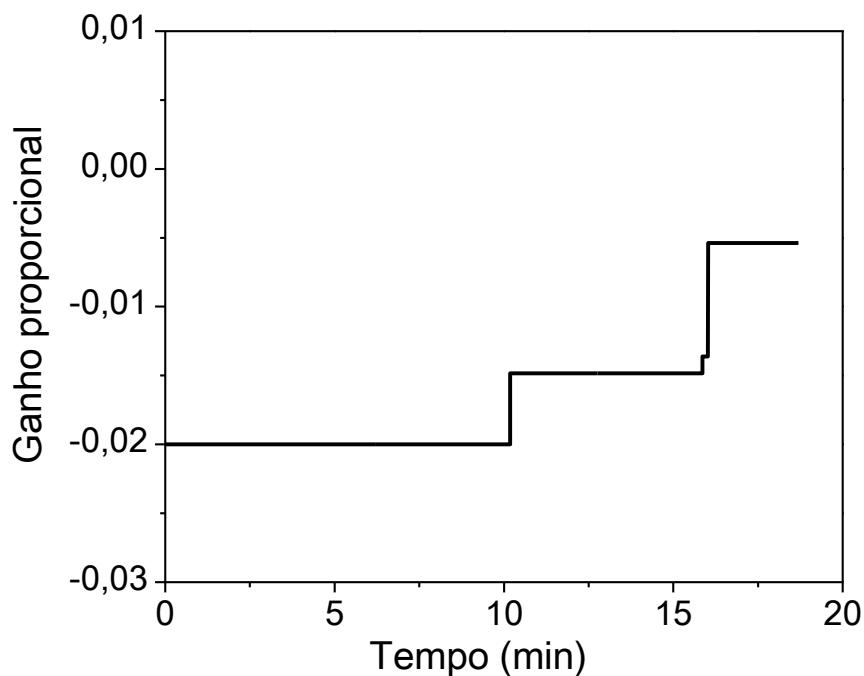


Figura 83 – Ganho do controlador atualizado via rede neuronal.

Ao longo da perfuração de poços de petróleo, diversos distúrbios podem ser encontrados. De fato, cada uma das perturbações avaliadas até aqui não acontecem de maneira isolada. Desta forma, foi implementado um teste experimental englobando todas as análises até aqui apresentadas com o objetivo de avaliar o comportamento do controlador neuronal desenvolvido. Este tipo de teste visou retratar a natureza inherentemente transitória do processo de perfuração de poços de petróleo.

O teste em questão, apresenta resultados de um processo de perfuração onde é realizado um procedimento de conexão de tubos, seguido por um *kick* de gás e perda de circulação. Uma vez que os fenômenos de *kick* e perda de circulação são eventos que ocorrem em consonância, os mesmos foram implementados em sequência.

Antes de iniciar a ação pelo controlador neuronal, assim como nos testes anteriores, foi necessário apresentar dados de treinamento para a rede. Para isso, foram implementadas perturbações no índice de abertura da válvula *choke* e na vazão do sistema em malha aberta, gerando oscilações na pressão anular de fundo (pontos 1 – 4). Após o treinamento ter sido bem realizado e a rede neuronal ter apresentado boa resposta, a condição operacional inicial é restabelecida (ponto 5). Em seguida, mantendo-se o sistema em estado estacionário iniciou - se a ação do controlador. A primeira perturbação imposta ao sistema (ponto 6) sob ação do controlador, se deu pelo procedimento de conexão de tubos realizado experimentalmente pela redução e retomada da vazão de bombeio de fluido de perfuração. Neste caso, implementou-se uma redução de 10 Hz na frequência da bomba (íncio do procedimento de conexão de tubos) o que acarreta automaticamente uma queda nos níveis de pressão anular de fundo. Frente a tal redução de bombeio pode-se observar que:

- A válvula *choke* restringiu seu índice de abertura para aproximadamente 19%. Essa rápida restrição de abertura está intrinsecamente ligada à estimativa do ganho proporcional pelo controlador neuronal;
- No momento em que ocorre o distúrbio na vazão, o parâmetro do controlador se altera para conferir uma maior velocidade de resposta a variável manipulada e, consequentemente, regular a pressão anular de fundo;
- A queda acentuada nos níveis de pressão anular de fundo. Tal distúrbio é rejeitado satisfatoriamente pela ação do controlador.

Com a retomada da vazão inicialmente empregada (ponto 7), fim do procedimento de conexão de tubos, a válvula *choke* aumentou seus níveis de abertura gradativamente, conferindo uma ação de controle suave sem a presença de *overshoots*. Pode-se observar que tal distúrbio de vazão é rejeitado satisfatoriamente sendo a pressão anular de fundo controlada no valor desejado. Após a estabilização da pressão, finalizado o procedimento de conexão de tubos, implementou-se um *kick* de gás na unidade (ponto 8), por meio da válvula de permeabilidade acoplada ao anular. Uma vez que a pressão de poros encontrava-se em um valor superior a pressão anular de fundo (BHP), no momento da perturbação, ou seja, com a abertura do índice da válvula de permeabilidade, gás proveniente do tanque reservatório migrou para o interior do poço fazendo com que a pressão anular de fundo aumentasse atingindo valor superior a pressão de poros. O controle da pressão anular de fundo durante o *kick* de gás foi realizado em um valor de pressão 5 psi acima do valor da pressão registrada no tanque reservatório (pressão de poros). Por fim, implementou-se uma redução na pressão do reservatório (ponto 9). Tal redução de pressão faz com que a pressão anular de fundo (BHP) se torne maior que a pressão de poros gerando, desta forma, uma perda de circulação no sistema. Para que a perda de circulação fosse então controlada, implementou-se uma redução na pressão anular de fundo (ponto 10). A Figura 84 ilustra o processo de perfuração experimental aqui reportado. As Figuras Figura 85 e Figura 86 representam o comportamento do índice de abertura da válvula *choke* e atualização do ganho do controlador via rede neuronal.

Vale ressaltar que as oscilações de pressão de poros observadas no tanque reservatório são ocasionadas pelo fluxo de água para o interior do mesmo. Este fenômeno, reportado por Russano (2014), acontece em virtude da entrada de água no tanque de pressão (reservatório) que gera, por consequência, distúrbios na pressão interna do tanque reservatório.

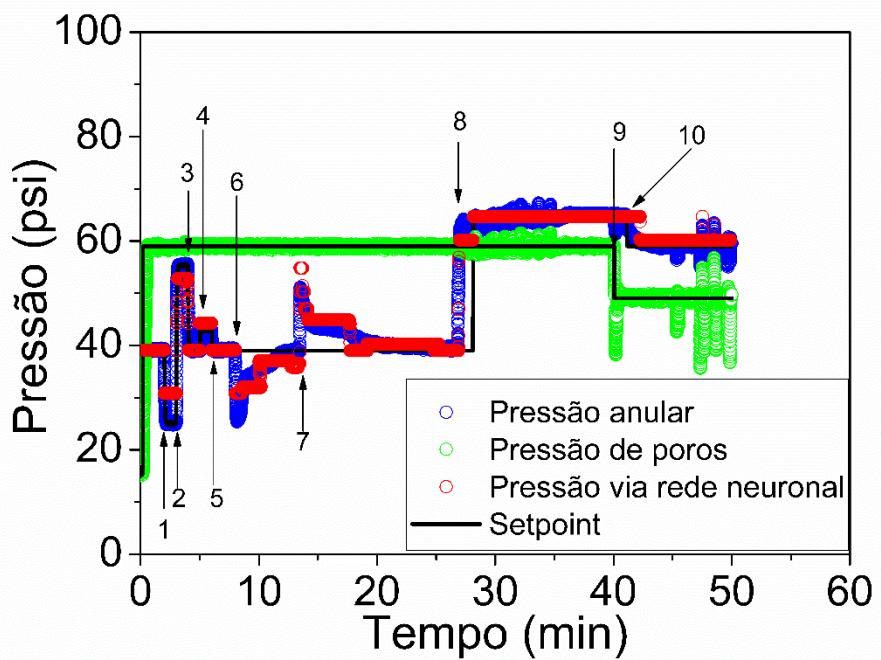


Figura 84 – Controle da pressão anular de fundo via rede neuronal.

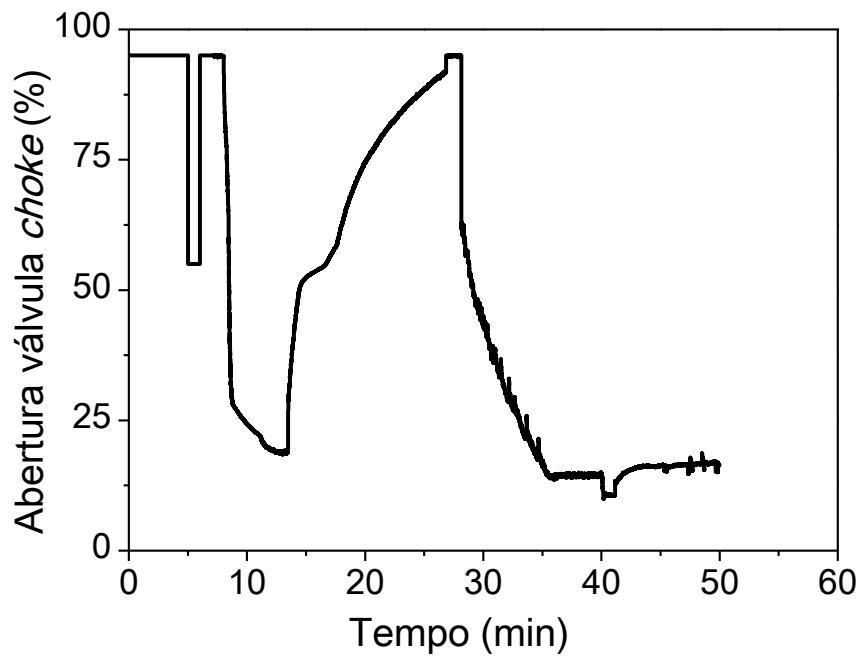


Figura 85 – Comportamento da variável manipulada.

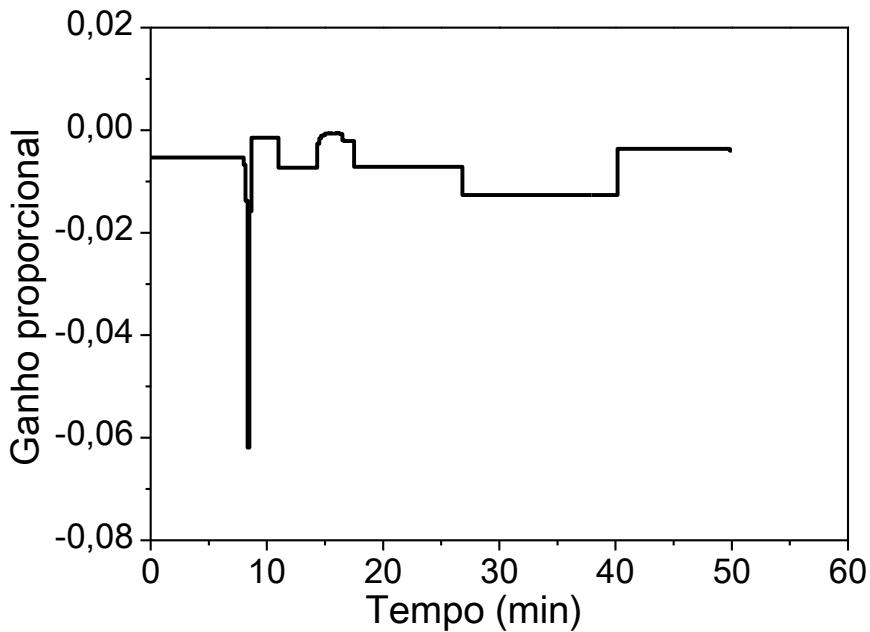


Figura 86 – Ganho do controlador atualizado via rede neuronal.

4.4.2 Controlador via rede neuronal inversa – método direto

O controlador via rede neuronal inversa, estima diretamente o valor da variável manipulada (índice de abertura da válvula *choke*) a fim de obter uma saída desejada, *set point* de pressão anular de fundo para o processo. Assim como no controlador anterior, para avaliação do controlador via rede neuronal inversa, foram implementados experimentos de mudança de *set point*, *kick* de gás, perda de circulação e conexão de tubos. Para avaliar o comportamento do controlador frente a todos esses fenômenos que acarretam distúrbio na pressão anular, foi realizado um experimento englobando todas essas perturbações, simultaneamente. Vale ressaltar que, em todos os testes de controle via rede neuronal inversa, foi empregada a rede com três dados passados de pressão e nove neurônios na camada oculta.

Antes de iniciar o controle pelo método direto, é necessário que sejam apresentados dados para o treinamento da rede. O treinamento inicial é realizado empregando-se um controlador PI. Após o treinamento, efetua-se o controle via rede neuronal inversa. Para fins de segurança operacional, visando assegurar a não utilização de uma rede neuronal que apresente singularidades, ou seja, que não apresente comportamento incomum, comportamento este possível de ser observado (Vega et al., 2008), a saída da rede (método direto) foi comparado à saída do controlador clássico PI. Caso a diferença fosse significativa, implementava-se a saída do controlador clássico PI.

A Figura 87 ilustra o controle da pressão anular de fundo obtida através de perturbações no *set point* de pressão anular. Foram empregados os parâmetros $K_c = -0,02$ e $\tau_i = 0,2$ para o controlador clássico PI. A Figura 88 ilustra a ação do controlador atuando sob a variável manipulada. Pode - se observar que o controlador mostrou ser eficiente em calcular o índice de abertura da válvula *choke*, garantindo o controle eficiente da pressão anular de fundo.

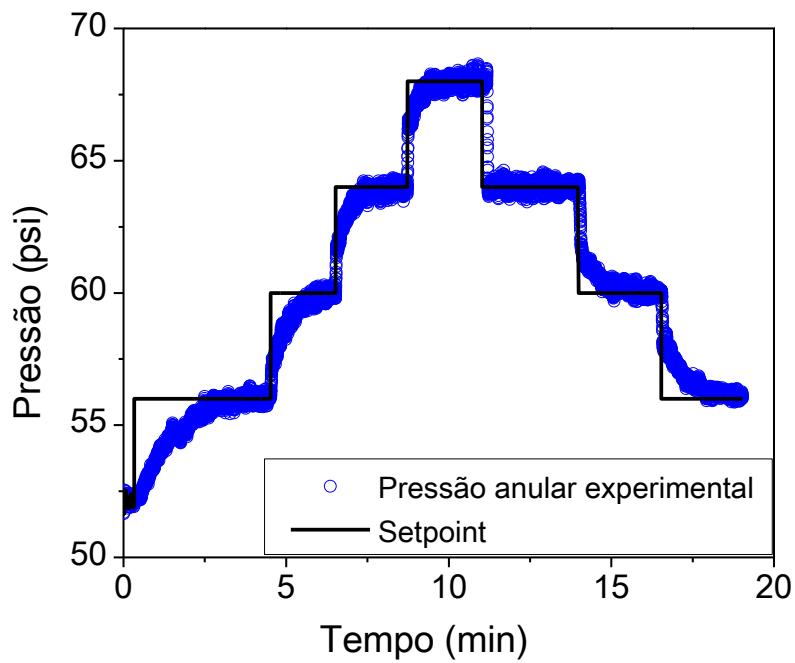


Figura 87 – Controle da pressão anular para diferentes *set points*

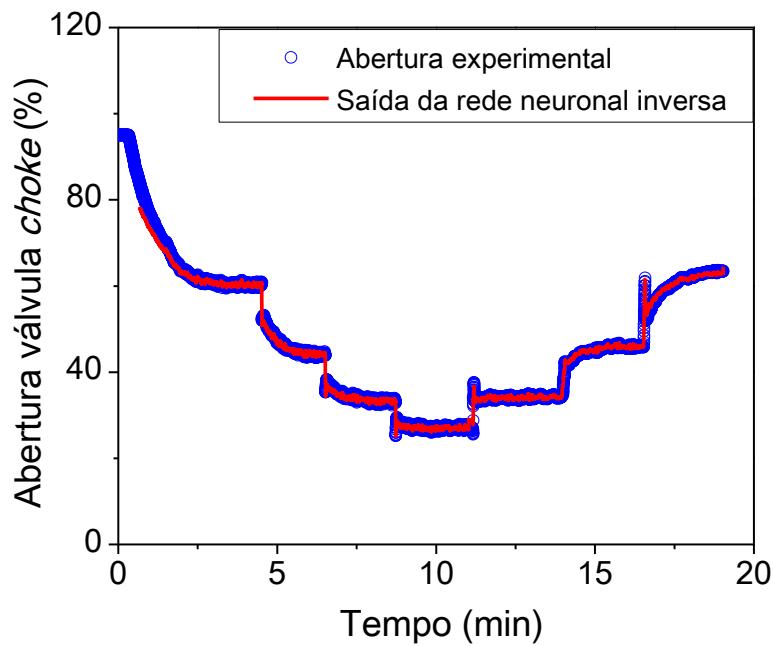


Figura 88 – Resposta do controlador neuronal inverso.

A Figura 89 ilustra a resposta do controlador para um teste de *kick* de gás, empregando-se 60% de abertura para a válvula de permeabilidade. A Figura 90 ilustra a ação da variável manipulada necessária para que a pressão anular de fundo seja controlada. As respostas do controlador para índices de abertura da válvula de permeabilidade em 40 e 50% são apresentadas no Anexo H.

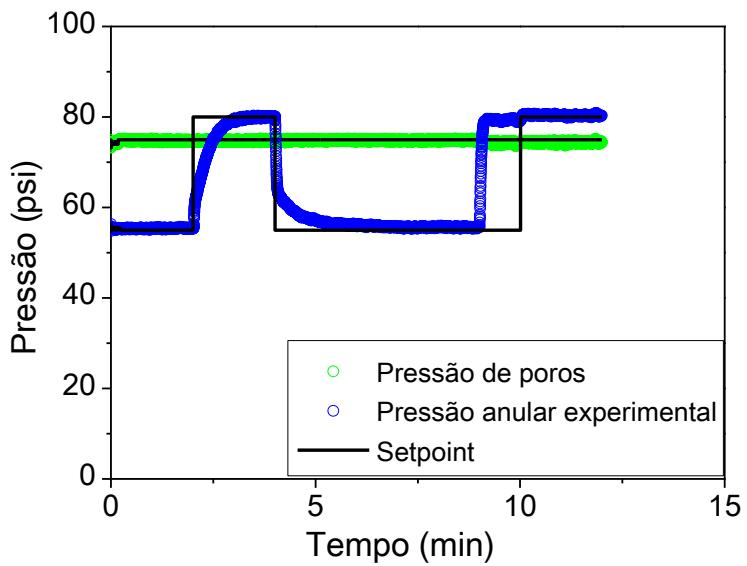


Figura 89 – Controle de *kick* de gás.

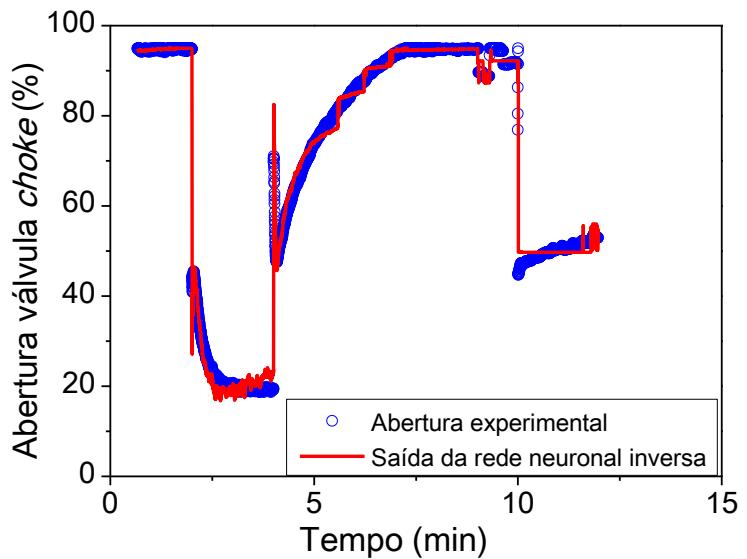


Figura 90 – Resposta do controlador neuronal inverso.

A Figura 91 ilustra o controle da pressão anular de fundo frente ao problema de perda de circulação, empregando-se índice de abertura da válvula de permeabilidade em 60%. A resposta obtida para a abertura da válvula *choke* pelo controlador neuronal é ilustrada na Figura 92.

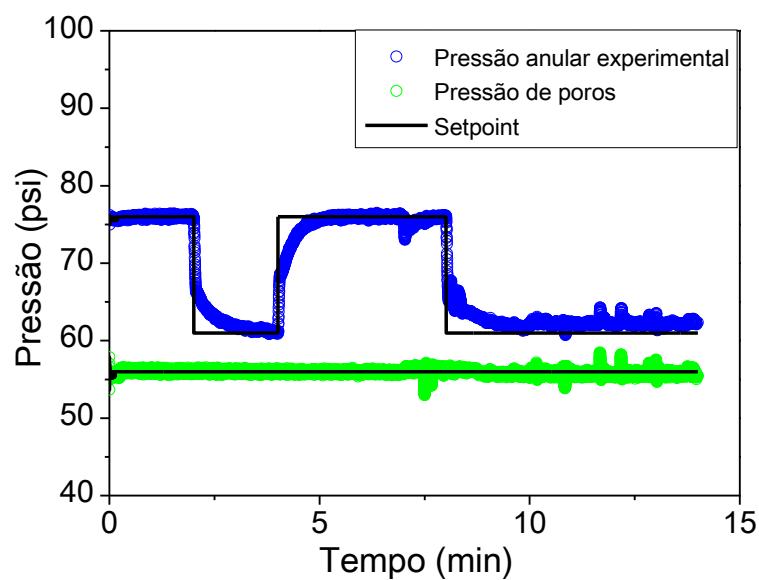


Figura 91 – Controle da pressão anular frente a perda de circulação.

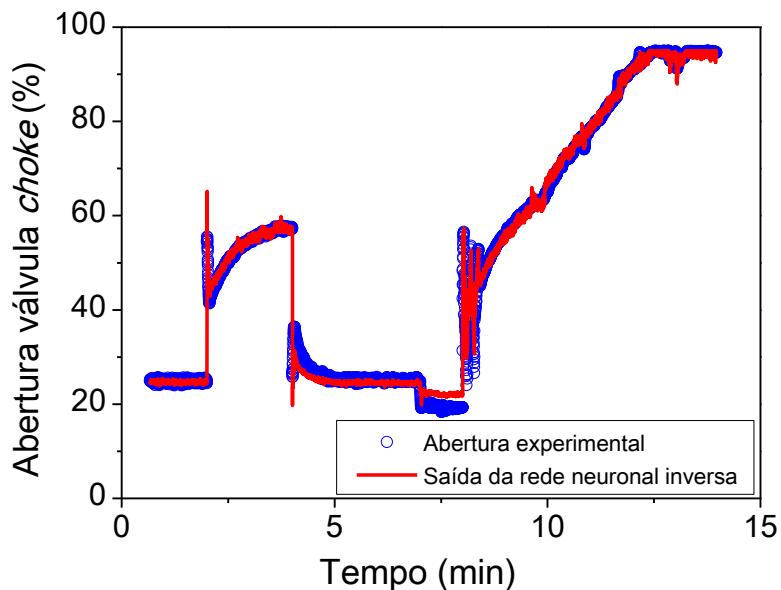


Figura 92 – Resposta do controlador neuronal inverso.

A Figura 93 ilustra o controle da pressão anular de fundo para a etapa de procedimento de conexão de tubos. A saída do controlador neuronal é ilustrada na Figura 94.

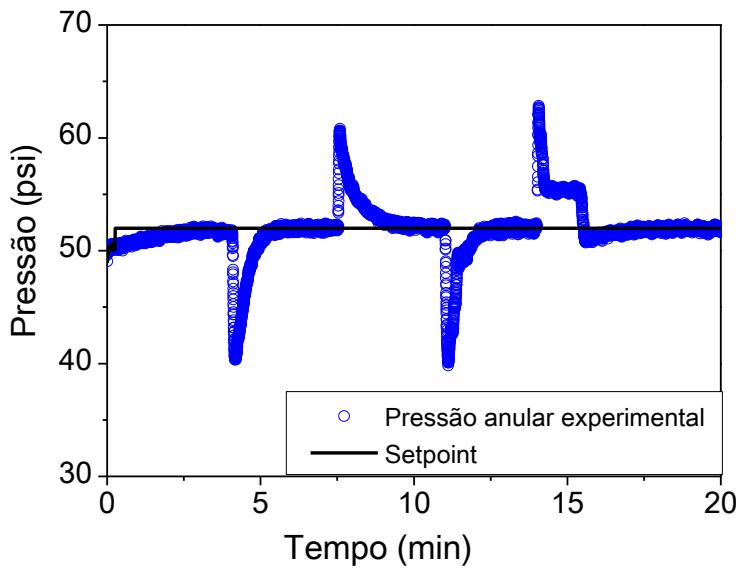


Figura 93 – Controle da pressão anular durante o procedimento de conexão de tubos.

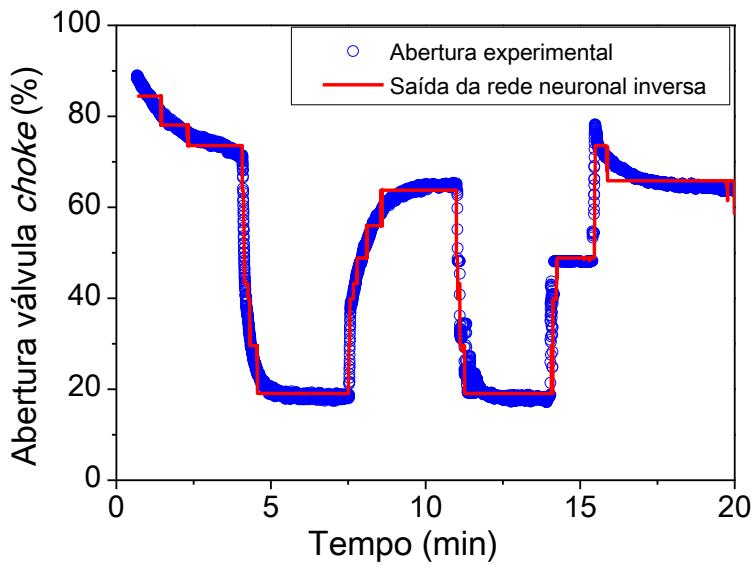


Figura 94 – Resposta do controlador neuronal inverso.

Para avaliar o comportamento do controlador empregou-se um teste engloando todas as perturbações inerentes ao processo de perfuração de poços de petróleo. Desta forma, foram empregados em um único teste distúrbios de vazão (procedimento de conexão de tubos), *kick* de gás e perda de circulação. O procedimento de realização deste tipo de teste é análogo ao controle pelo método indireto, entretanto, o treinamento é realizado em malha fechada pelo emprego do controlador clássico PI. Os pontos 1 – 4 na Figura 93 indicam a resposta da pressão anular de fundo frente as perturbações realizadas no sistema a fim de gerar dados de aprendizagem para a rede. Após o treinamento ter sido bem estabelecido e a rede neuronal ter apresentado boa resposta, a condição operacional inicial é restabelecida (ponto 5). Em seguida mantendo-se o sistema em estado estacionário iniciou - se a ação do controlador. A primeira perturbação imposta ao sistema (ponto 6) sob ação do controlador, se deu pela redução de 10 Hz na frequência da bomba (inicio do procedimento de conexão de tubos) o que acarretou uma

queda na pressão anular de fundo. Após a rejeição deste distúrbio e estabilização da pressão anular de fundo no set point desejado, implementa-se o segundo distúrbio (finalização do procedimento de conexão de tubos) no sistema (ponto 7). Mais uma vez observa-se que o controlador é eficiente em rejeitar o distúrbio de vazão controlando a pressão anular de fundo. Após a regulação da pressão, foi implementado um kick de gás (ponto 8) no sistema por meio do emprego de uma perturbação na válvula de permeabilidade a qual realiza o acoplamento anular-reservatório. A implementação do kick de gás é possível uma vez que a pressão de poros é superior a pressão anular de fundo (BHP) fazendo com que haja a migração de fluido do reservatório, neste caso gás, para o interior do poço. O controle da pressão anular de fundo durante o kick de gás foi realizado em um valor de pressão 10 psi acima do valor da pressão registrada no tanque reservatório (pressão de poros) como pode ser observado pela mudança de *set point* (linha cheia) empregada na pressão anular de fundo. Por fim, implementou-se uma redução na pressão do reservatório (pressão de poros) indicado pelo ponto 9 na Figura 93. Tal redução de pressão faz com que a pressão anular de fundo (BHP) se torne maior que a pressão de poros levando a uma perda de circulação no sistema. Para que a perda de circulação fosse então controlada, implementou-se uma redução na pressão anular de fundo (ponto 10).

A Figura 94 ilustra a saída do controlador neuronal inverso o qual estima diretamente o valor da variável manipulada (índice de abertura da válvula choke) necessária à regulação da pressão anular de fundo (BHP). Os pontos de 1 – 5 ilustram a resposta da variável manipulada para cada perturbação implementada no sistema durante a etapa de treinamento da rede neuronal. A partir do ponto 6 são apresentadas a resposta do controlador para cada uma das perturbações realizadas. Vale ressaltar que a mudança realizada na pressão de poros não interfere no índice de abertura da válvula *choke*.

Como pode ser observado, o controlador mostrou-se capaz de regular a dinâmica do processo, apresentando resposta satisfatória na estimativa da variável manipulada.

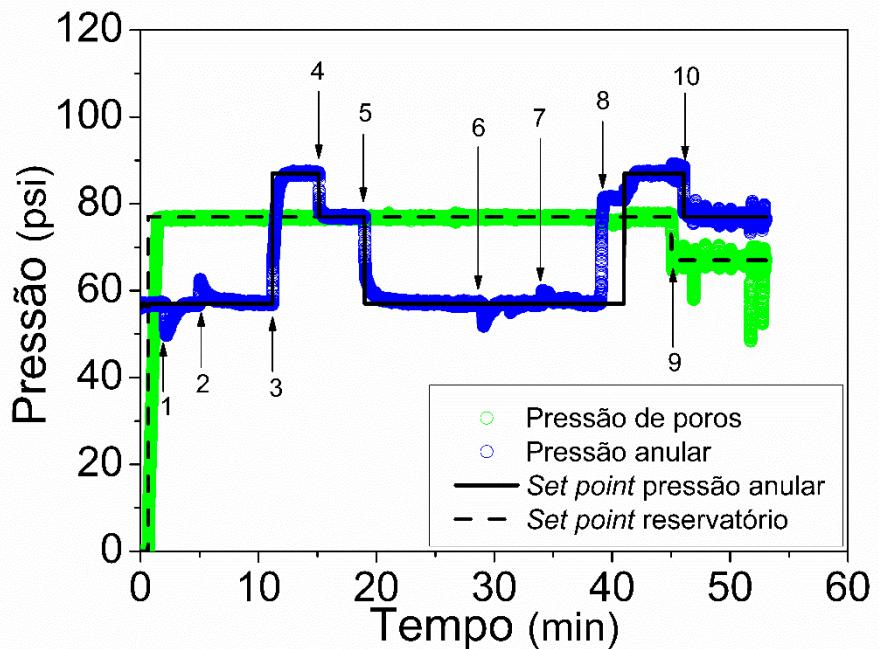


Figura 95 – Controle da pressão anular durante perfuração.

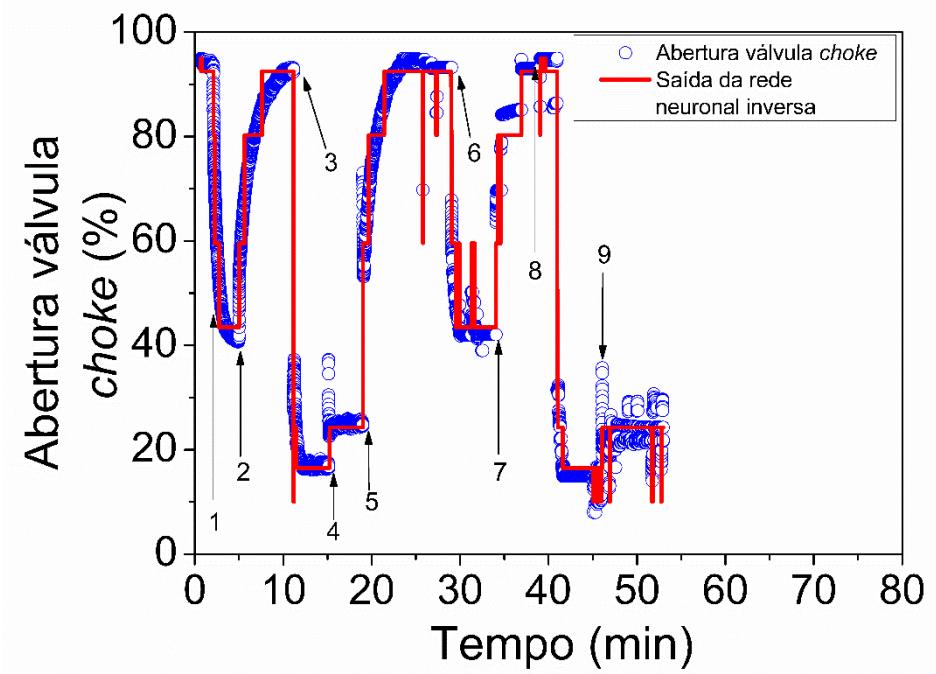


Figura 96 – Resposta do controlador neuronal inverso.

5 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

Uma unidade experimental foi construída para analisar fenômenos que ocorrem durante o processo de perfuração de poços de petróleo. A variação da pressão anular de fundo pode ser acarretada, dentre outras razões, pelo procedimento de conexão de tubos, realizado periodicamente durante o processo de perfuração; pelos fenômenos de *kick* e perda de circulação decorrentes do desequilíbrio entre as pressões no interior do poço e dos poros da formação rochosa; e pela variação da vazão de bombeio. Redes neurais foram utilizadas para modelar o processo de perfuração em tempo real e pela variação do índice de abertura da válvula *choke*. Com isso, o presente trabalho buscou sintetizar um controlador baseado em rede neuronal para regular em linha o processo de perfuração frente aos fenômenos de *kick* de gás, perda de circulação e procedimentos de conexão de tubos, tendo como variável manipulada o índice de abertura da válvula *choke*. As metodologia de modelagem e controle foram validadas em unidade experimental de perfuração de poços de petróleo.

Foram implementados testes de identificação da unidade piloto para as ocorrências de *kick* de gás, perda de circulação, variação do índice de abertura da válvula *choke* e distúrbios na frequência da bomba água. Os parâmetros do controlador PI foram calculados pelos métodos propostos por Ziegler-Nichols (1942) e Cohen-Coon (1953), tendo como base o resultado originário da identificação do sistema a partir da implementação da metodologia de Sundaresan – Krishnaswamy (1977).

A partir dos dados experimentais coletados na unidade piloto, para todas as condições avaliadas, realizou-se o treinamento, validação e teste da rede neuronal, cujo algoritmo de treinamento baseou - se na retropropagação do erro (HAYKIN, 2009; NGUYEN, 2003; FAUSETT, 1994). O algoritmo de treinamento utilizado apresentou bom desempenho fornecendo resultados satisfatórios em relação aos dados inéditos.

Ambos os controladores mostraram-se eficientes em controlar a pressão anular de fundo frente aos mais variados distúrbios ao qual o processo está sujeito.

O desempenho das redes neurais artificiais está intrinsecamente relacionado à variabilidade dos dados entrada – saída, arquitetura e aos pesos iniciais, principalmente no que tange à sua capacidade de generalização. No entanto, a definição de tais parâmetros é inerente ao problema em questão, sendo que uma rede neuronal próxima do ideal é uma rede com parâmetros específicos e escolhidos adequadamente para resolver um determinado problema (NGUYEN, 2003). Assim, propõem-se a introdução de algoritmos evolucionários (Algoritmos Genéticos etc) para a otimização dos parâmetros das redes neurais, tais como, definição da arquitetura, pesos iniciais, regra de aprendizado, funções de ativação, quantidade de camadas e neurônios ocultos entre outros, pois tal abordagem permite adaptar estes parâmetros para diferentes tarefas sem intervenção humana, fornecendo, portanto, uma abordagem de design automático para as redes neurais. Além disso, sugere – se:

- Estudar o controle da pressão anular de fundo através da manipulação da frequência da bomba de água, empregando o esquema de Jenner et al. (2004) onde a vazão não é interrompida durante o procedimento de conexão de tubos;
- Empregar a utilização de outros fluidos para representar o fluido de perfuração.
- Empregar controladores neurais no estudo no controle da pressão anular durante o processo de cimentação;
- Estudar o controle da pressão anular de fundo frente ao *kick* de líquido;
- Comparar os controladores neurais com outros controladores não lineares.

6 REFERÊNCIA BIBLIOGRAFIA

- AHMADI, M. A.; SOLEIMANI, R.; LEE, M.; KASHIWAO, T.; BAHADORI, A.; **Determination of oil well production performance using artificial neural network (ANN) linked to the particle swarm optimization (PSO) tool**, Petroleum, <http://dx.doi.org/10.1016/j.petlm.2015.06.004>, 2015.
- AHMED, M. A.; HEGAB, O. A.; SABRY, A.; **Early detection enhancement of the kick and near-balance drilling using mud logging warning sign**, Egyptian Journal of Basic and Applied Science, 3, 85-93, 2016.
- ALMEIDA, L. F.; VELLASCO, M. M. B. R.; PACHECO, M. A. C.; **Optimization system for valve control in intelligent wells under uncertainties**, Journal of Petroleum Science and Engineering, 73, 129-140, 2010.
- AKIN, S.; ROSS, C. M.; KOVSCEK A. R.; **Combination of well log and pore-scale data to predict petrophysical properties of diatomite**, Journal of Petroleum Science and Engineering, 133-149, 2008.
- ALIZADEH, M.; MOVAHED, Z.; JUNIN, R.; MOHSIN, R.; ALIZADEH, M.; ALIZADEH, M.; **A new technique to predict the fractures dip using artificial neural networks and image logs data**, Jurnal Teknologi (Science & Engineering), 75:11, 33-40, 2015.
- ARBIB, M. A.; **The handbook of brain theory and neuronal networks**, 2nd ed., Madison, Wisconsin, USA, 2002.
- ARDEKANI, O. S.; SHADIZADEH, S. R.; **Development of drilling trip time model for southern Iranian oil fields: using artificial neural networks and multiple linear regression approaches**, Journal of Petrol Explor Prod Technol, 3:287-295, 2013.
- AZADPOUR, M.; MANAMAN, N. S.; KADKHODAIE-ILKHCHI, A. SEDGHIPOUR, M.-R.; **Pore pressure prediction and modeling using well-logging data in one of the gas fields in south of Iran**, Journal of Petroleum Science and Engineering, 128, 15-23, 2015.
- BASSAM, A.; CASTILLO, A. A.; GARCÍA-VALLADARES, O.; SANTOYO, E.; **Determination of pressure drops in flowing geothermal wells by using artificial neural networks and wellbore simulation tools**, Applied Thermal Engineering, 75, 1217-1228, 2015.
- BOURGOYNE, A. T.; MILLHEIM, K. K.; CHENEVERT, M. E.; YOUNG, F. S.; **Applied Drilling Engineering**, Society of Petroleum Engineers, Richardson -TX 1986.
- BJORKEVOLL, K. S.; ANFINSEN, B.-T.; MERLO, A.; ERIKSEN, N.-H.; OLSEN, E.; **Analysis of extended reach drilling data using an advanced pressure and temperature model**, SPE 62728, 2000.
- BJORKEVOLL, K. S.; ROMMETVEIT, R.; AAS, I. B.; GJERALDSTVEIT, H.; MERLO, A.; **Transient gel breaking model for critical wells applications with field data verification**, SPE /IADC 79843, 2003.

BREYHOLTZ, O.; NYGAARD G.; NIKOLAOU, M.; **Advanced automatic control or dual gradient drilling**, in SPE Annual Technical Conference and Exhibition, SPE 124631, New Orleans, Louisiana, USA, 2009.

CARVALHO, M. A. D.; **Estudos experimentais, de simulação e de controle na perfuração de poços de petróleo utilizando a técnica pressurized mud cap drilling**, Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Química/ UFRRJ, Seropédica, 2018.

CARVALHO, M. A. D.; OLIVEIRA, G. F. M.; FERNANDES, L. D.; MARTINS, A. L.; VEJA, M. P.; **Two-phase flow model validation during conventional/Pressurized Mud Cap Drilling (PMCD) scenarios**, Journal of Petroleum Science and Engineering, 2018.

COHEN, G.H.; COON, G.A., **Theoretical considerations of retarded control**, Transactions of the ASME, p. 827-834, 1953.

CUNHA, J. C.; ROSA, F. S. N.; LAGE, A. C. V. M.; NEGRÃO, A. F.; **Planejamento e execução de poços de petróleo no Brasil utilizando-se perfuração sub-balanceada**, XV Congresso Brasileiro de Engenharia Mecânica, São Paulo, 1999.

ESIM, E.; YILDIRIM, S.; **Drilling performance analysis of drill column machine using proposed neural networks**, Neural Comput & Applic, 2016.

FATTAHI, H.; BAZDAR, H.; **Applying improved artificial neuronal network models to evaluate drilling rate index**, Tunnelling and Underground Space Technology 70 114–124, 2017.

FAUSETT, L. V.; **Fundamentals of Neuronal Networks: Architectures, Algorithms and Applications**, 1^a ed., Prentice – Hall, 1994.

FREITAS, M. G.; **Controle da pressão anular de fundo durante a perfuração de poços de petróleo**, Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Química/ UFRRJ, Seropédica, 2013.

GANDELMAN, R. A.; TEIXEIRA, G. T.; WALDMANN, A. T. A.; MARI, A.; REZENDE, M. S.; ARAGÃO, A. F. L.; MARTINS, A. L.; **Development of a computational tool to avoid and remediate drilling problems by real time PWD data interpretation**, International Congress of Mechanical Engineering, 2009.

GAO, F.; WANG, F.; LI, M.; **Neuronal network-based optimal iterative controller for nonlinear processes**, The Canadian Journal of Chemical Engineering, v.78, 2000.

GHOBADPOURI, S.; HAJIDAVALLOO, E.; NOGHREHABADI, A. R.; **Modeling and simulation of gas-liquid-solid three-phase flow in under-balanced drilling operation**, Journal of Petroleum Science and Engineering, 156, 348-355, 2017.

GODHAVN, J. M.; **Control requirements for automatic managed pressure drilling system**, SPE, Statoil ASA, 2010.

GODHAVN, J. M.; **Control requirements for high-end automatic MPD operations**, in: SPE/IADC Drilling Conference and Exhibition, SPE 119442, Amsterdam, Netherlands, 2009.

- GRACE, R. D.; **Advanced blowout and well control**, Gulf Publishing Company, 1994.
- GREIN, E. A.; DANNENHAUER, C. E.; CRUZ, M. S.; SILVA, F. R. G.; MARTINS, A. L.; VANNI, G. S.; RIBEIRO, V. J. S.; VEGA, M. P.; **Evolution of Control Strategies to Minimize Pressure Fluctuation During Connections in MPD Deepwater Operations**, OTC 27990 MS, Rio de Janeiro, 2017.
- HANSEN, S. A.; ROMMETVEIT, R.; STERRY, N.; AAS, B.; MERLO, A.; **A new hydraulics model slim hole drilling applications**, SPE/IADC 575579, 1999.
- HAYAJNEH, M.; HASSAN, A. M.; MAYYAS, A. T.; **Artificial neural network modeling of the drilling process of self-lubricated aluminum/alumina/graphite hybrid composites synthesized by powder metallurgy technique**, Journal of Alloys and Compounds, 478, 559-565, 2009.
- HAYKIN, S.; **Neuronal networks and learning machines**, 3^a ed., Prentice – Hall, 2009.
- HIMMELBLAU, D. M.; **Applications of artificial neural networks in chemical engineering**, Korean J. Chem. Eng., 17(4), 373-392, 2000.
- HUNT, K. J.; SBARBARO, D.; ZBIKOWSKI, R.; GAWTHROP, P. J.; **Neural networks for control system – a survey**, Automatica, 28, 6, 1083-1112, 1992.
- INGHAM, J; DUNN, I. J.; HEINZLE, E.; PRENOSIL, J. E.; SNAPE, J. B.; **Chemical Engineering Dynamics: An Introduction to Modelling and Computer Simulation**, 3. Edition, Wiley-VCH Verlag GmbH & Co. KGaA, Weinheim, 2007.
- IRAWAN, S.; FAHMI, R. M.; FATHADDIN, M. T.; **Application of neuronal network for predictive control in bit properties selection**, International Journal of Petroleum Science and Technology, v. 3, n° 1, pp. 101 – 112, 2009.
- JENNER, J.W., ELKINS, H.L., SPRINGETT, F., LURIE, P.G., WELLINGS, J.S., **The continuous circulations systems: an advance in constante pressure drilling**, in SPE anual technical Conferencia and Exhibition, no. SPE 90702, Houston, TX, USA, 2004.
- KAASA, G.; STAMNES, O. N.; IMSLAND, L.; AAMO, O. M.; **Intelligent estimation of downhole pressure using a simple hydraulic model**, IADC/SPE 143097, 2011.
- KHEZRIAN, M.; HAJIDAVALOO, E.; SHEKARI, Y.; **Modeling and simulationof underbalanced drilling operation using two-fluid model of two-phase flow**, Chemical Engineering Research and Design, 93, 30-37, 2015.
- KHORIAKOV, V.; JOHANSEN, A. C.; JOHANSEN, T. E.; **Transient flow modeling of advanced wells**, Journal of Petroleum Science and Engineering, 86-87, 99 – 110, 2012.
- LAGE, A. C. V. M.; FJELDE, K. K.; TIME, R. W.; **Underbalanced drilling dynamics: two-phase flow modeling and experiments**, SPE Journal, 8, pp. 61-70, SPE 83607, 2003.
- LAGE, A. C. V. M.; TIME, R. W.; **Mechanistic model for upward two-phase flow in annuli**, SPE 63127, 2000.

LEITH, D. J.; LEITHEAD, W. E.; **Survey of gain-scheduling analysis and design**, International Journal of Control, v. 73, n. 11, p. 1001-1025, DOI: 10.1080/002071700411304, 2010.

LI, X.; FENG, Y.; EL MOHTAR, C. S.; GRAY, K. E.; **Transient modeling of borehole breakouts: A coupled thermo-hydro-mechanical approach**, Journal of Petroleum Science and Engineering, 2018.

LYONS, W. C.; **Standard handbook of petroleum & natural gas engineering**, v. 1, Gulf Publishing Company, 1996.

MAROOKA, C. K.; GUILHERME, I. R.; MENDES, J. R. P.; **Development of intelligent systems for well drilling and petroleum production**, Journal of Petroleum Science and Engineering, 32, 191-199, 2001.

MARTIN, M. D.; **Managed pressure drilling techniques and tools**, A thesis, Texas A&M University, 2006.

MOHAGHEGH, S.; AREFI, R.; BILGESU, I.; AMERI, S.; ROSE, D.; **Design and development of an artificial neural network for estimation of formation permeability**, SPE 28237, 1995.

NANDAN, A., IMTIAZ, S., 2017. **Nonlinear model predictive control of managed pressure drilling**, ISA Transactions, 69, 307-314.

NARENDRA, K. S.; **Neural networks for control: theory and practice**, Proceedings of the IEEE, 84, 10, 1385-1406, 1996.

NAS, S.; GEDGE, B.; PALAO, F. BOT, N. V.; **Advantages of managed pressure drilling and the recent deployment of the technology in Vietnam**, IADC/SPE 136513, 2010.

NGUYEN, H. T.; PRASAD, N. R.; WALKER, C. L.; WALKER, E. A.; **A first course in fuzzy and neuronal control**, Chapman & Hall/CRC, 2003.

NYGAARD, G.; NAEVDAL, G.; **Nonlinear model predictive control scheme for stabilizing annulus pressure during oil well drilling**, Journal of process control, ELSEVIER, 2006.

NYGAARD, G.; **Multivariable process control in high temperature and high-pressure environment using non-intrusive multi-sensor data fusion**, Ph.D. Thesis, Norwegian University of Science and Technology, 2006.

NYGAARD, G.H.; VEFRING, E. H.; FJELDE, K. K.; NAEVDAL, G.; LORENTZEN, R. J.; MYLVAGANAM, S.; **Bottomhole pressure control during pipe connection in gas-dominant wells**, SPE 91578, 2004a.

NYGAARD, G.H.; VEFRING, E. H.; MYLVAGANAM, S.; LORENTZEN, R. J.; NAEVDAL, G.; FJELDE, K. K.; **Underbalanced drilling: improving pipe connection procedures using automatic control**, SPE 90962, 2004b.

NYGAARD, G.H., NAEVDAL, G., MYLVAGANAM, S., **Evaluating non linear Kalman filters for parameter estimation in reservoirs during petroleum well drilling**, International conference on control applications, Munich, Germany, October 4-6, 2006.

NYGAARD, G.; JOHANNESSEN, E.; GRAVDAL, J. E.; IVERSEN, F.; **Automatic coordinated control of pump rates and choke valve for compensating pressure fluctuations during surge and swab operations**, in: IADC/SPE Managed Pressure Drilling and Underbalanced Operations Conference and Exhibition, SPE 108344, Galveston, Texas, U.S.A., 2007.

OLIVEIRA, G. F. M.; VIEIRA, F. R. B.; VEGA, M. P.; COELHO, D. A. F.; RIBEIRO, V. J. S.; **Estudo de controlador com compensação de tempo morto para regular a pressão anular de fundo – VI Encontro Nacional de Hidráulica de Poços de Petróleo e Gás**, 2015.

OKPO, E. E.; DOSUNMU, A.; ODAGME, B .S.; **Artificial neural network model for predicting wellbore instability**, SPE 184371 – MS, 2016.

PATRÍCIO, R. V.; **Estudo de controle na perfuração de poços de petróleo em presença de kick de gás**, Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Química/UFRRJ, Seropédica, 2016.

PATRÍCIO, R. V.; OLIVEIRA, G. F. M.; CARVALHO, M. A. D.; FERNANDES, L. D.; MARTINS, A. L.; VEJA, M. P.; **Dynamicgas kick regulation through control reconfiguration under MPD scenario – two-phase flow validation**, Journal of Petroleum Science and Engineering, 2018.

PEDERSEN, T.; AARSNES, U. J. F.; GODHAVN, J.-M.; **Flow and pressure control of underbalanced drilling operations using NMPC**, Journal of Process Control, 68, 73-85, 2018.

PETERSEN, J.; BJORKEVOLL, K. S.; LEKVAM, K.; **Computing the danger of hydrate formation using a modified dynamic kick simulator**, SPE/IADC 67749, 2001.

PETERSEN, J.; ROMMETVEIT, R.; TARR, B.; **Kick with lost circulation simulator, a tool for design of complex well control situations**, SPE 49956, 1998.

RAMGULAM, A.; ERTEKIN, T.; FLEMINGS, P. B.; **Utilization of artificial neural network in the optimization of history matching**, SPE 107468, 2007.

ROCHA, L. A. S.; AZEVEDO, C. T.; **Projeto de poços de petróleo: Geopressões e Assentamentos de Colunas de Revestimento**, 2º ed., Interciência, Rio de Janeiro, 2009.

ROMMETVEIT, R.; VEFRING, E. H.; **Comparison of results from an advanced gas kick simulator with surface and downhole data from full scale gas kick experiments in an inclined well**, SPE 22558, 1991.

ROOKI, R.; **Application of general regression neural network (GRNN) for indirect measuring pressure loss of Herschel-Bulkley drilling fluids in oil drilling**, Measurement, 85, 184-191, 2016.

SANTOS, G.; SERRANO, M.; VILLA, L.; NIETO, E.; **It is all about pressure: drilling a high – pressure well in record time using real-time tools**, Society of Petroleum Engineers, 2010.

SEBORG, D. E.; EDGAR, T. F.; MELLICHAMP, D. A.; **Process dynamics and control**, 2º ed., John Wiley & Sons, Inc., 2003.

SHAO, H.; JIANG, L.; LIU, L.; ZHAO, Q.; **Modeling of multiphase flow through chokes**, Flow Measurement and Instrumentation, 60, 44-50, 2018.

SHAYEGI, S.; LOVORN, R.; **Comparison of reservoir knowledge, drilling benefits and economic advantages of UBD, MP**, IADC/SPE Managed Pressure Drilling and Underbalanced Operations Conference & Exhibition, Galveston-Texas, 2007.

SPESIVTSEV, P.; SINKOV, K.; SOFRONOV, I.; ZIMINA, A.; UMNOV, A.; YARULLIN, R.; VETROV, D.; **Predictive model for bottomhole pressure based on machine learning**, Journal of Petroleum Science and Engineering, 166, 825-841, 2018.

SUNDARESAN, K. R. & KRISHNASWAMY P. R.; **Estimation of time delay time constant parameters in time, frequency, and Laplace domains**, Can J. Chem. Eng., 56, pp 257, 1977.

THOMAS, J. E.; **Fundamentos de Engenharia de Petróleo**, Interciênciac, Rio de Janeiro, 2001.

TURNEY, D. E.; KALAGA, D. V.; ANSARI, M.; YAKOBOV R.; JOSHI, J. B.; **Reform of the drift-flux model of multiphase flow in pipes, wellbores, and reactors vessels**, Chemical Engineering Science, 184, 251-258, 2018.

VAZ, A.G.R.; ELSINGA, B.; van SARK, W. G. J. H. M.; BRITO, M. C.; **An artificial neuronal network to assess the impact of neighbouring photovoltaic systems in power forecasting in Utrecht, the Netherlands**, Renewable Energy, v. 85, p 631-641, 2016.

VEGA, M. P.; OLIVEIRA, G. F. M; FERNANDES, L. D.; MARTINS, A. L.; **Monitoring and control strategies to manage pressure fluctuations during oil well drilling**, Journal of Petroleum Science and Engineering, v 106, p. 337-349, 2018.

VEGA, M. P.; VIEIRA, F. B.; FERNANDES, L. D.; FREITAS, M. G.; RUSSANO, E.; MARTINS, A. J.; **Smart monitoring and decision making for regulating annulus bottom hole pressure while drilling oil wells**, Brazilian Journal of Chemical Engineering, V. 33, No. 04, pp 969-983, 2016.

VEGA, M.; FREITAS, M.; FERNANDES, L.; SCHEID, C.; MARTINS, A.; **Best real-time model development of an oil well drilling system**, Chemical Engineering Transactions, 26, 561-566 DOI:103303/CET1226094; 2012.

VEGA, M. P.; SCHEID, C. M.; CALÇADA, L. A.; MANCINI, M. C.; MARTINS, A. L.; **Nonlinear Identification and Model-Based Control of an Oil Well Drilling Process**, ESCAPE, 2008.

VEGA, M. P.; LIMA, E. L.; PINTO, J. C.; **Use of bifurcation analysis form development of nonlinear models for control applications**, Chemical Engineering Science, v. 63, nº 21, p. 5129-5140, 2008.

VIEIRA, F. R. B.; **Controle da pressão anular de fundo durante a perfuração de poços de petróleo**, Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Química/UFRRJ, Seropédica, 2009.

VIEIRA, F. R. B.; VEGA, M. P; FREITAS, M. G.; FOLSTA, M. G.; ARAÚJO, N. F; GANDELMAN, R.; **Controle da pressão de fundo durante a perfuração de poços de petróleo**, Boletim técnico da produção de petróleo, Rio de Janeiro, v. 4, p. 275-300, 2009.

WALDMANN, A., ANDRADE, A.R., MARTINS A.L., LOMBA, R.F.T., ARAGÃO, A.F.L.; **Sobre os mecanismos responsáveis por minimizar a invasão do fluido de perfuração na rocha reservatório** - Encontro Nacional de Hidráulica de Perfuração e Completação de Poços de Petróleo e Gás Pedra Azul, Domingos Martins, 2006.

YOU, J.; RAHNEMA, H.; **Numerical modeling of multiphase steam flowin wellbore**, Journal of Petroleum Science and Engineering, 164, 259-277, 2018.

ZAHEDI, J.; ROUNAGHI, M. M.; **Application of artificial neural network models and principal component analysis method in predicting stock prices on Tehran Stock Exchange**, Physica A, v. 438, p 178 – 187, 2015.

ZHANG, S.; LV, J.; YUAN, X.; YIN, S.; **BP neural network with genetic algorithm optimization for prediction of geo-stress state from wellbore pressures**, International Journal of Computational Intelligence and Applications, 15, 3, 2016.

ZHAO, Q.; ZHANG, B.; HU, H.; **Novel two-step filtering scheme for a logging-while-drilling system**, Computer Physics Communications, 180, 1566-1571, 2009.

ZIEGLER, J. G. NICHOLS, N. B. **Optimum Settings for Automatic Controllers**, Transactions of the A.S.M.E., V. 64, p. 759-768, 1942.

ZHOU, J.; NYGAARD, G.; **Automatic model-based control scheme for stabilizing pressure during dual-gradient drilling**, Journal of Process Control, 21, 1138-1147, 2011.

ZHOU, Y.; WOJTANOWICZ, A. K.; LI, X.; MIAO, Y.; CHEN, Y.; **Improved model for gas migration velocity of stagnant non-Newtonian fluids in annulus**, Journal of Petroleum Science and Engineering, 168, 190-200, 2018.

ANEXOS

- A – Gráficos de treinamento experimental da rede neuronal utilizando como variável anipulada a vazão da bomba de água (bomba principal), acionada via inversor de frequência.
- B - Gráficos de treinamento experimental da rede neuronal para situação de kick de gás.
- C – Gráficos de treinamento experimental da rede neuronal para situação de perda de circulação.
- D – Gráficos de treinamento experimental da rede neuronal utilizando como variável manipulada o índice de abertura da válvula *choke*.
- E – Parâmetros calculados por Sundaresan-Krishnaswamy.
- F – Parâmetros calculados pelos métodos de Ziegler-Nichols e Cohen-Coon.
- G – Gráficos de controle via rede neuronal – método indireto.
- H – Gráficos de controle via rede neuronal inversa – método direto.

Anexo A - Gráficos de treinamento experimental da rede neuronal utilizando como variável manipulada a vazão da bomba de água.

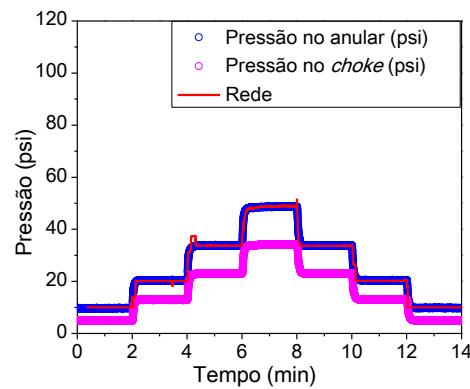


Figura 97 - Três dados passados de pressão, índice de abertura da válvula *choke* em 95% e sete neurônios na camada oculta.

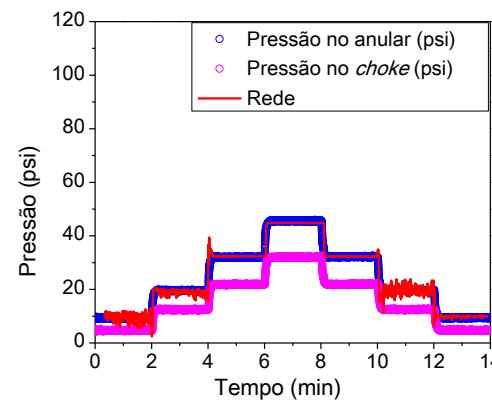


Figura 98 - Três dados passados de pressão, índice de abertura da válvula choke em 95% e nove neurônios na camada oculta.

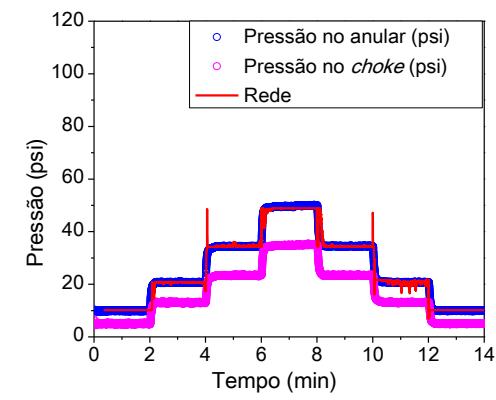


Figura 99 - Sete dados passados de pressão, índice de abertura da válvula choke em 95% e cinco neurônios na camada oculta.

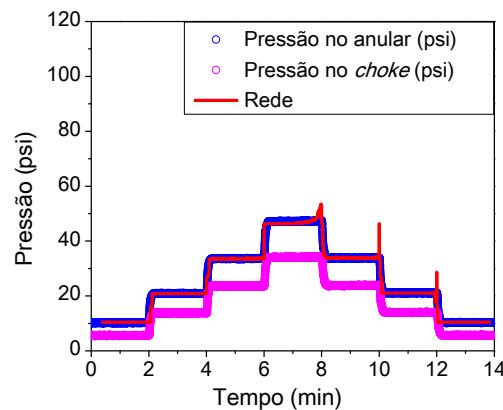


Figura 100 - Três dados passados de pressão, índice de abertura da válvula choke em 55% e nove neurônios na camada oculta.

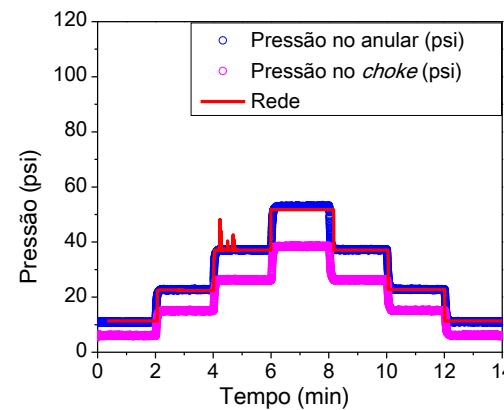


Figura 101 - Cinco dados passados de pressão, índice de abertura da válvula choke em 55% e sete neurônios na camada oculta.

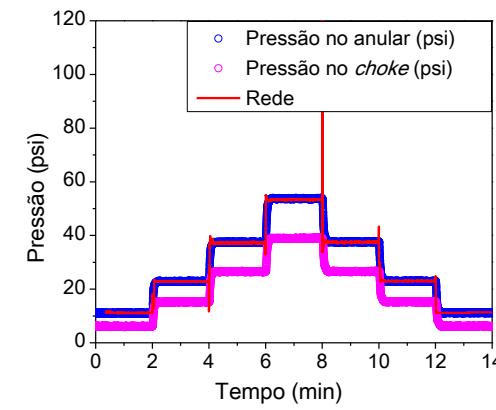


Figura 102 - Cinco dados passados de pressão, índice de abertura da válvula choke em 55% e nove neurônios na camada oculta.

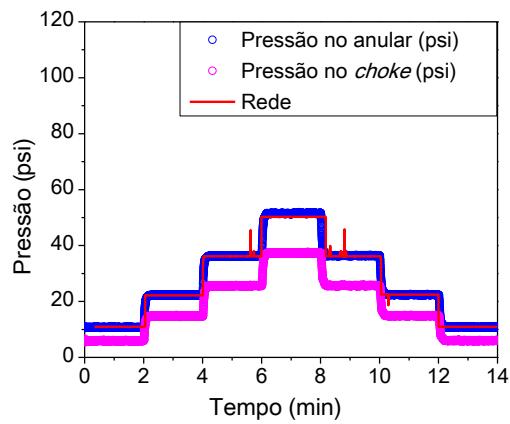


Figura 103 - Treinamento com sete dados passados de pressão, índice de abertura da válvula choke em 55% e e nove neurônios na camada

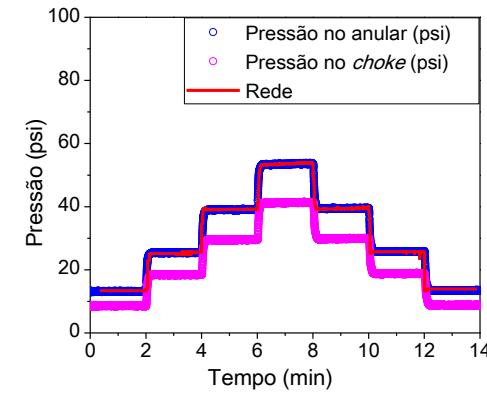


Figura 104 - Treinamento com três dados passados de pressão, índice de abertura da válvula choke em 25% e e nove neurônios na camada

Anexo B - Gráficos de treinamento experimental da rede neuronal para situação de *kick* de gás.

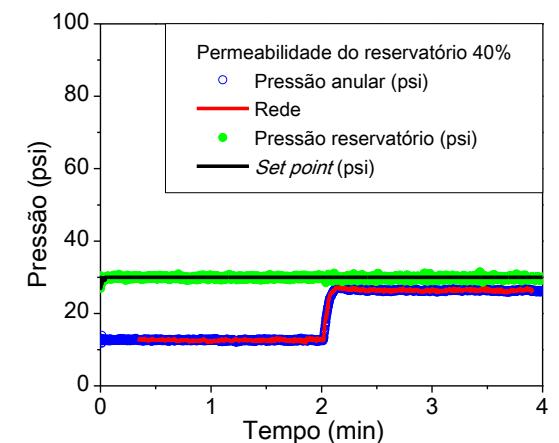
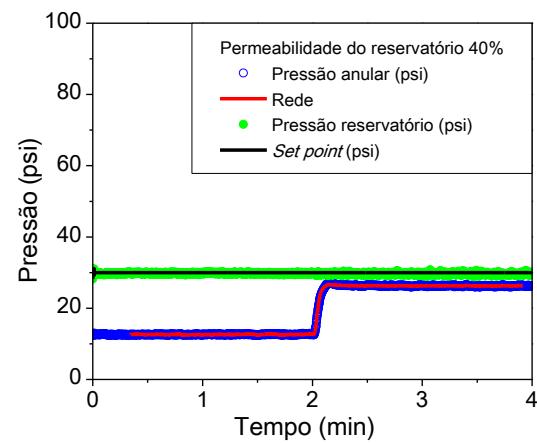
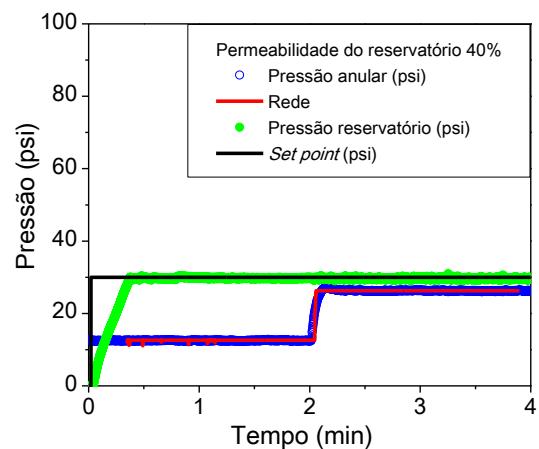


Figura 105 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

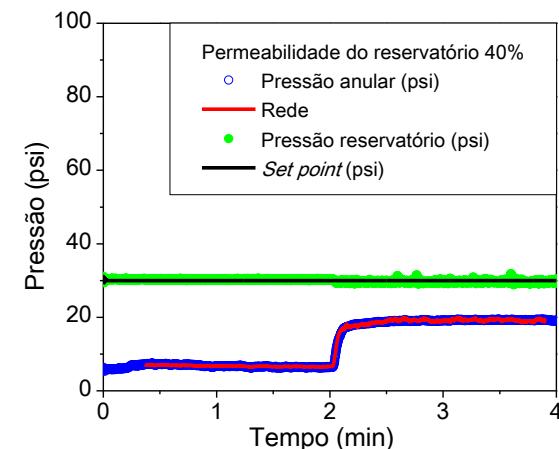
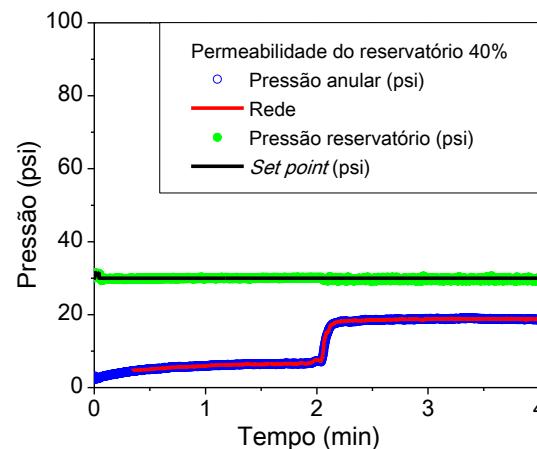
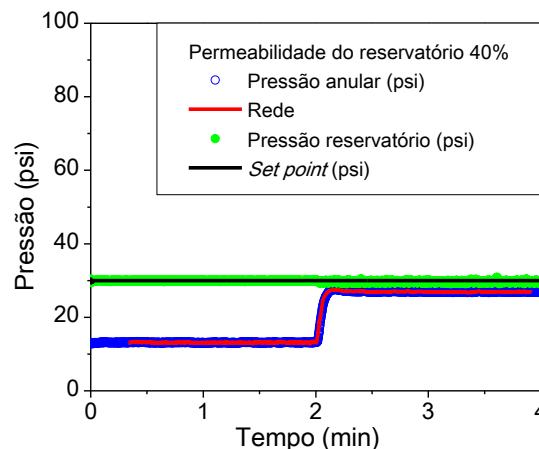


Figura 106 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

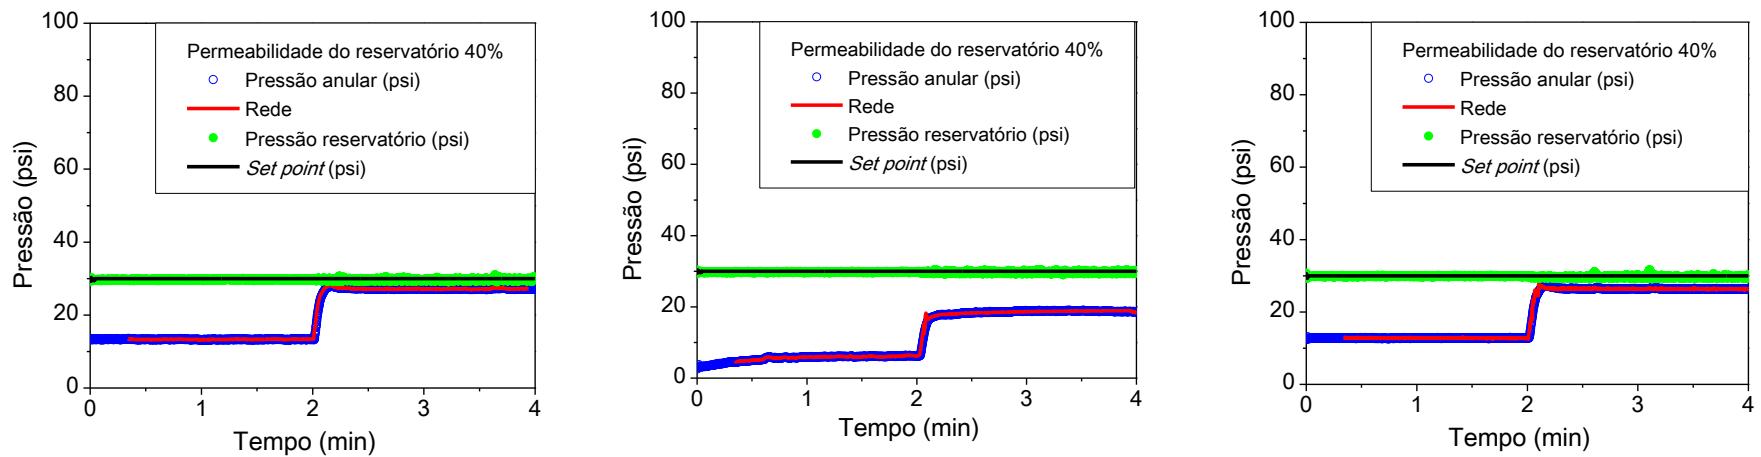


Figura 107 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

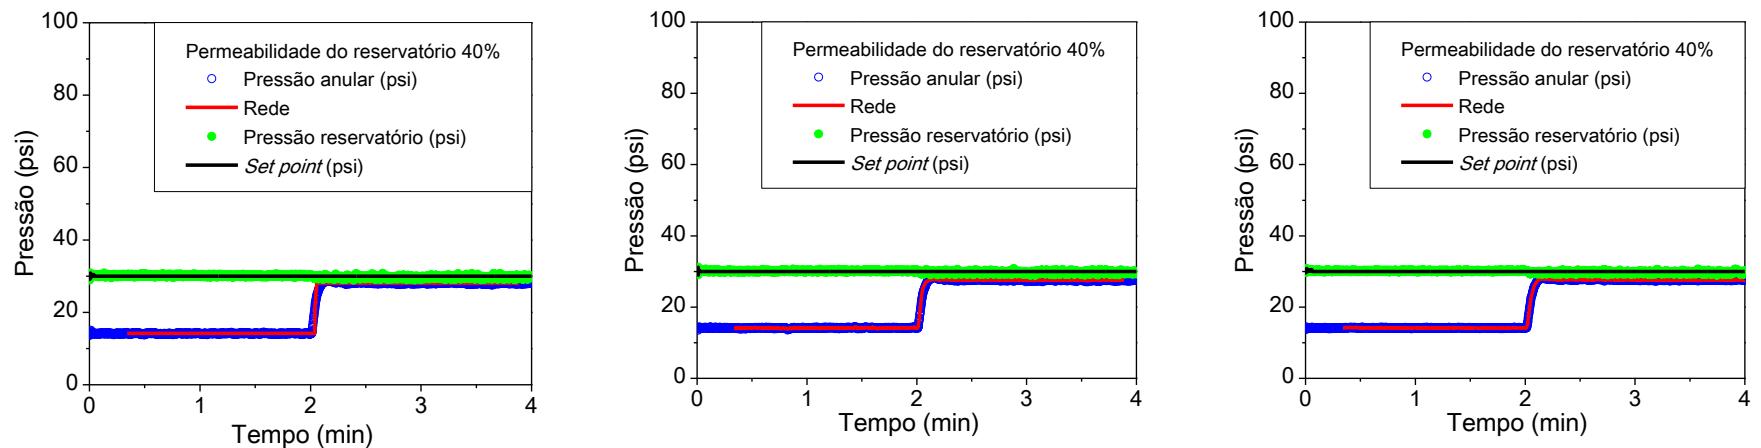


Figura 108 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

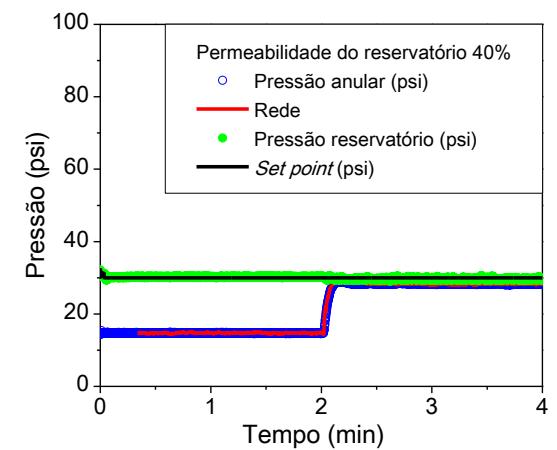
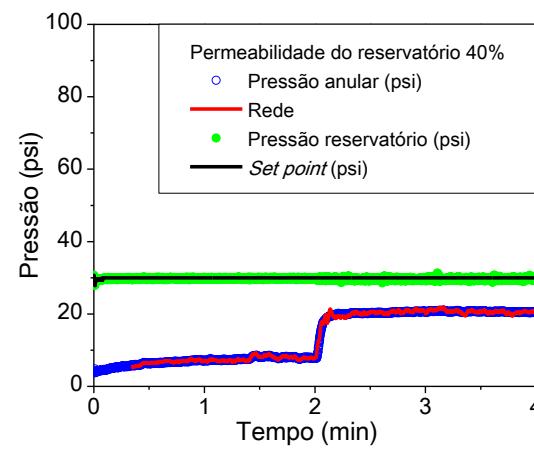
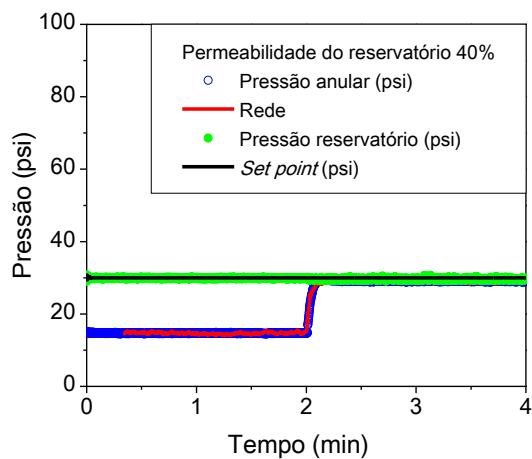


Figura 109 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

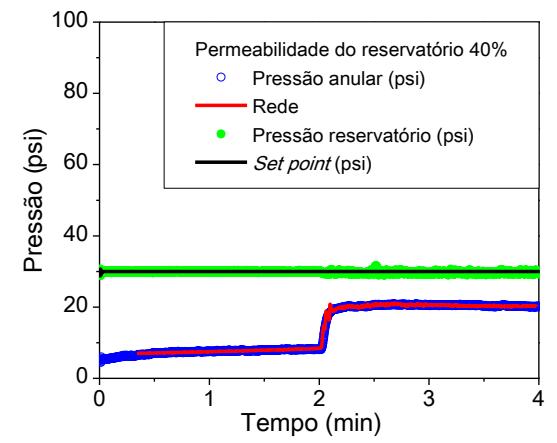
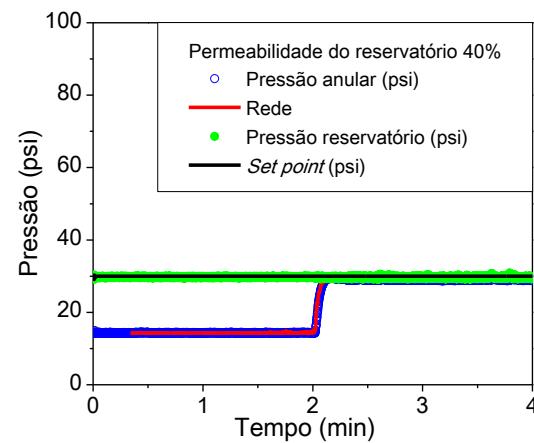
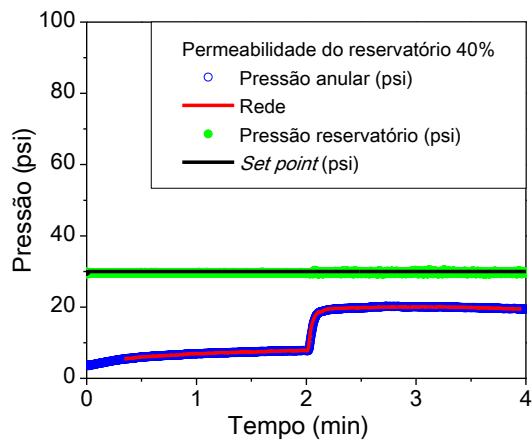


Figura 110 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

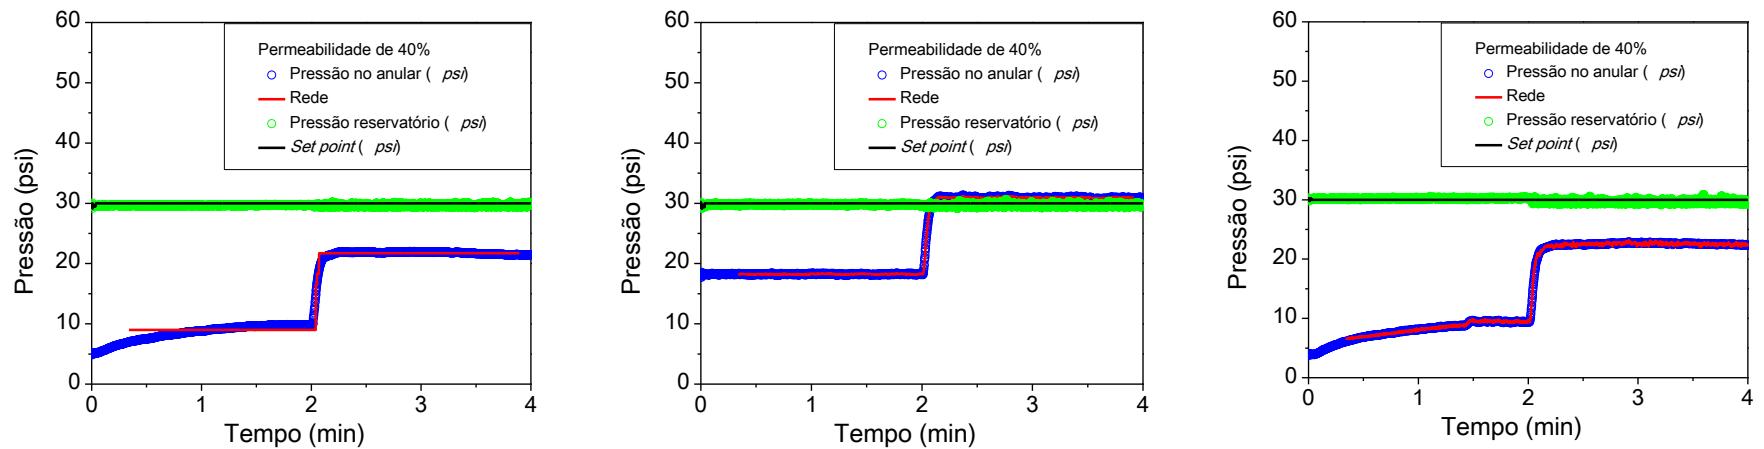


Figura 111 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

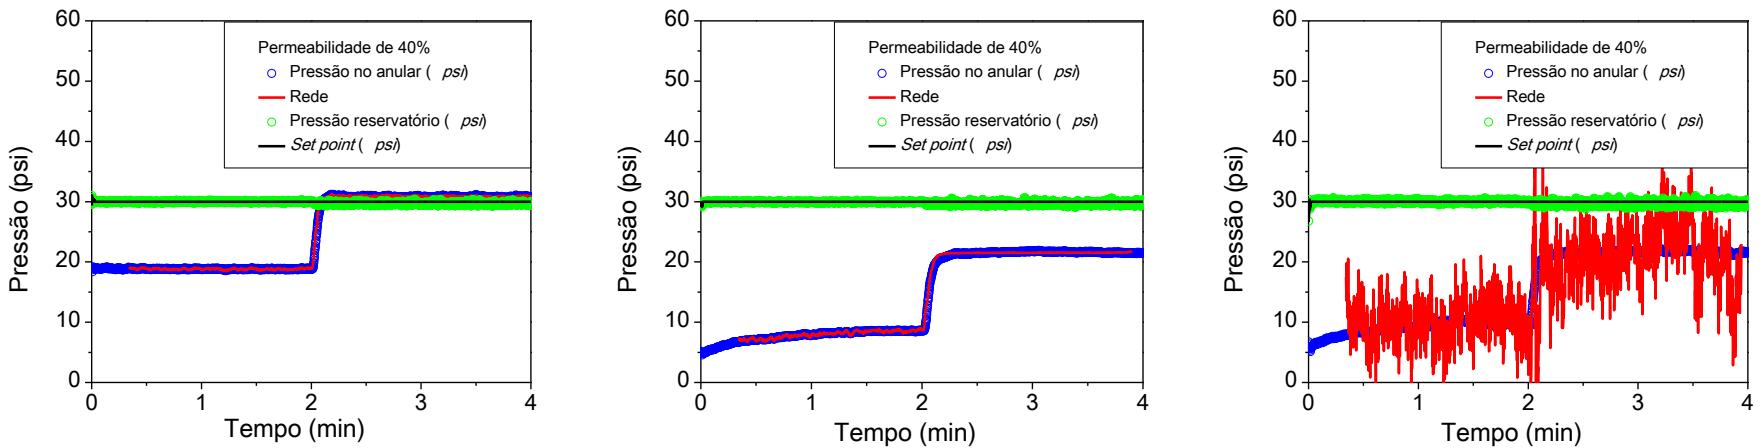


Figura 112 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

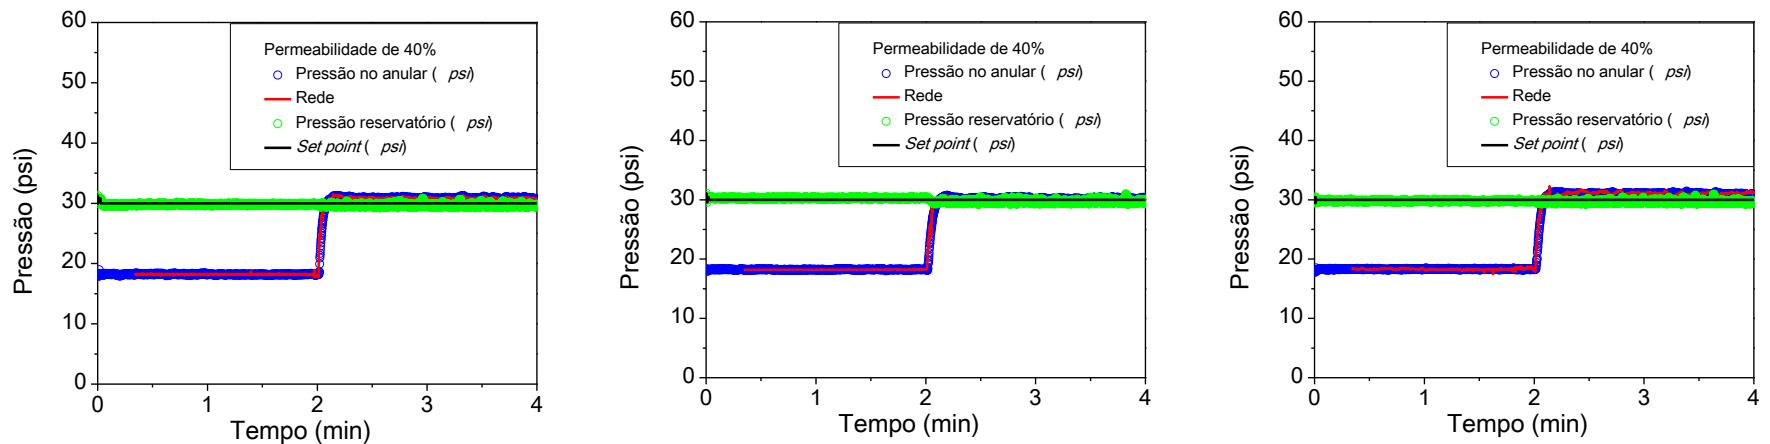


Figura 113 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

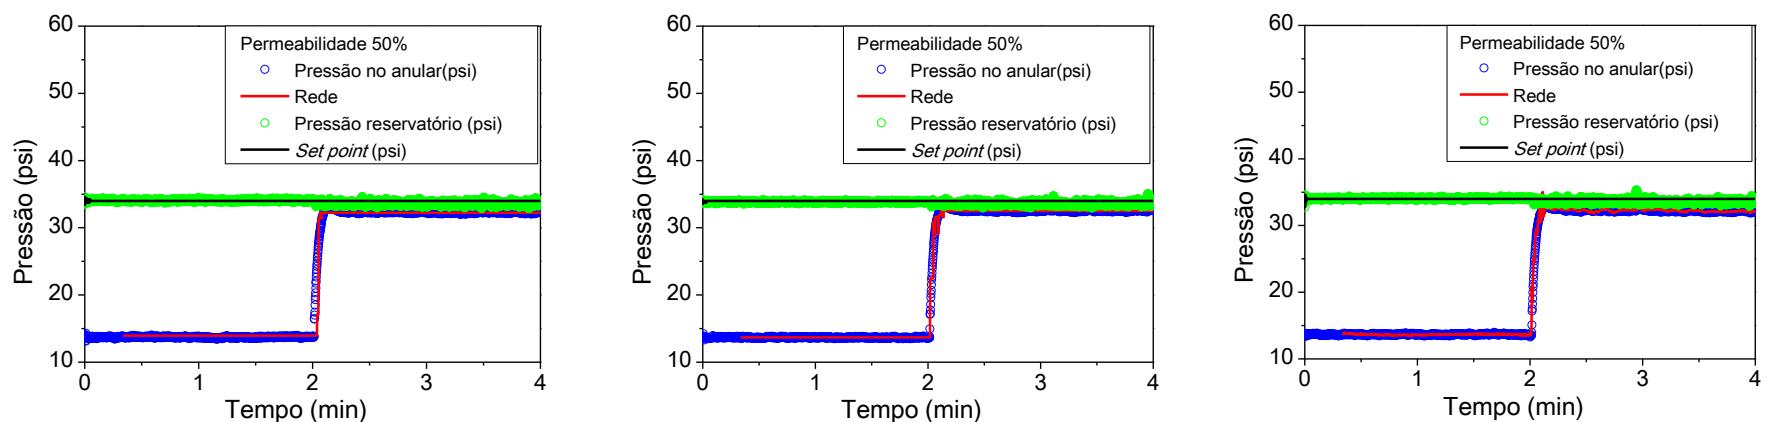


Figura 114 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

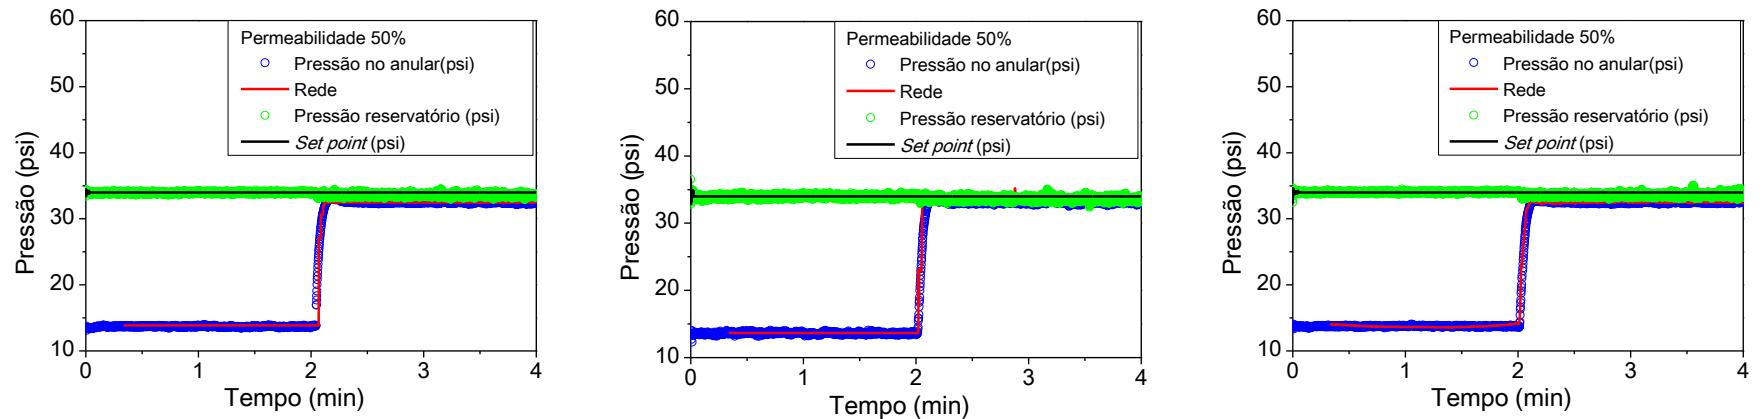


Figura 115 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

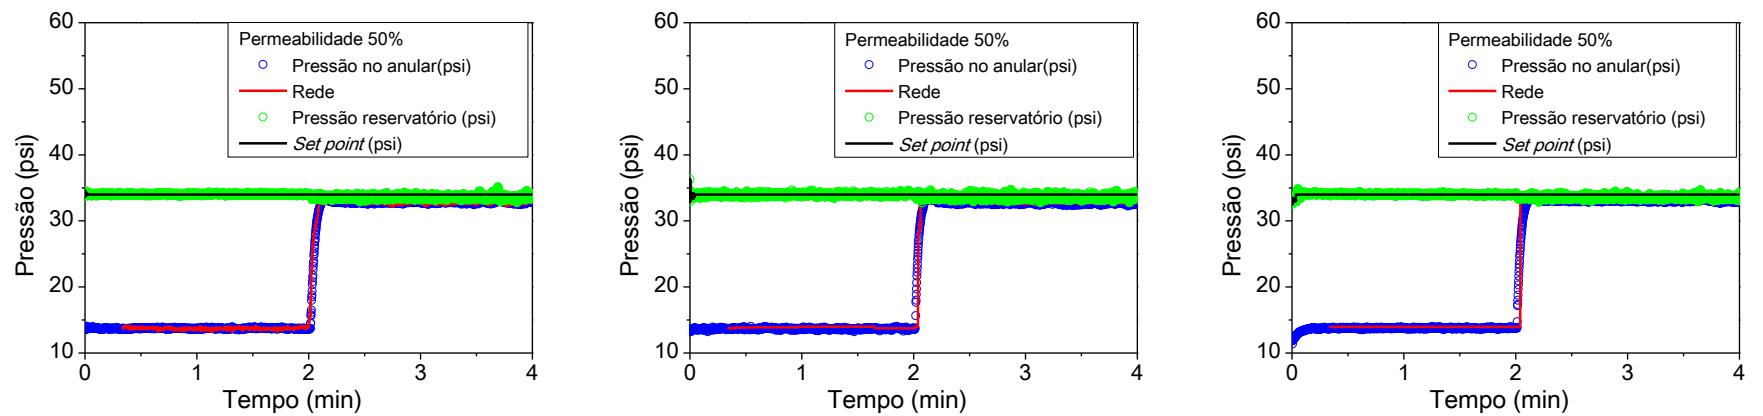


Figura 116 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

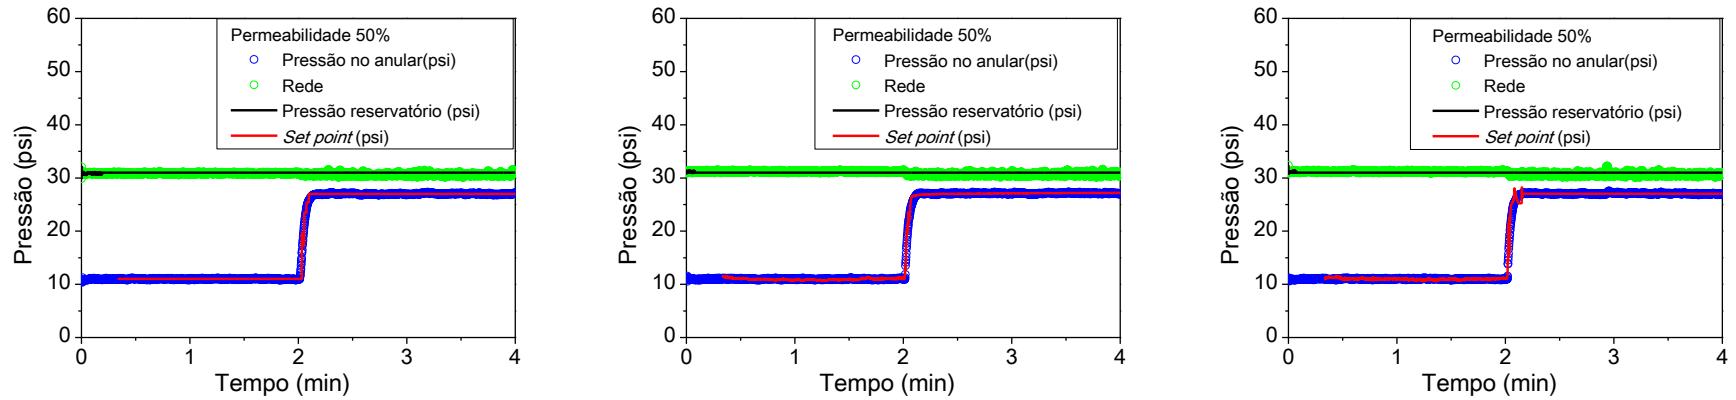


Figura 117 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

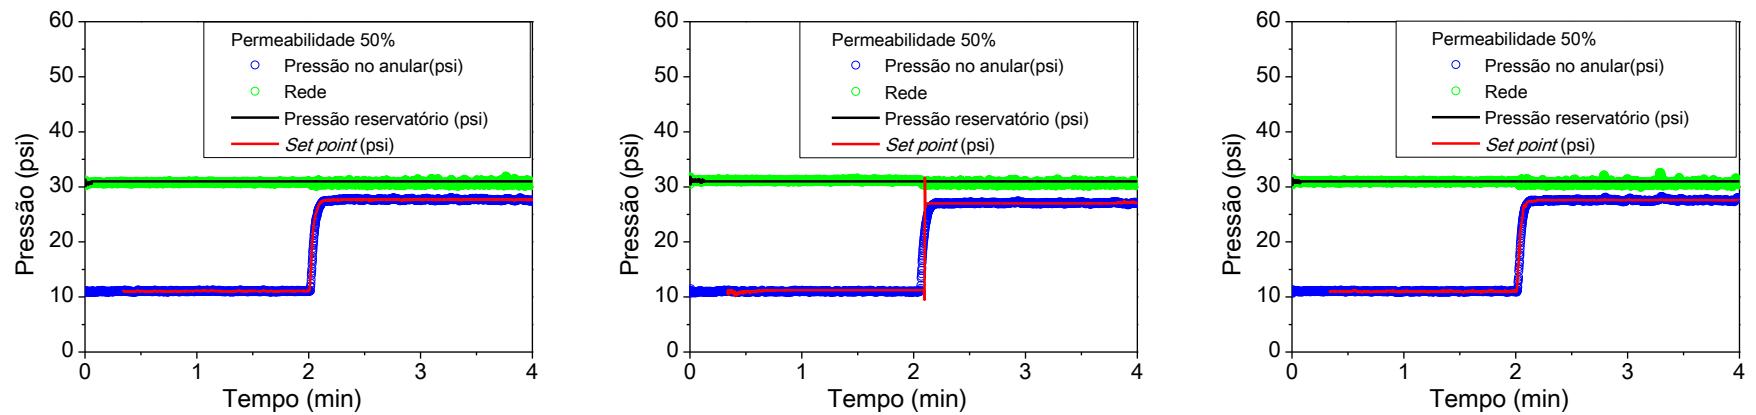


Figura 118 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

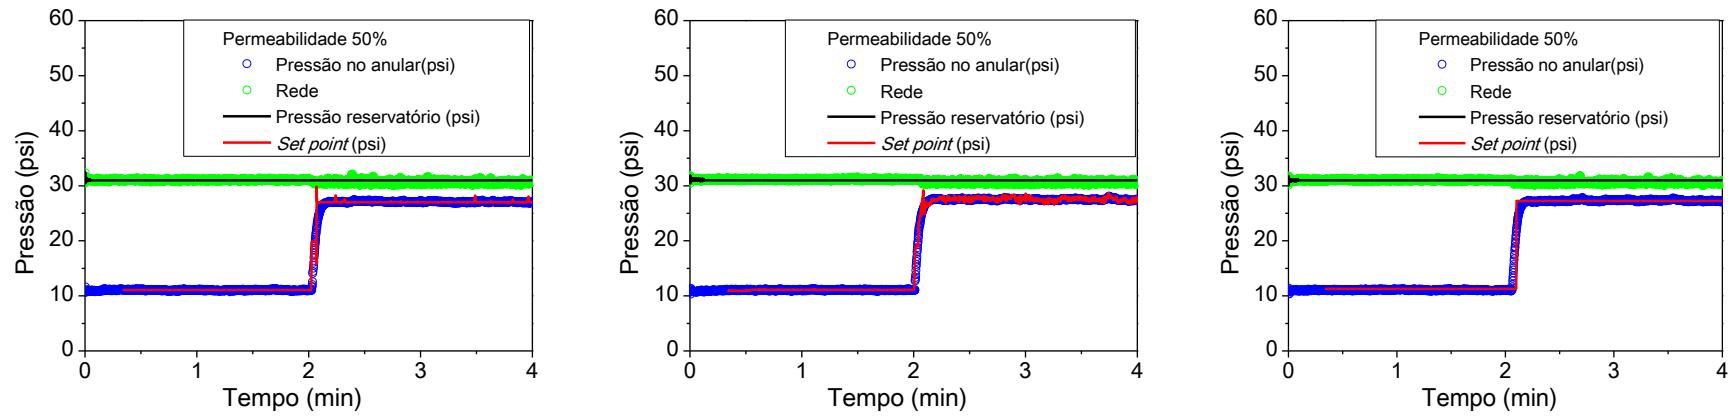


Figura 119 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

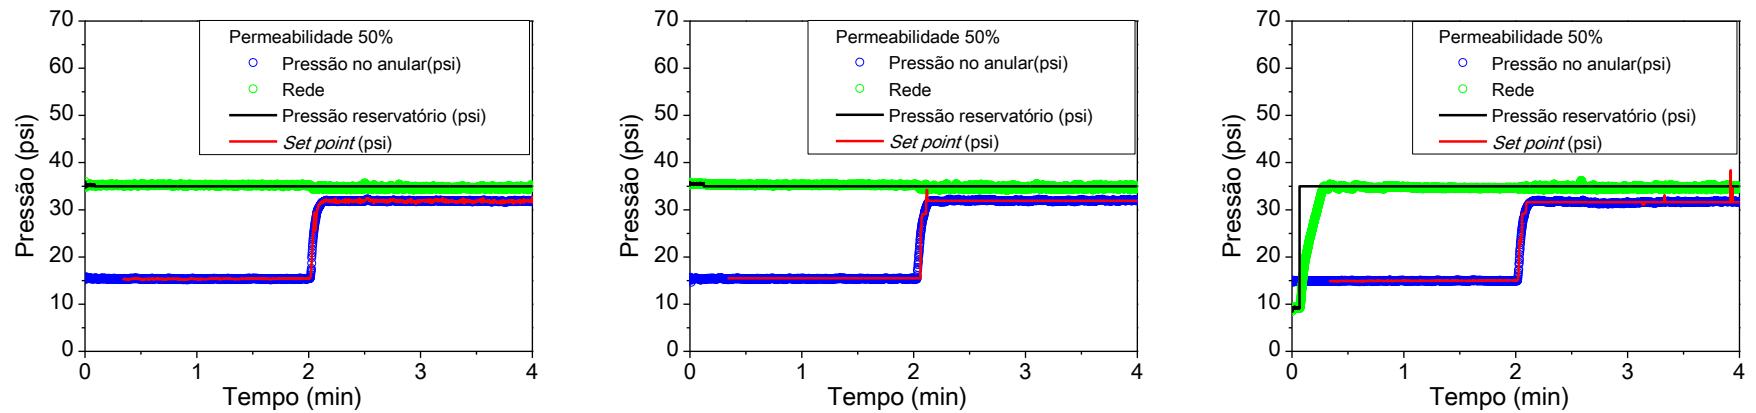


Figura 120 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

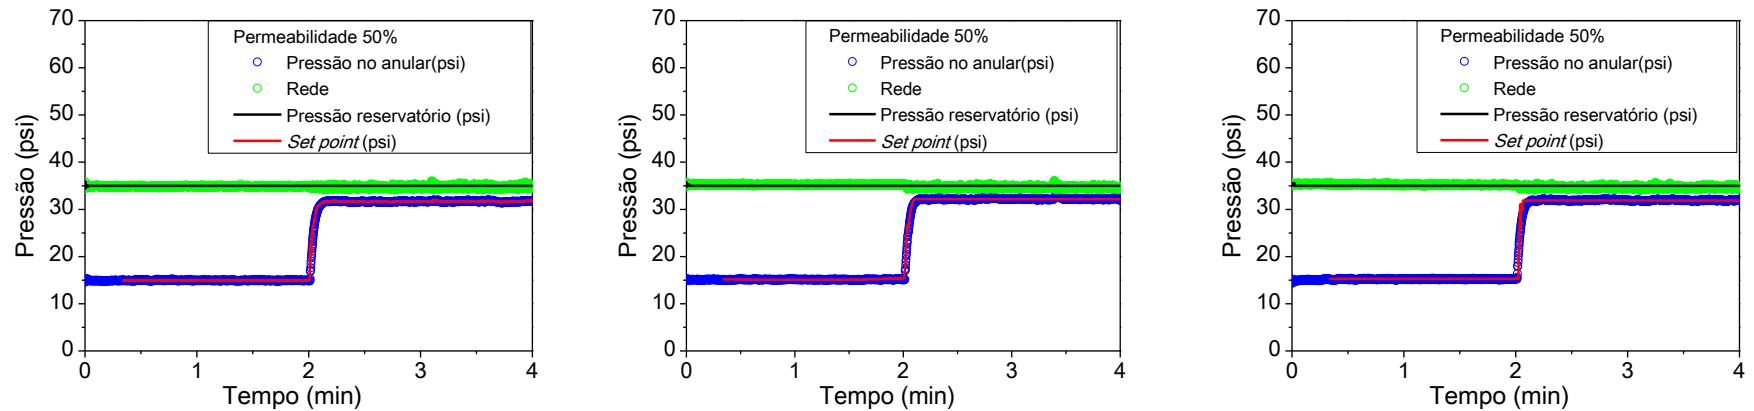


Figura 121 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

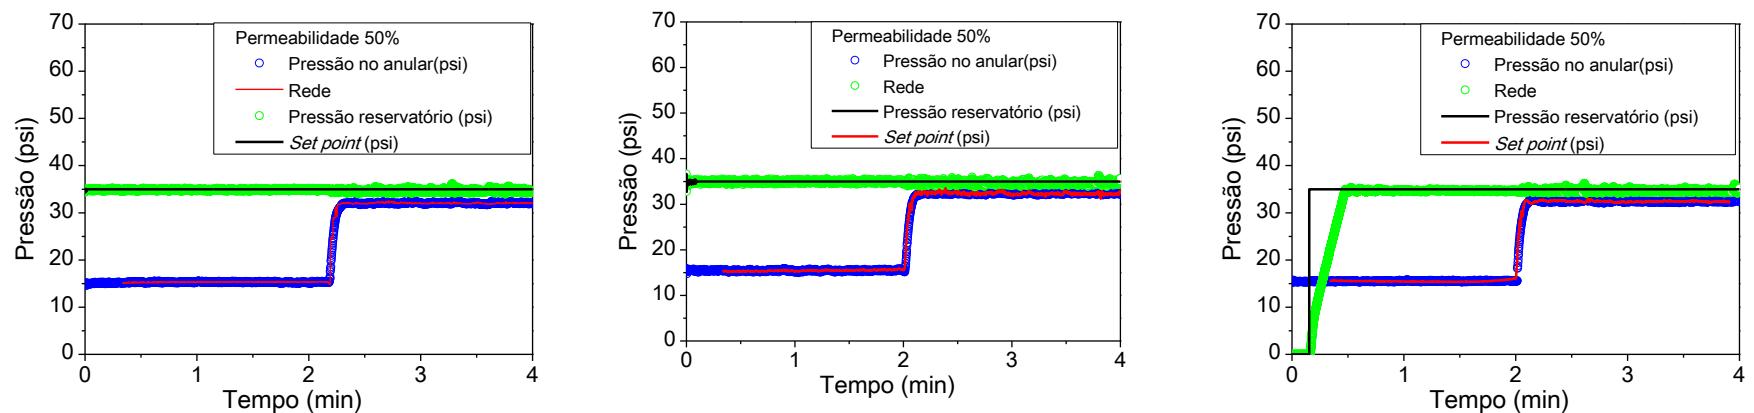


Figura 122 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

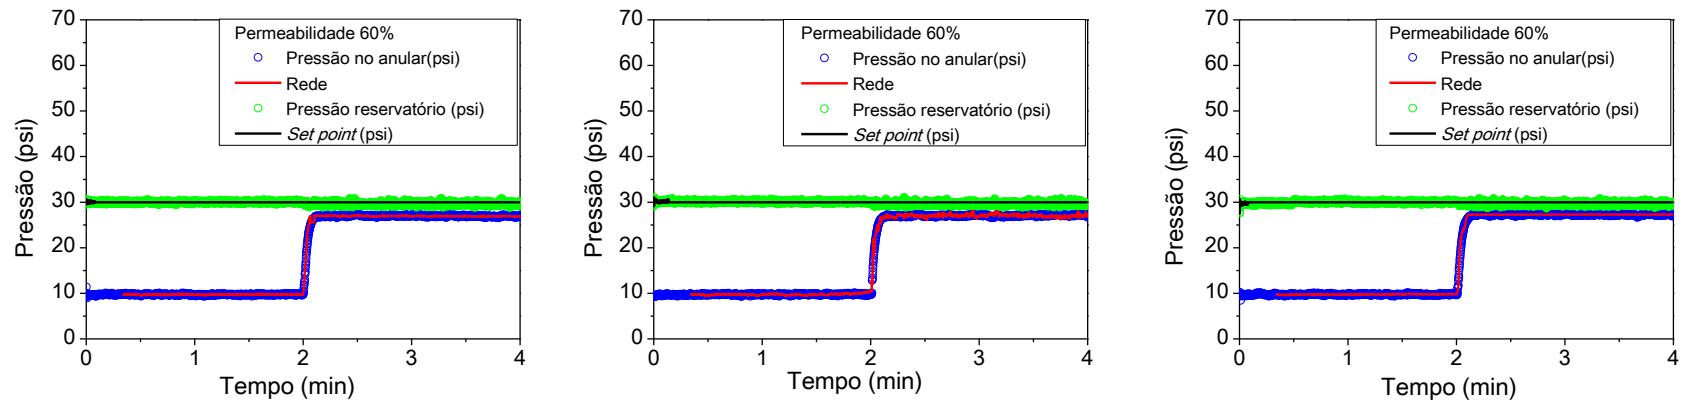


Figura 123 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

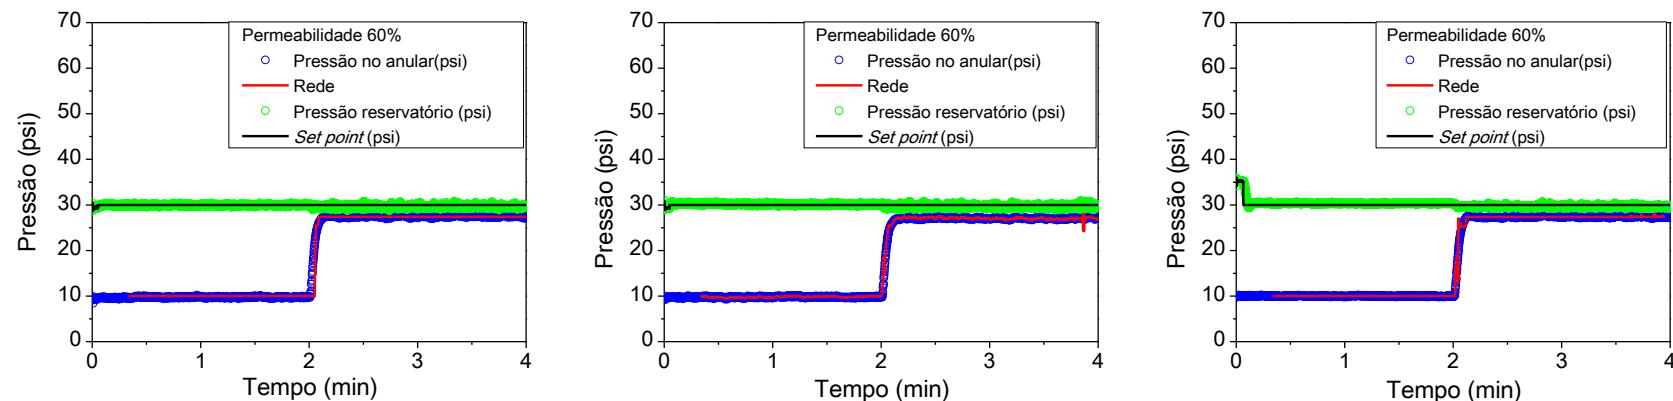


Figura 124 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

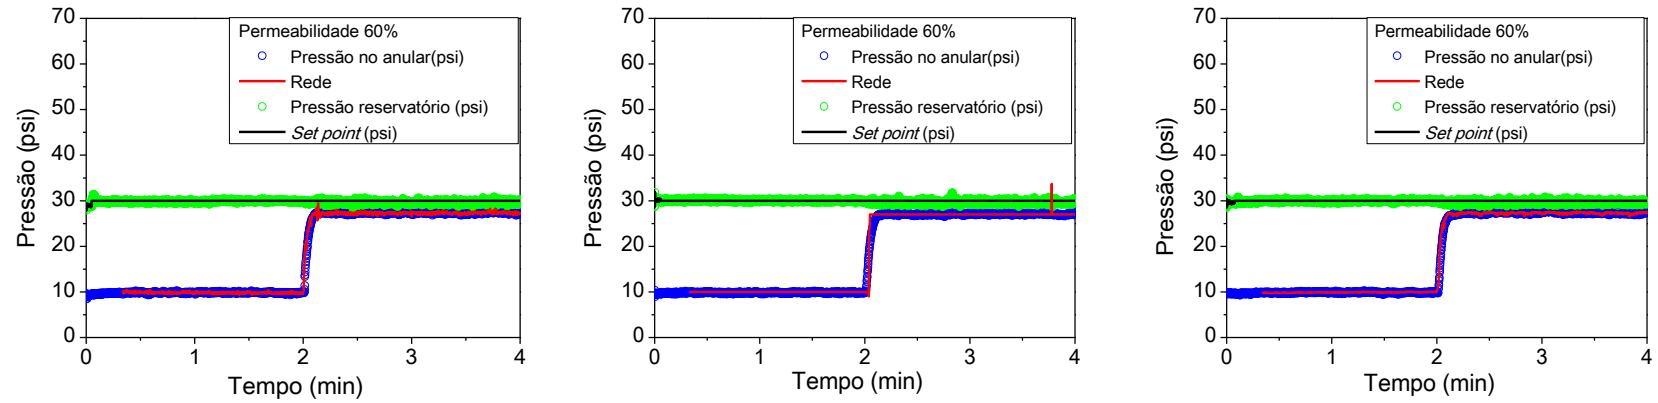


Figura 125 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

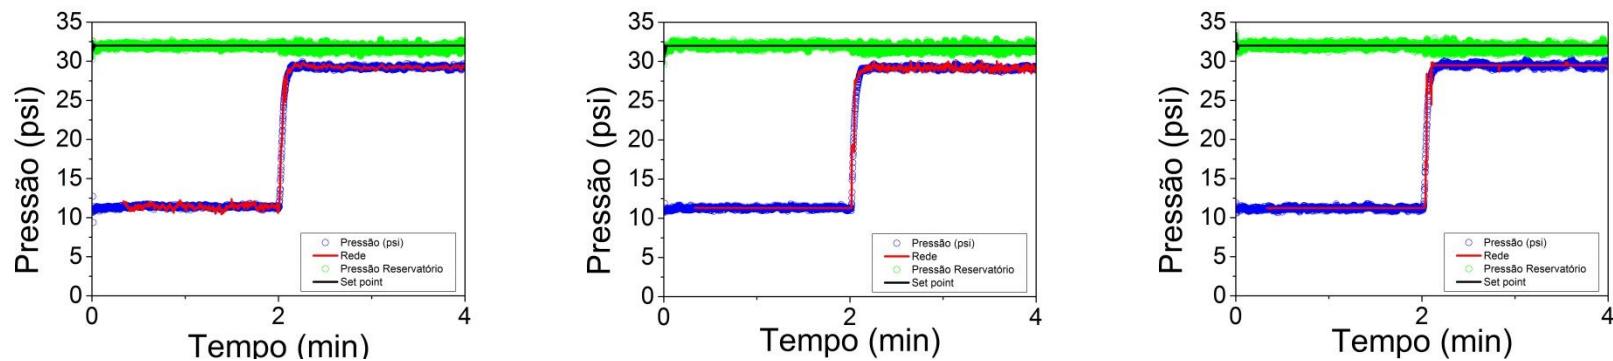


Figura 126 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

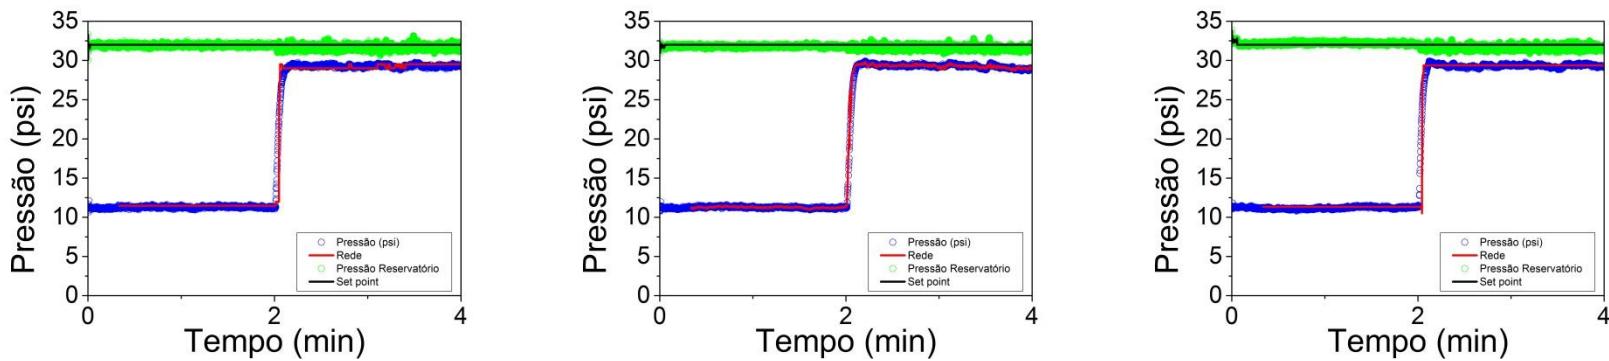


Figura 127 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

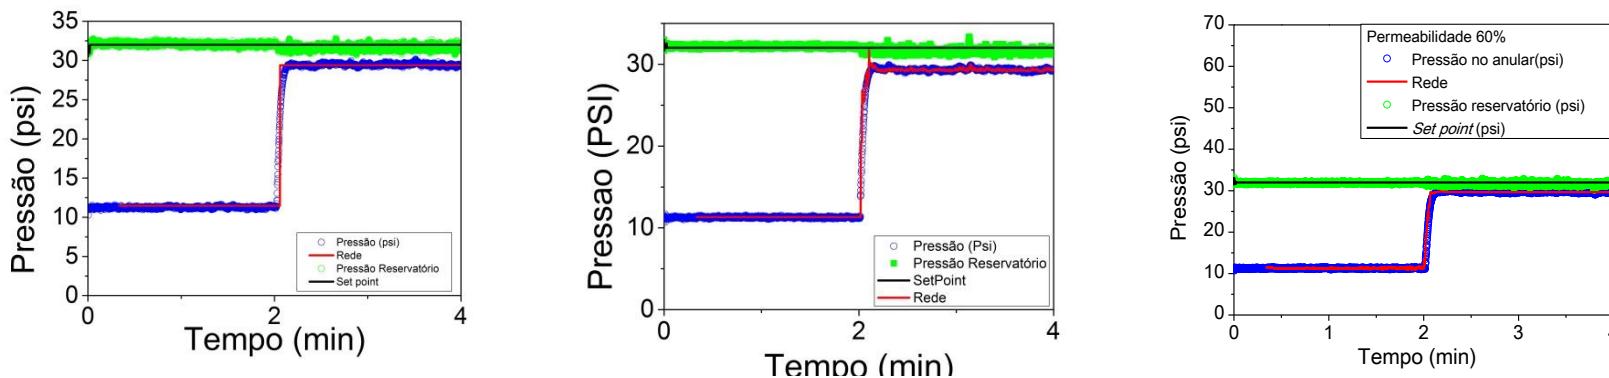


Figura 128 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

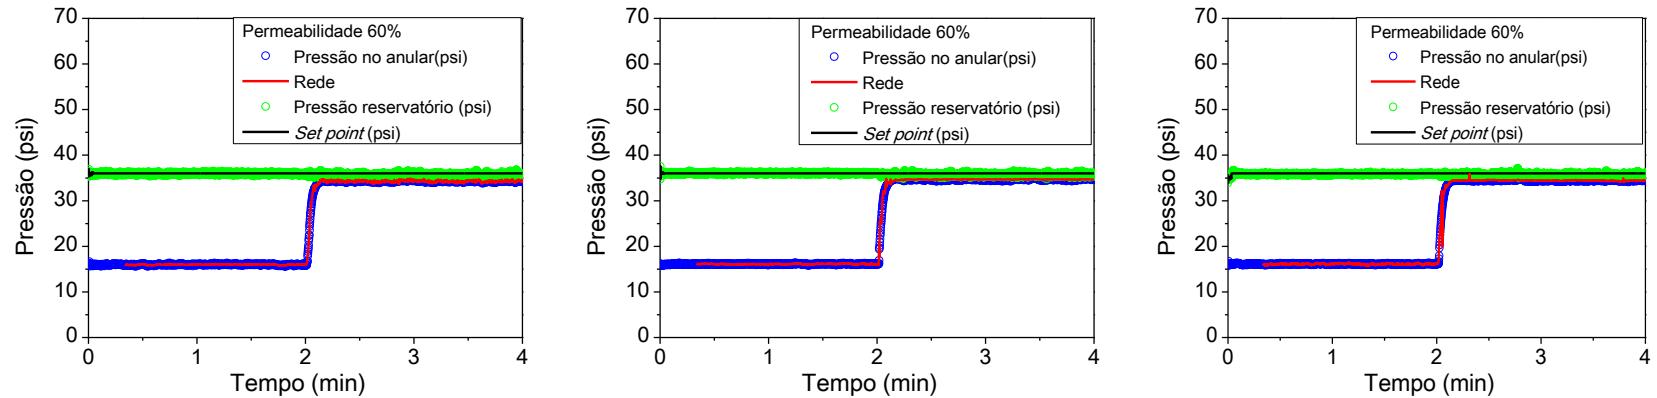


Figura 129 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

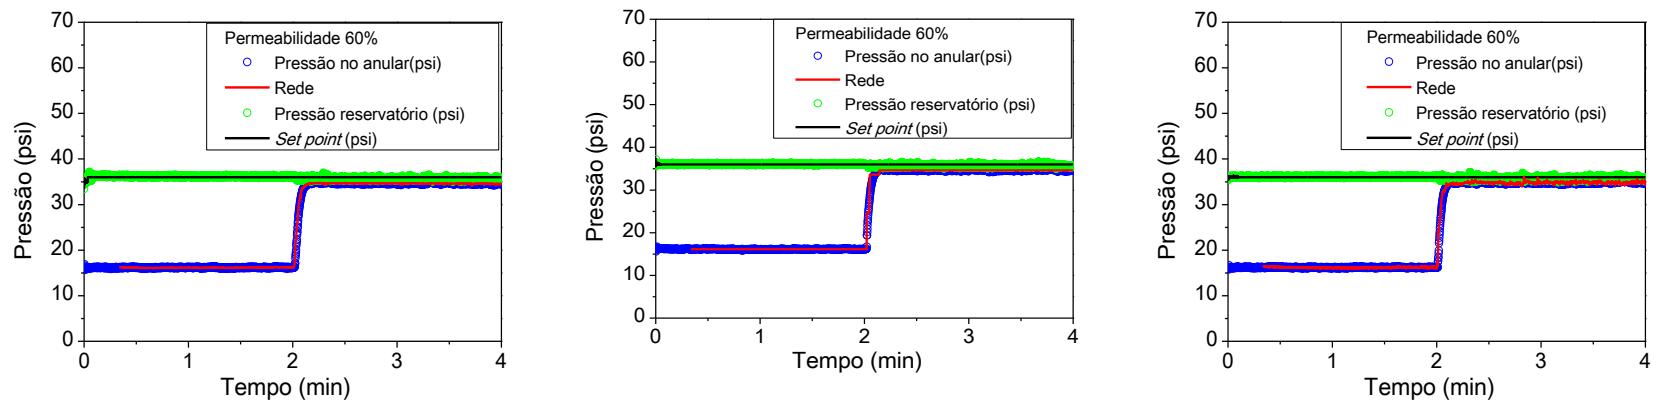


Figura 130 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

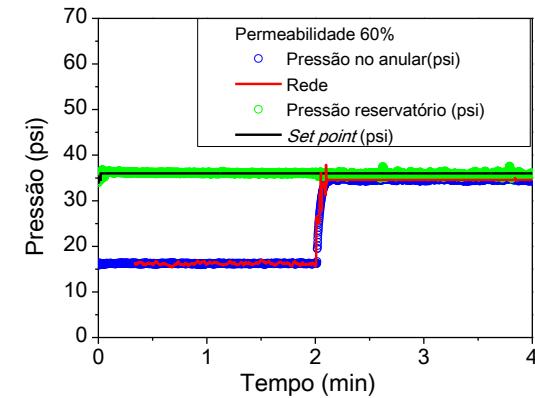
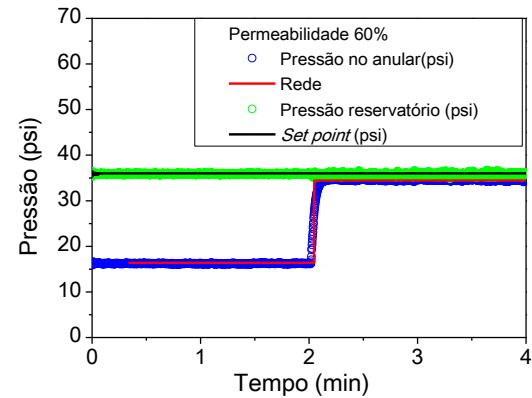
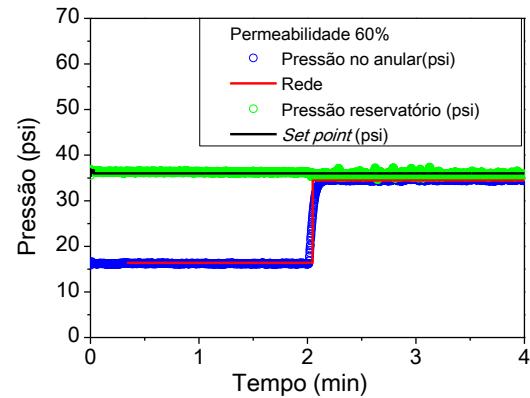


Figura 131 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

Anexo C – Gráficos de treinamento experimental da rede neuronal para situação de perda de circulação.

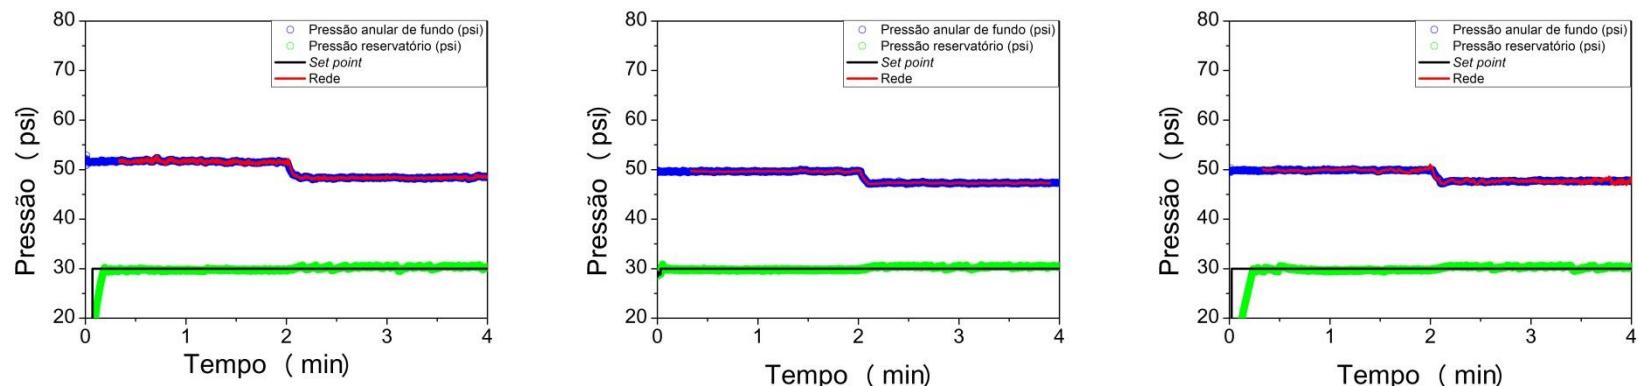


Figura 132 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

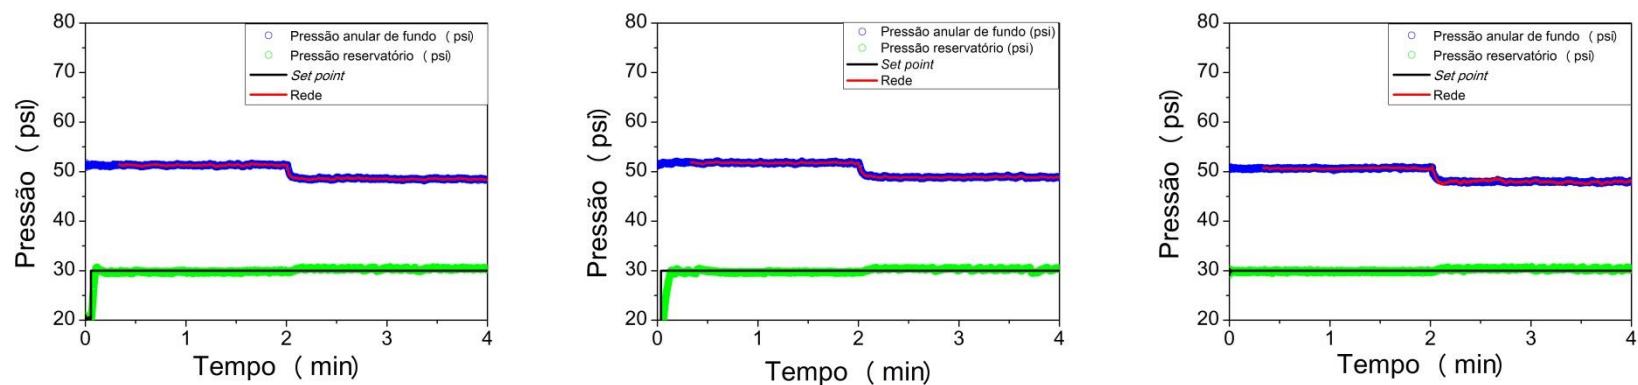


Figura 133 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

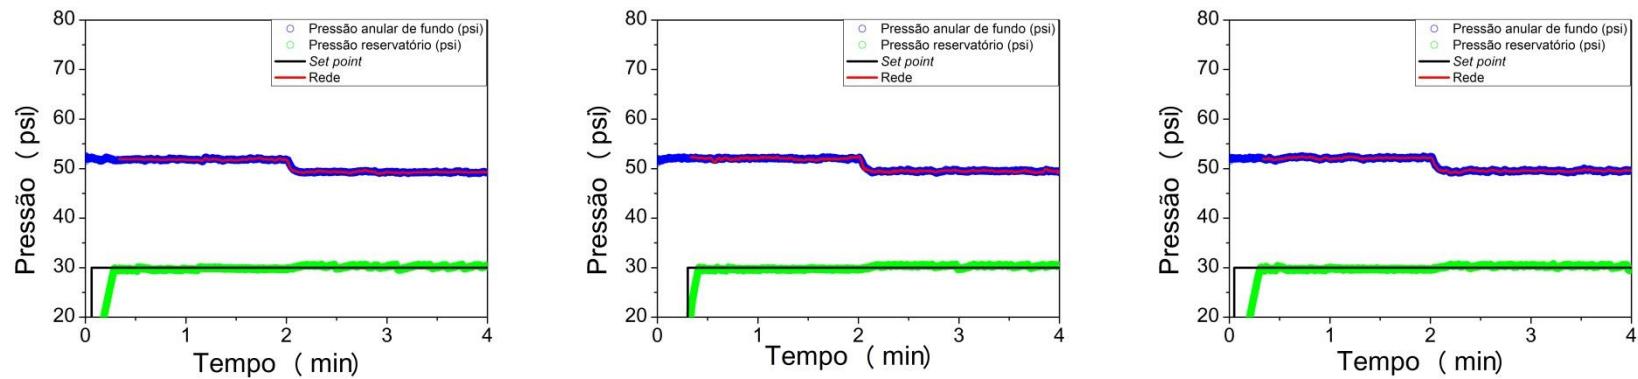


Figura 134 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

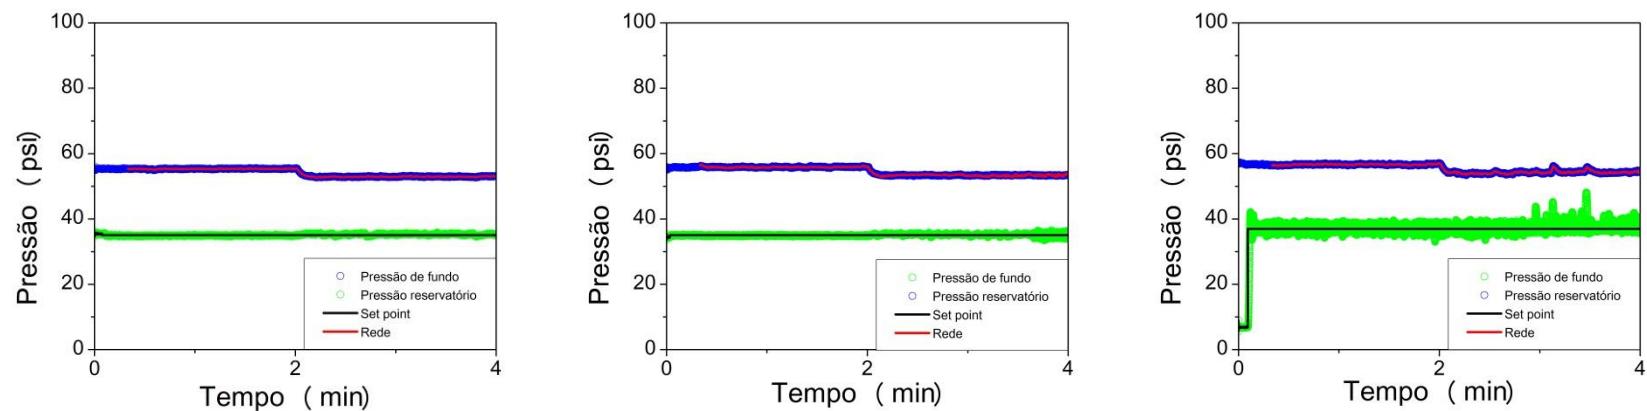


Figura 135 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

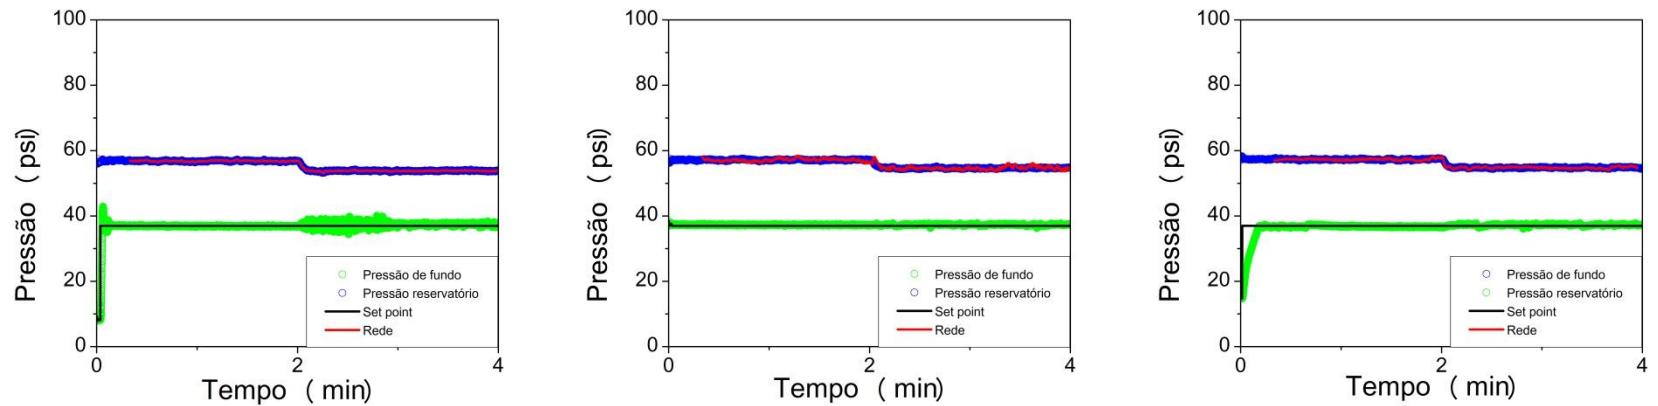


Figura 136 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

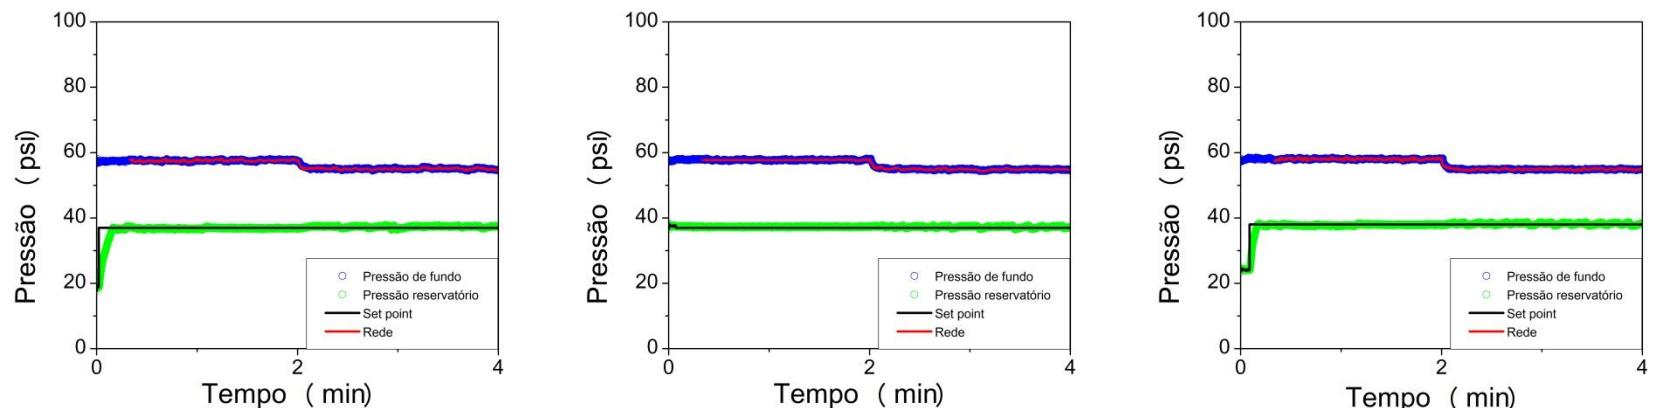


Figura 137 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

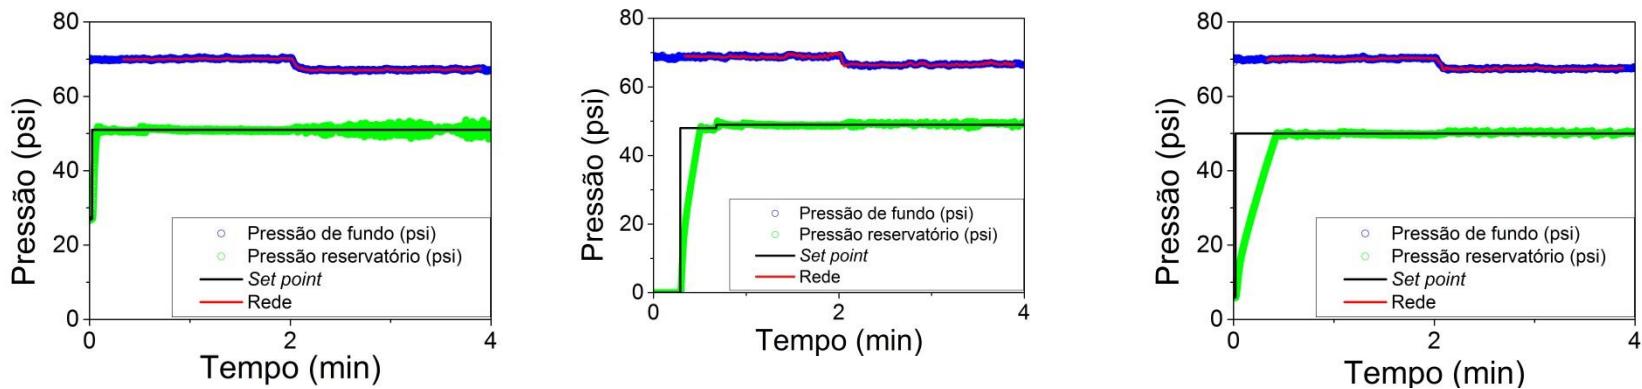


Figura 138 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

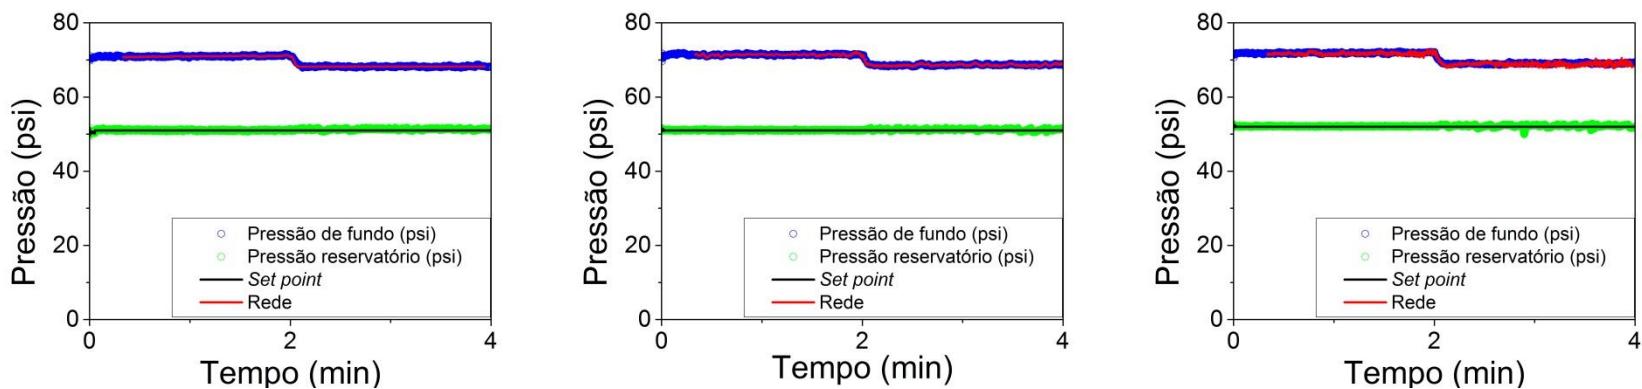


Figura 139 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

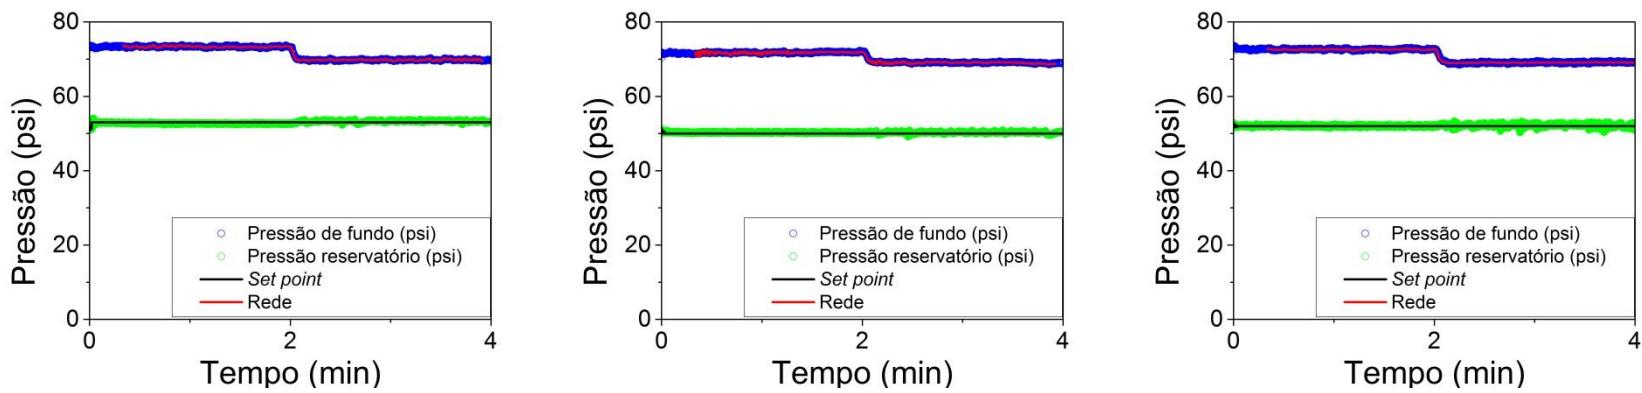


Figura 140 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 40% e cinco, sete e nove neurônios na camada oculta, respectivamente.

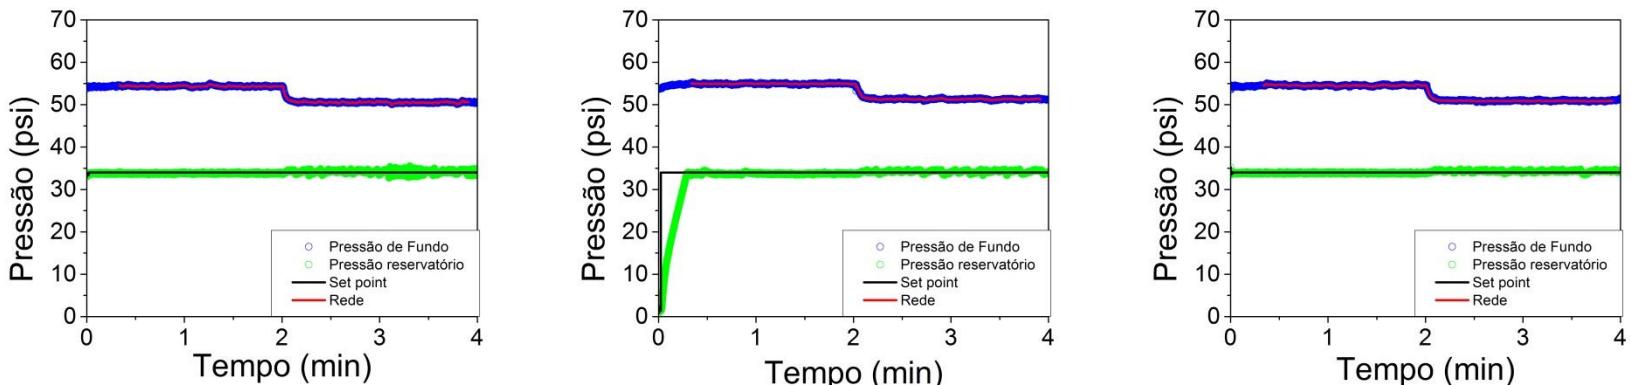


Figura 141 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

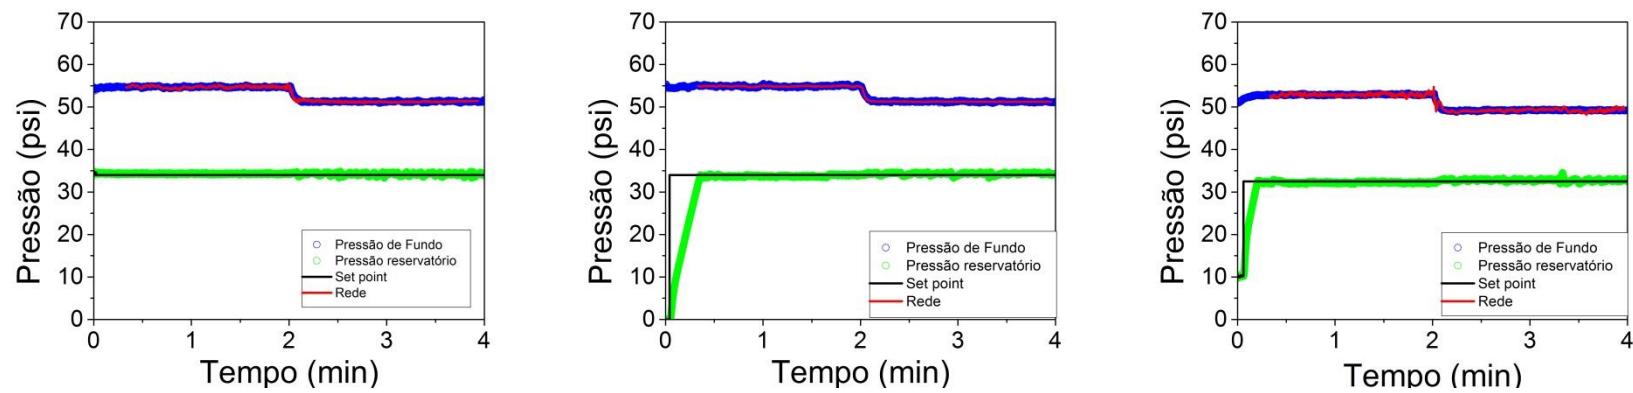


Figura 142 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

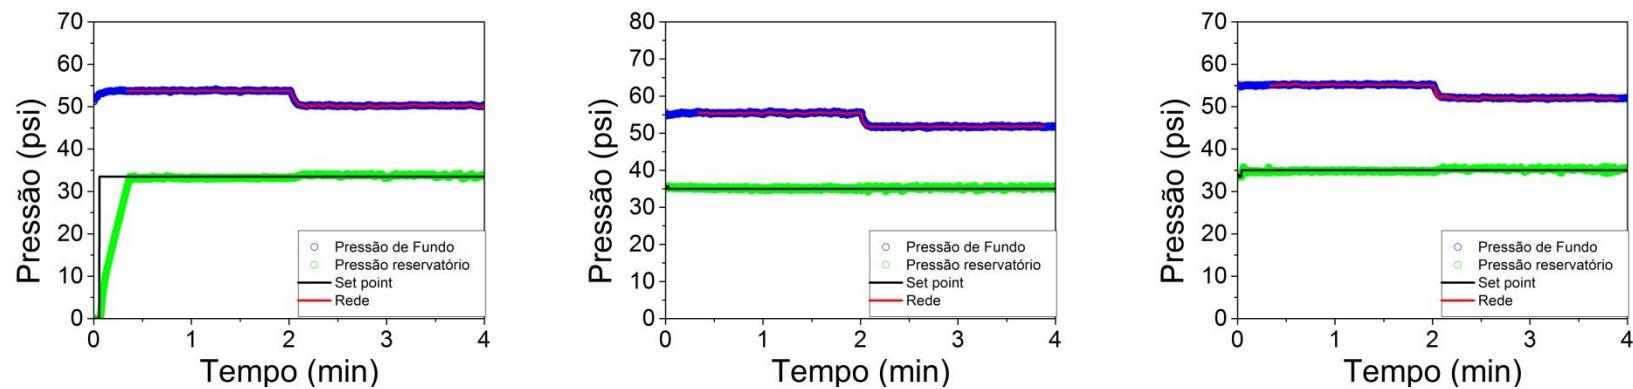


Figura 143 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

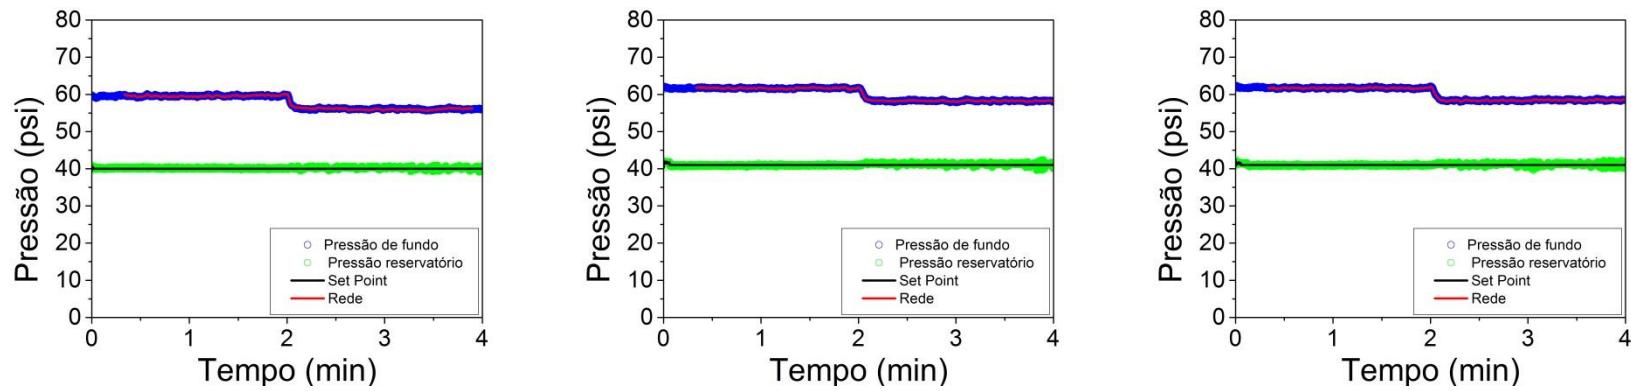


Figura 144 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

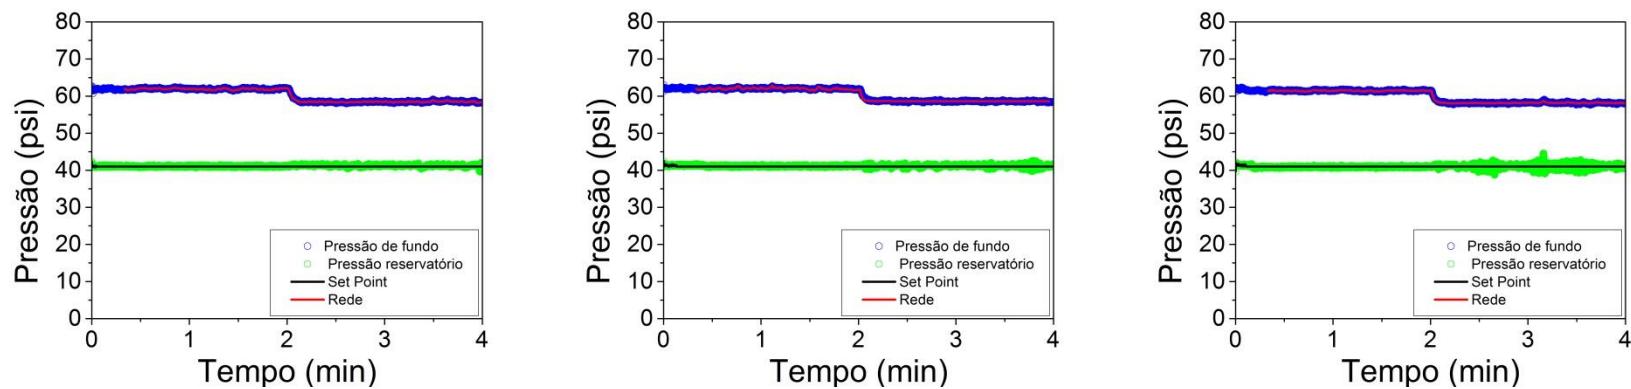


Figura 145 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

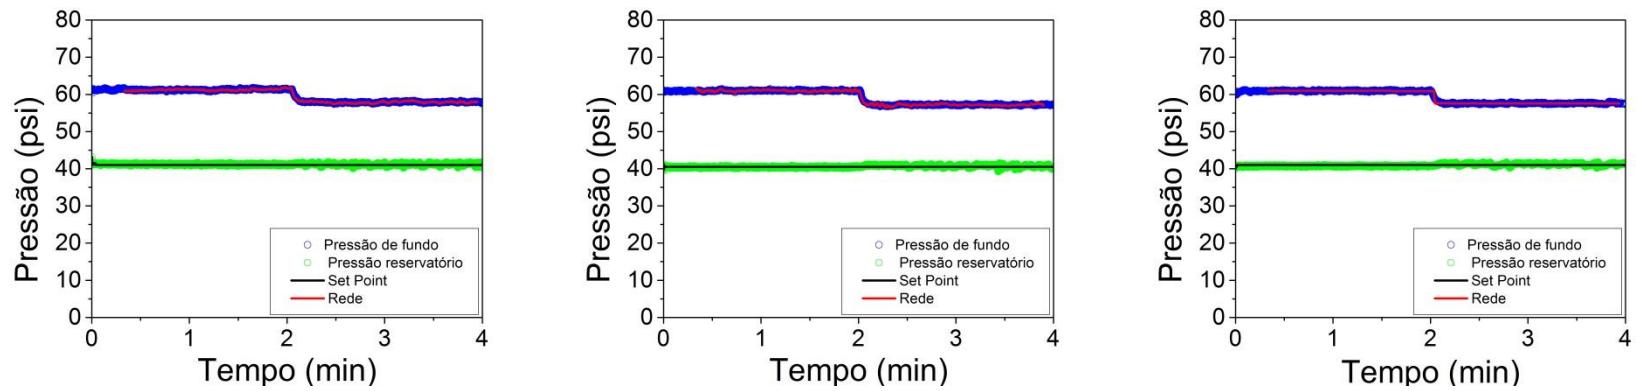


Figura 146 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

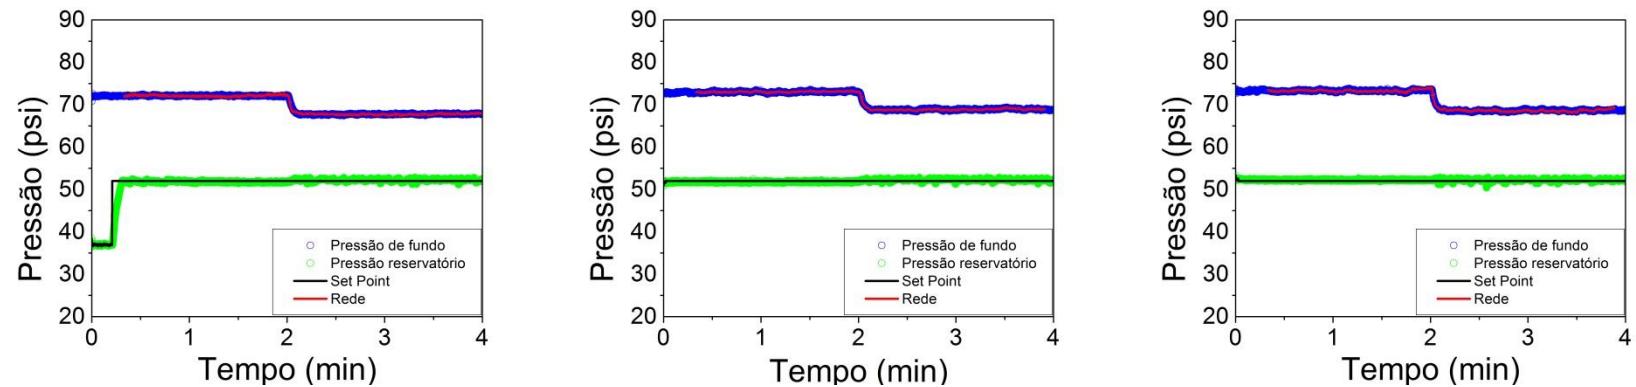


Figura 147 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

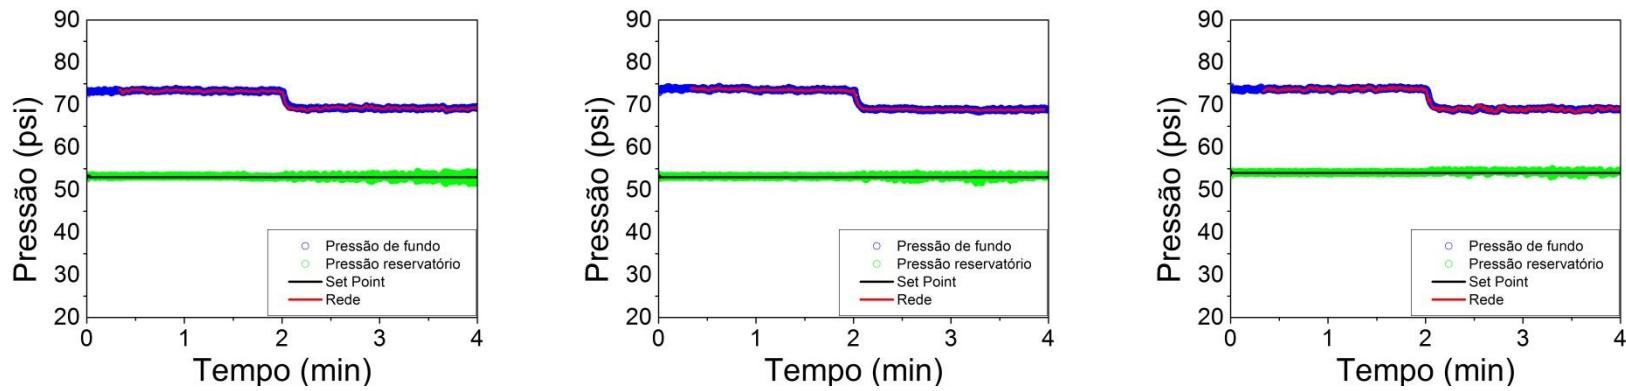


Figura 148 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

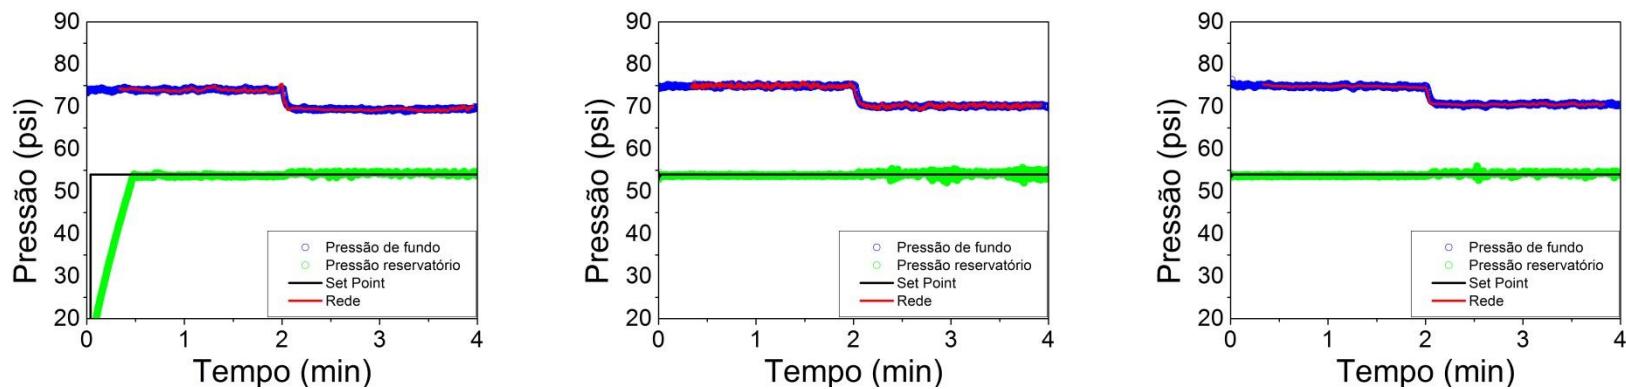


Figura 149 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 50% e cinco, sete e nove neurônios na camada oculta, respectivamente.

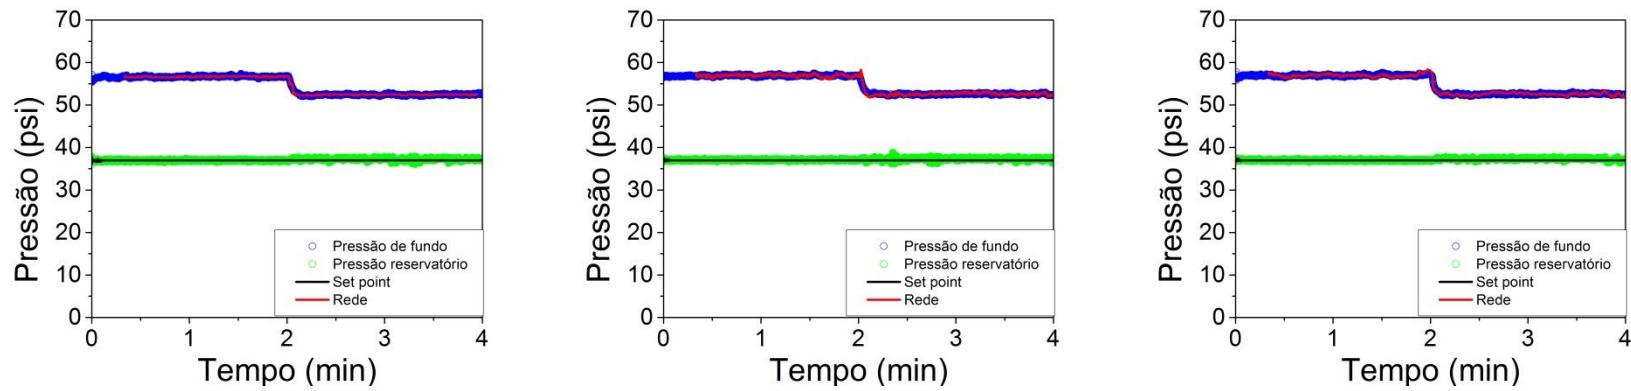


Figura 150 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

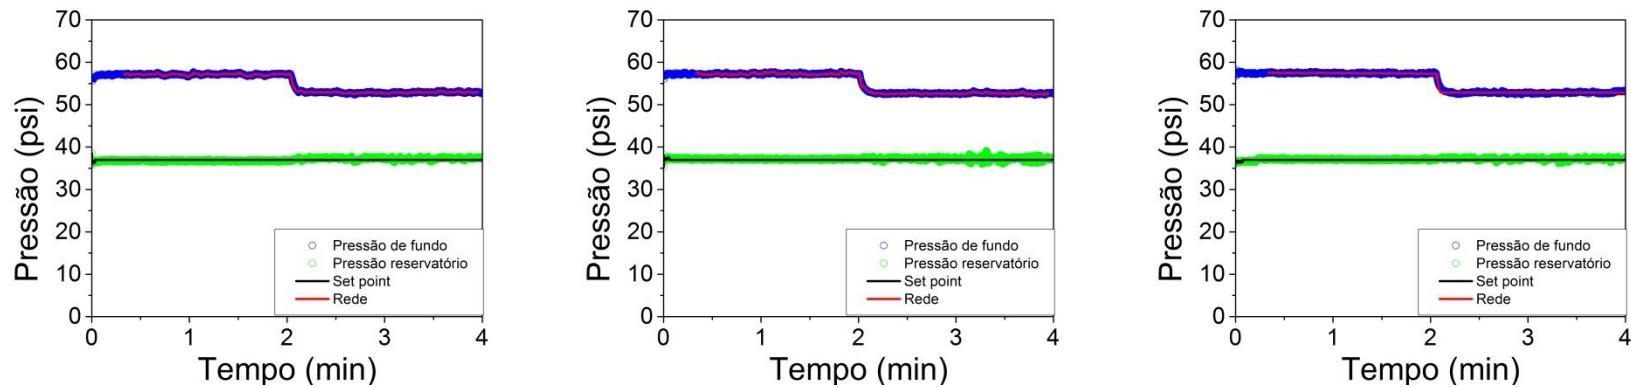


Figura 151 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

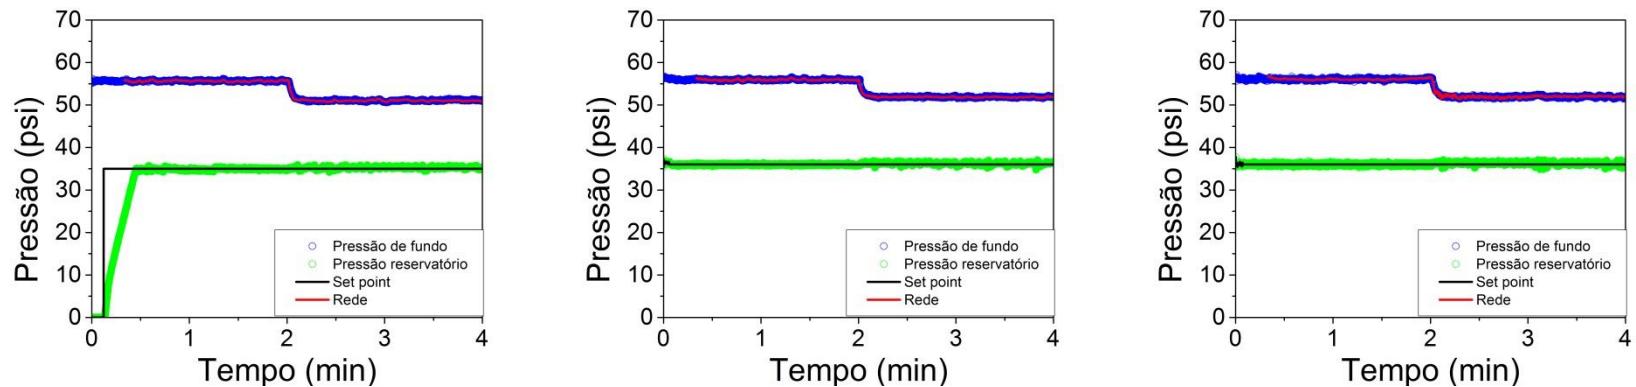


Figura 152 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 95%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

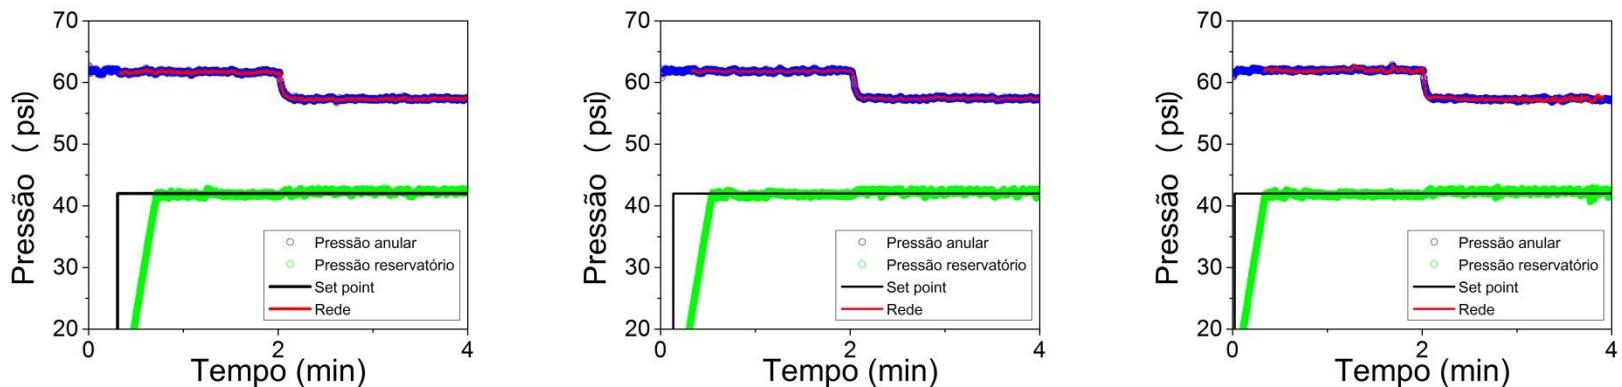


Figura 153 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

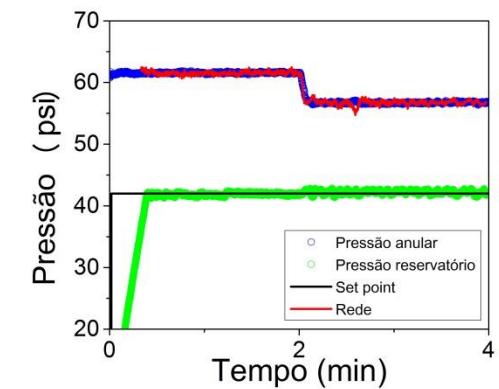
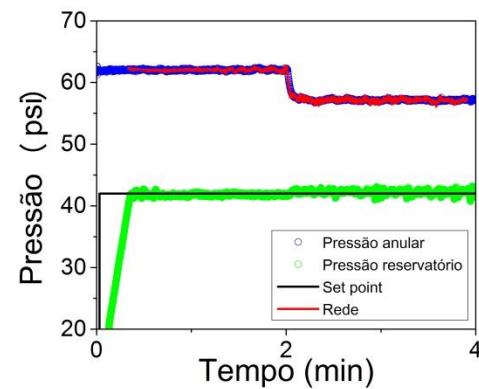
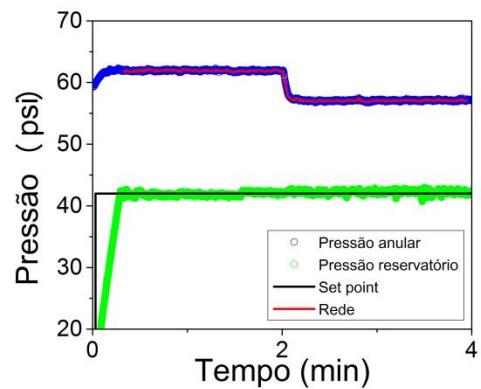


Figura 154 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

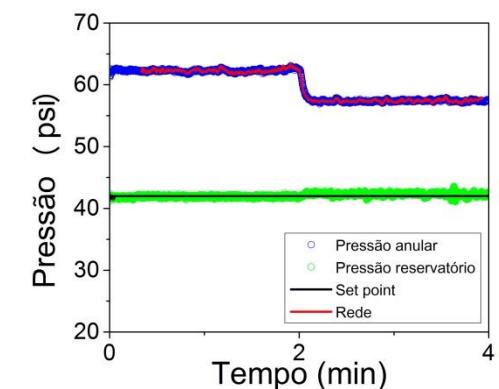
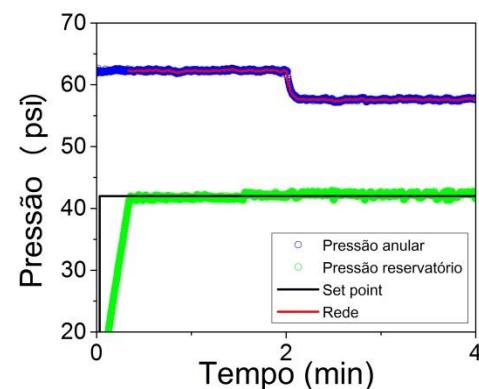
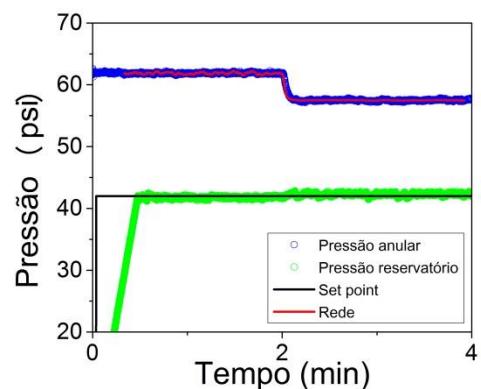


Figura 155 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 55%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

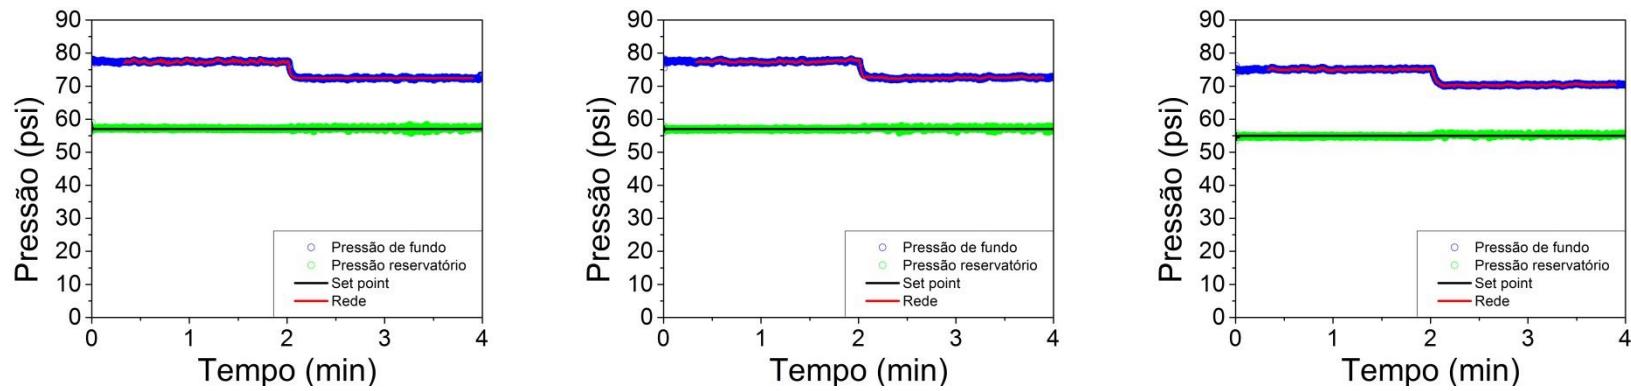


Figura 156 - Treinamento com três dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

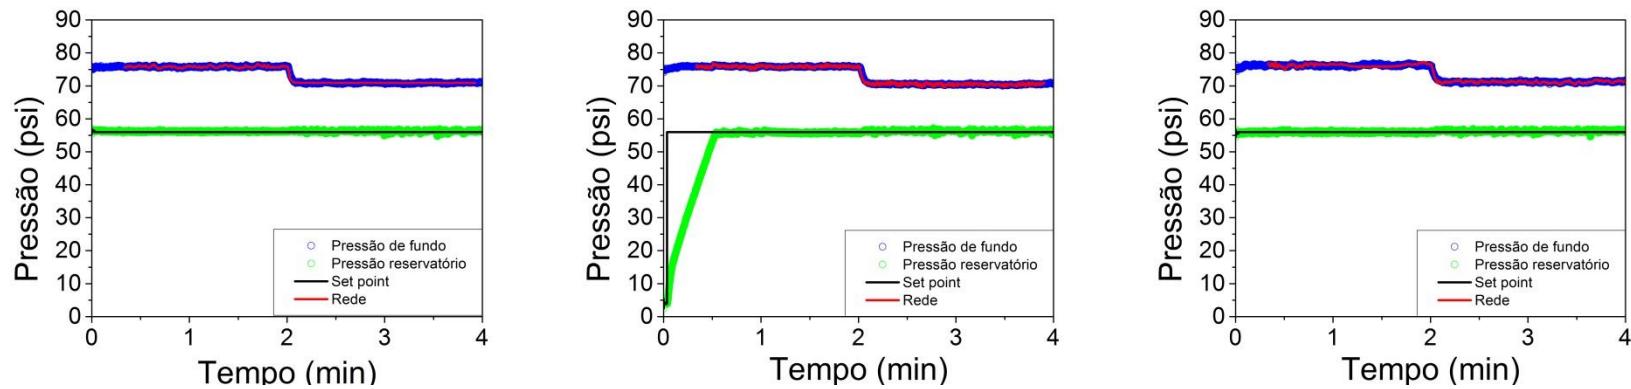


Figura 157 - Treinamento com cinco dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

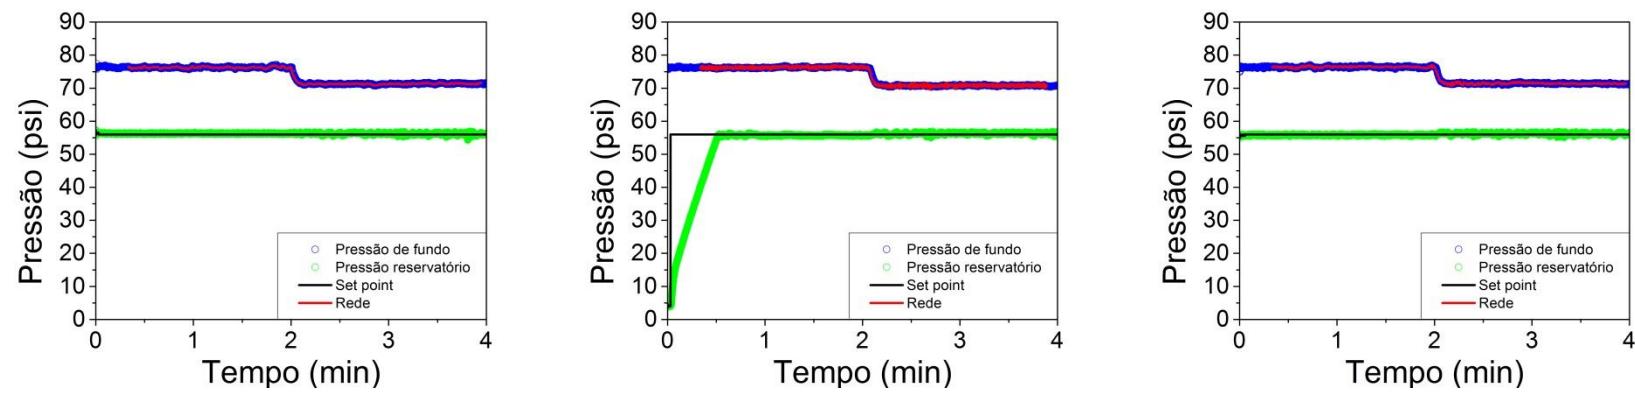


Figura 158 - Treinamento com sete dados passados de pressão, índice de abertura da válvula *choke* em 25%, índice de abertura da válvula de permeabilidade em 60% e cinco, sete e nove neurônios na camada oculta, respectivamente.

Anexo D – Gráficos de treinamento experimental da rede neuronal utilizando como variável manipulada o índice de abertura da válvula *choke*.

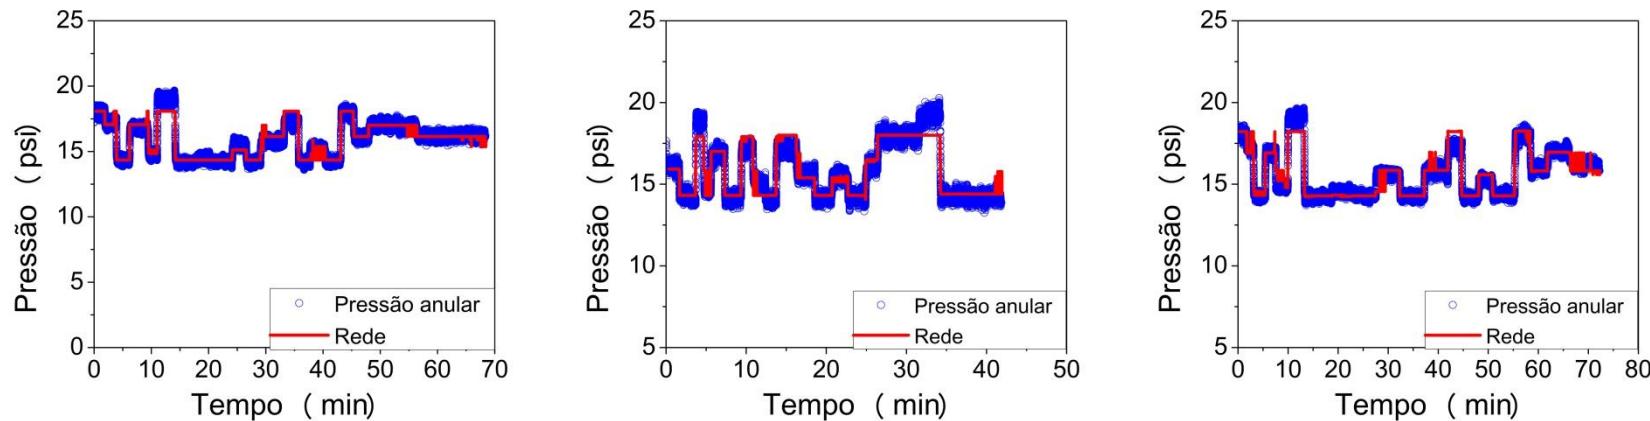


Figura 159 - Treinamento com sete dados passados de pressão, frequência de 30 Hz e cinco, sete e nove neurônios na camada oculta, respectivamente.

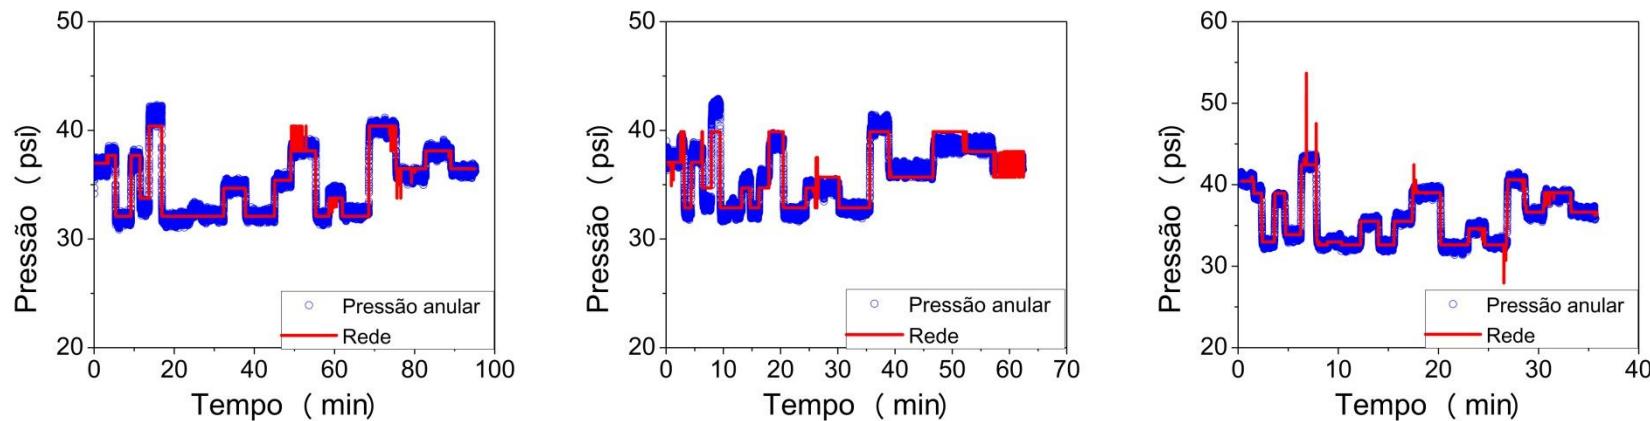


Figura 160 - Treinamento com três dados passados de pressão, frequência de 45 Hz e cinco, sete e nove neurônios na camada oculta, respectivamente.

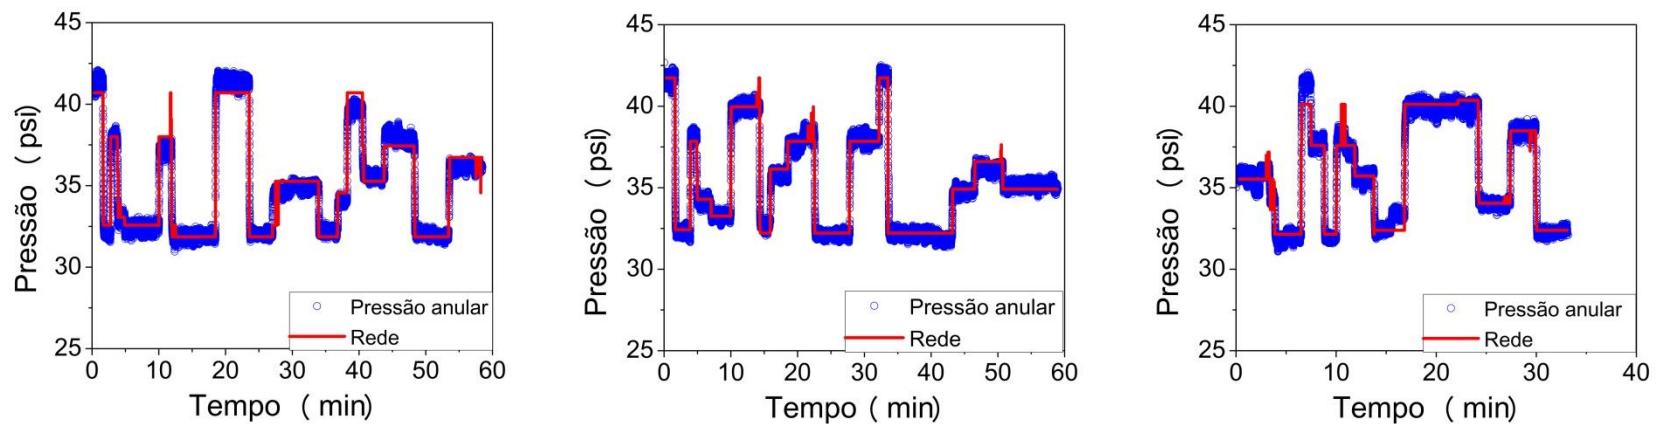


Figura 161 - Treinamento com cinco dados passados de pressão, frequência de 45 Hz e cinco, sete e nove neurônios na camada oculta, respectivamente.

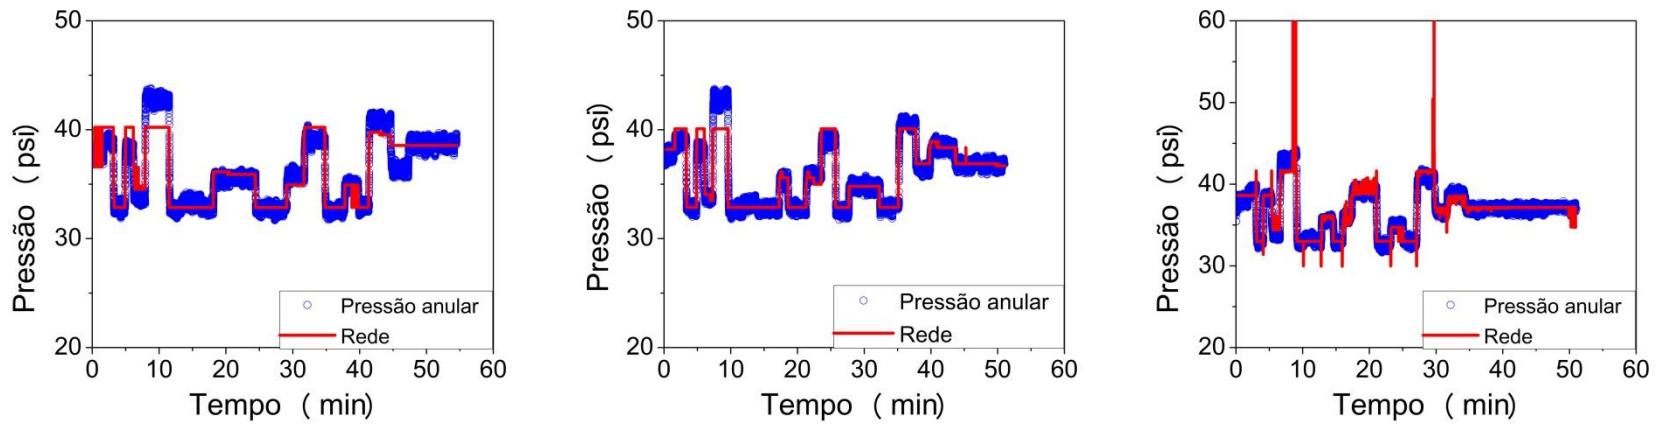


Figura 162 - Treinamento com sete dados passados de pressão, frequência de 45 Hz e cinco, sete e nove neurônios na camada oculta, respectivamente.

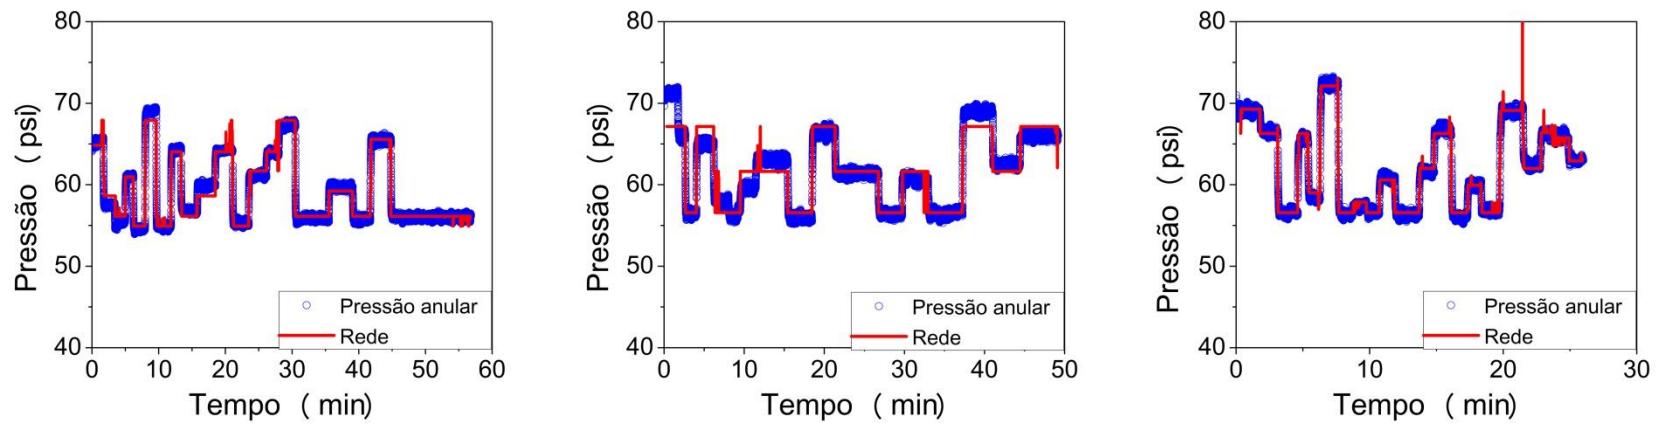


Figura 163 - Treinamento com três dados passados de pressão, frequência de 60 Hz e cinco, sete e nove neurônios na camada oculta, respectivamente.

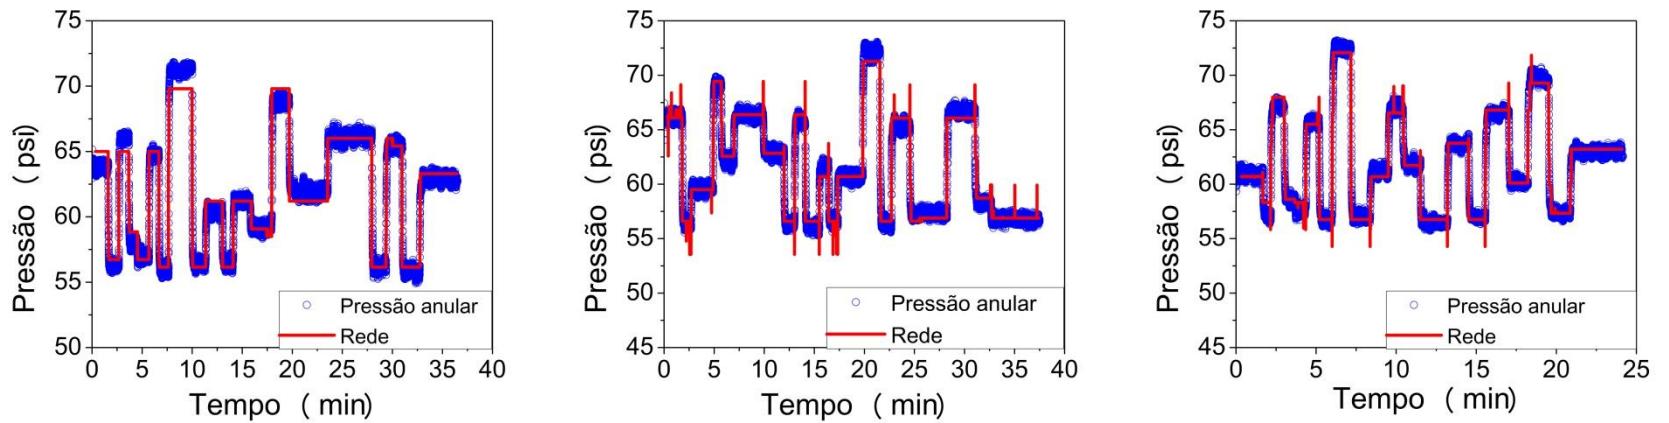


Figura 164 - Treinamento com cinco dados passados de pressão, frequência de 60 Hz e cinco, sete e nove neurônios na camada oculta, respectivamente.

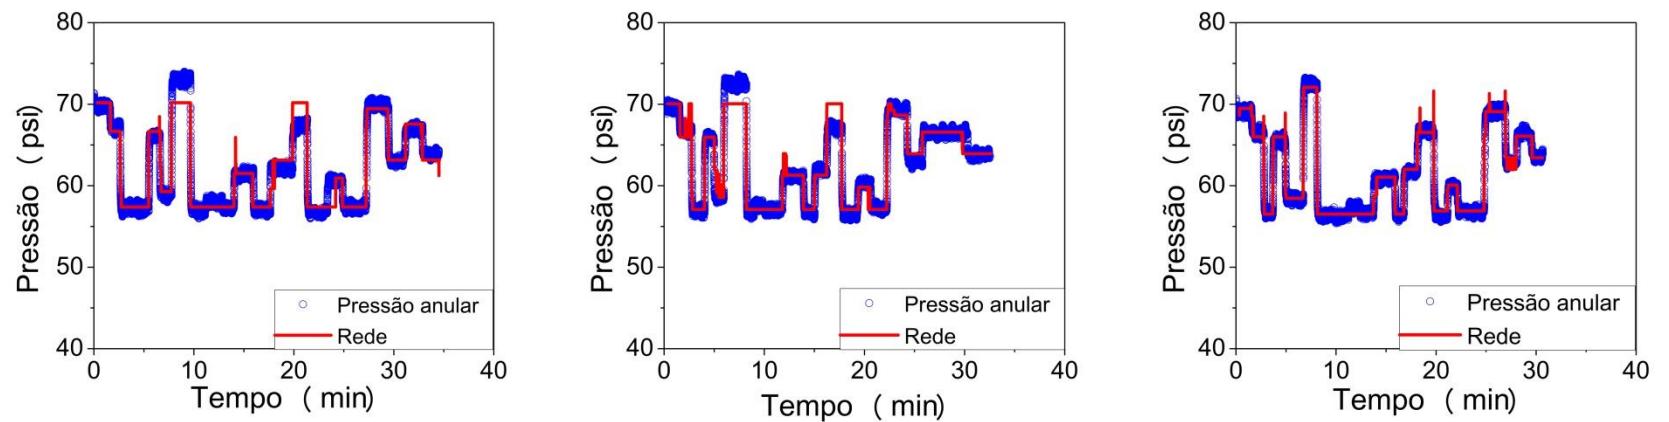


Figura 165 - Treinamento com sete dados passados de pressão, frequência de 60 Hz e cinco, sete e nove neurônios na camada oculta, respectivamente.

Anexo E – Parâmetros calculados pelo método de Sundaresan-Krishnaswamy

Quadro 1 - Cálculo dos parâmetros dos testes de treinamento de *kick* para os três índices de abertura da válvula *choke*.

Permeabilidade 40%	Sundaresan-Krishnaswany											
	Abertura choke	tf	t1	t2	td	T	Pi	Pf	Bu	M	Kp	S
95	4,04	1,43	3,45	0,86	1,35	6,87	22,04	15,17	0,40	37,93	11,20	28,00
55	4,04	1,42	3,44	0,85	1,35	7,43	22,76	15,33	0,40	38,33	11,34	28,35
25	4,09	1,44	3,49	0,86	1,37	9,66	25,16	15,50	0,40	38,76	11,33	28,34
Permeabilidade 50%	Sundaresan-Krishnaswany											
	Abertura choke	tf	t1	t2	td	T	Pi	Pf	Bu	M	Kp	S
95	4,10	1,45	3,50	0,87	1,37	13,39	32,69	19,30	0,50	38,61	14,05	28,10
55	4,24	1,50	3,61	0,90	1,42	11,07	27,20	16,13	0,50	32,26	11,40	22,81
25	4,19	1,48	3,57	0,89	1,40	15,08	32,16	17,08	0,50	34,16	12,21	24,42
Permeabilidade 60%	Sundaresan-Krishnaswany											
	Abertura choke	tf	t1	t2	td	T	Pi	Pf	Bu	M	Kp	S
95	4,10	1,45	3,50	0,87	1,37	9,76	27,18	17,41	0,60	29,02	12,69	21,15
55	4,17	1,47	3,56	0,88	1,40	11,19	29,31	18,12	0,60	30,20	12,98	21,64
25	4,06	1,43	3,46	0,86	1,36	15,94	34,48	18,54	0,60	30,90	13,64	22,74

Quadro 2 - Cálculo dos parâmetros dos testes de treinamento de perda de circulação para os três índices de abertura da válvula *choke*.

Permeabilidade 40%	Sundaresan-Krishnaswany											
Abertura choke	tf	t1	t2	td	T	Pi	Pf	Bu	M	Kp	S	S*
95	4,16	1,47	3,55	0,88	1,39	50,91	48,61	-2,30	0,40	-5,76	-1,66	-4,15
55	4,00	1,41	3,41	0,85	1,34	56,73	54,39	-2,34	0,40	-5,86	-1,75	-4,37
25	4,03	1,42	3,44	0,85	1,35	71,10	68,56	-2,54	0,40	-6,35	-1,88	-4,66
Permeabilidade 50%	Sundaresan-Krishnaswany											
Abertura choke	tf	t1	t2	td	T	Pi	Pf	Bu	M	Kp	S	S*
95	4,03	1,42	3,44	0,85	1,35	54,03	51,01	-3,02	0,50	-6,04	-2,25	-4,50
55	4,12	1,45	3,51	0,87	1,38	61,10	57,71	-3,40	0,50	-6,79	-2,46	-4,93
25	4,02	1,42	3,43	0,85	1,35	73,45	69,32	-4,13	0,50	-8,27	-3,08	-6,15
Permeabilidade 60%	Sundaresan-Krishnaswany											
Abertura choke	tf	t1	t2	td	T	Pi	Pf	Bu	M	Kp	S	S*
95	4,13	1,46	3,52	0,87	1,38	56,52	52,45	-4,07	0,60	-6,78	-2,94	-4,90
55	4,03	1,42	3,44	0,85	1,35	61,51	57,40	-4,11	0,60	-6,85	-3,04	-4,92
25	4,01	1,41	3,42	0,85	1,34	76,13	71,34	-4,80	0,60	-7,99	-3,58	-5,96

Quadro 3 - Cálculo dos parâmetros dos testes de treinamento para variação de vazão para os três índices de abertura da válvula *choke*.

Choke 95%		Sundaresan - Krishnaswany											
Bomba de água (Hz)	Bomba de lama (Hz)	tf	t1	t2	td	T	Pi	Pf	Bu	M	Kp	S	S*
30	40	4,01	1,42	3,42	0,85	1,34	9,29	19,55	10,25	10,00	1,03	7,63	0,76
40	50	4,00	1,41	3,42	0,85	1,34	19,55	32,07	12,52	10,00	1,25	9,34	0,93
50	60	4,00	1,41	3,41	0,85	1,34	32,07	45,90	13,83	10,00	1,38	10,32	1,03
60	50	4,01	1,41	3,42	0,85	1,34	45,90	31,33	-14,57	-10,00	1,46	-10,84	1,08
50	40	4,02	1,42	3,43	0,85	1,35	31,33	19,61	-11,72	-10,00	1,17	-8,70	0,87
40	30	4,41	1,56	3,76	0,93	1,48	19,61	9,34	-10,27	-10,00	1,03	-7,09	0,71
Choke 55%		Sundaresan - Krishnaswany											
Bomba de água (Hz)	Bomba de lama (Hz)	tf	t1	t2	td	T	Pi	Pf	Bu	M	Kp	S	S*
30	40	4,02	1,42	3,43	0,85	1,35	10,58	21,88	11,31	10,00	1,13	8,40	0,84
40	50	4,02	1,42	3,43	0,85	1,35	21,88	35,47	13,59	10,00	1,36	10,10	1,01
50	60	3,99	1,41	3,40	0,84	1,34	35,47	50,35	14,88	10,00	1,49	11,13	1,11
60	50	3,99	1,41	3,40	0,84	1,34	50,35	35,67	-14,69	-10,00	1,47	-11,00	1,10
50	40	4,00	1,41	3,41	0,85	1,34	35,67	22,00	-13,66	-10,00	1,37	-10,19	1,02
40	30	4,34	1,53	3,70	0,92	1,46	22,00	10,70	-11,31	-10,00	1,13	-7,87	0,79
Choke 25%		Sundaresan - Krishnaswany											
Bomba de água (Hz)	Bomba de lama (Hz)	tf	t1	t2	td	T	Pi	Pf	Bu	M	Kp	S	S*
30	40	4,01	1,41	3,42	0,85	1,34	14,10	27,53	13,44	10,00	1,34	10,01	1,00
40	50	4,01	1,41	3,42	0,85	1,34	27,53	43,38	15,85	10,00	1,58	11,81	1,18
50	60	4,00	1,41	3,41	0,84	1,34	43,38	60,28	17,08	10,00	1,71	12,77	1,28
60	50	4,01	1,41	3,42	0,85	1,34	60,28	43,77	-16,51	-10,00	1,65	-12,30	1,23
50	40	4,00	1,41	3,41	0,85	1,34	43,77	27,90	-16,05	-10,00	1,60	-11,98	1,20
40	30	4,02	1,42	3,43	0,85	1,35	27,90	14,33	-13,58	-10,00	1,36	-10,07	1,01

Quadro 4 - para variação do índice de abertura da válvula *choke*.

Bomba 30 Hz		Sundaresan-Krishnaswamy											
Abertura inicial	Abertura final	t	t1 (min)	t2(min)	td	T	Pi(psi)	Pf(psi)	Bu	M	Kp	S	S*
35	39,98	6,0696	2,1426	5,1773	1,2839	2,0333	17,1375	16,5834	-0,5541	4,9800	-0,1113	-0,2725	-0,0547
86,87	43,14	2,9549	1,0431	2,5205	0,6250	0,9899	13,5946	16,0281	2,4336	-43,7300	-0,0556	2,4585	-0,0562
70	30	6,0980	2,1526	5,2016	1,2899	2,0428	14,4231	18,4325	4,0093	-40,0000	-0,1002	1,9627	-0,0491
91,06	80	3,2828	1,1588	2,8002	0,6944	1,0997	13,9212	14,0517	0,1305	-11,0600	-0,0118	0,1186	-0,0107
86,93	57,97	6,0013	2,1184	5,1191	1,2694	2,0104	13,9532	15,1823	1,2292	-28,9600	-0,0424	0,6114	-0,0211
90,27	54,99	5,2205	1,8428	4,4530	1,1043	1,7489	14,0053	15,3870	1,3818	-35,2800	-0,0392	0,7901	-0,0224
40,18	94,48	6,7555	2,3847	5,7624	1,4290	2,2631	16,9959	13,9172	-3,0787	54,3000	-0,0567	-1,3604	-0,0251
85,3	62,2	7,0472	2,4877	6,0113	1,4907	2,3608	15,0821	14,1172	-0,9649	-23,1000	0,0418	-0,4087	0,0177
35,1	51,32	9,1844	3,2421	7,8343	1,9428	3,0768	17,8570	15,7842	-2,0728	16,2200	-0,1278	-0,6737	-0,0415
41,73	49,1	6,7769	2,3922	5,7807	1,4335	2,2703	16,8221	16,0772	-0,7450	7,3700	-0,1011	-0,3281	-0,0445
75	40,18	0,9857	0,3480	0,8408	0,2085	0,3302	14,9104	17,3705	2,4601	-34,8200	-0,0707	7,4501	-0,2140
51,32	35,1	1,1032	0,3894	0,9410	0,2334	0,3696	16,0017	17,8964	1,8947	-16,2200	-0,1168	5,1266	-0,3161
62,2	85,3	1,1460	0,4045	0,9775	0,2424	0,3839	15,3043	14,4996	-0,8047	23,1000	-0,0348	-2,0962	-0,0907
49,1	94,48	1,0895	0,3846	0,9293	0,2305	0,3650	16,2951	14,0000	-2,2952	45,3800	-0,0506	-6,2887	-0,1386
41,73	90,27	1,1180	0,3947	0,9536	0,2365	0,3745	17,1600	14,3237	-2,8363	48,5400	-0,0584	-7,5729	-0,1560
54,99	86,93	1,2651	0,4466	1,0791	0,2676	0,4238	16,0508	14,3549	-1,6960	31,9400	-0,0531	-4,0019	-0,1253
57,97	30	2,7143	0,9581	2,3153	0,5741	0,9093	15,5867	19,0252	3,4385	-27,9700	-0,1229	3,7815	-0,1352
91,06	43,14	1,1534	0,4071	0,9838	0,2440	0,3864	14,1033	16,9561	2,8529	-47,9200	-0,0595	7,3837	-0,1541
80	39,98	2,0114	0,7100	1,7157	0,4255	0,6738	14,2929	17,1626	2,8697	-40,0200	-0,0717	4,2588	-0,1064
70	87	4,3459	1,5341	3,7071	0,9193	1,4559	14,8781	14,0364	-0,8417	17,0000	-0,0495	-0,5781	-0,0340
65	39,98	2,0522	0,7244	1,7505	0,4341	0,6875	14,6837	16,5071	1,8234	-25,0200	-0,0729	2,6523	-0,1060
86,87	43,14	1,7980	0,6347	1,5337	0,3803	0,6023	13,9707	16,2025	2,2318	-43,7300	-0,0510	3,7053	-0,0847
70	30	2,8788	1,0162	2,4556	0,6090	0,9644	14,2077	18,5479	4,3402	-40,0000	-0,1085	4,5004	-0,1125
91,06	80	2,2646	0,7994	1,9317	0,4790	0,7587	13,5555	13,7759	0,2204	-11,0600	-0,0199	0,2905	-0,0263
86,93	57,97	3,3296	1,1753	2,8401	0,7043	1,1154	13,5832	14,9512	1,3680	-28,9600	-0,0472	1,2264	-0,0423
90,27	54,99	2,6231	0,9259	2,2375	0,5549	0,8787	13,6710	15,0736	1,4026	-35,2800	-0,0398	1,5962	-0,0452
40,18	94,48	2,2977	0,8111	1,9599	0,4860	0,7697	16,4163	13,3602	-3,0561	54,3000	-0,0563	-3,9705	-0,0731
62,2	85,3	2,7824	0,9822	2,3734	0,5886	0,9321	14,6038	13,7714	-0,8324	23,1000	-0,0360	-0,8930	-0,0387
35,1	51,32	6,6758	2,3566	5,6945	1,4121	2,2364	17,1387	15,2726	-1,8661	16,2200	-0,1150	-0,8344	-0,0514

Bomba 30 Hz		Sundaresan-Krishnaswamy												
Abertura inicial	Abertura final	t	t1 (min)	t2(min)	td	T	Pi(psi)	Pf(psi)	Bu	M	Kp	S	S*	
33	86,87	1,4686	0,5184	1,2527	0,3107	0,4920	18,7151	14,9890	-3,7261	53,8700	-0,0692	-7,5736	-0,1406	
39,98	70	1,2860	0,4539	1,0969	0,2720	0,4308	17,4277	15,3638	-2,0639	30,0200	-0,0687	-4,7909	-0,1596	
80	43,14	1,4706	0,5191	1,2544	0,3111	0,4927	15,0344	17,3493	2,3149	-36,8600	-0,0628	4,6989	-0,1275	
91,06	30	3,6954	1,3045	3,1522	0,7817	1,2380	14,8214	19,2413	4,4200	-61,0600	-0,0724	3,5704	-0,0585	
86,93	57,97	2,3607	0,8333	2,0136	0,4993	0,7908	15,0070	16,0518	1,0448	-28,9600	-0,0361	1,3211	-0,0456	
54,99	85,3	2,1015	0,7418	1,7926	0,4445	0,7040	16,4836	14,9770	-1,5067	30,3100	-0,0497	-2,1401	-0,0706	
62,2	35,1	2,8981	1,0230	2,4721	0,6130	0,9709	15,7836	18,7912	3,0076	-27,1000	-0,1110	3,0979	-0,1143	
51,32	40,18	3,2341	1,1416	2,7587	0,6841	1,0834	16,7701	18,2382	1,4681	-11,1400	-0,1318	1,3550	-0,1216	
41,73	90,27	3,2335	1,1414	2,7581	0,6840	1,0832	17,6544	15,0123	-2,6421	48,5400	-0,0544	-2,4392	-0,0503	
94,48	49,1	2,8860	1,0188	2,4618	0,6105	0,9668	14,6826	16,8840	2,2015	-45,3800	-0,0485	2,2770	-0,0502	
35	39,98	1,3953	0,4925	1,1902	0,2951	0,4674	17,9864	17,1559	-0,8305	4,9800	-0,1668	-1,7767	-0,3568	
86,87	43,14	2,1029	0,7423	1,7937	0,4448	0,7045	14,2345	17,1096	2,8750	-43,7300	-0,0657	4,0812	-0,0933	
70	30	3,2876	1,1605	2,8043	0,6954	1,1013	14,8961	19,2954	4,3993	-40,0000	-0,1100	3,9944	-0,0999	
91,06	80	3,9773	1,4040	3,3926	0,8413	1,3324	14,2372	14,3517	0,1145	-11,0600	-0,0104	0,0859	-0,0078	
86,93	57,97	4,8341	1,7064	4,1235	1,0225	1,6194	14,1924	15,6713	1,4788	-28,9600	-0,0511	0,9132	-0,0315	
90,27	54,99	4,7149	1,6644	4,0219	0,9974	1,5795	14,2487	15,4215	1,1727	-35,2800	-0,0332	0,7425	-0,0210	
40,18	94,48	3,4523	1,2187	2,9448	0,7303	1,1565	17,3191	14,3360	-2,9831	54,3000	-0,0549	-2,5794	-0,0475	
62,2	85,3	4,4696	1,5778	3,8126	0,9455	1,4973	15,0929	14,4915	-0,6014	23,1000	-0,0260	-0,4017	-0,0174	
35,1	51,32	3,5001	1,2355	2,9856	0,7404	1,1725	18,0033	16,2307	-1,7726	16,2200	-0,1093	-1,5118	-0,0932	
41,73	49,1	6,1471	2,1699	5,2435	1,3003	2,0593	17,2725	15,8187	-1,4538	7,3700	-0,1973	-0,7060	-0,0958	
50	80	1,3972	0,4932	1,1918	0,2956	0,4681	15,8252	14,1439	-1,6813	30,0000	-0,0560	-3,5920	-0,1197	
91,06	30	1,0094	0,3563	0,8610	0,2135	0,3382	14,1681	19,1259	4,9578	-61,0600	-0,0812	14,6611	-0,2401	
70	43,14	1,7086	0,6031	1,4575	0,3614	0,5724	14,4754	16,9016	2,4261	-26,8600	-0,0903	4,2386	-0,1578	
86,87	39,98	1,4846	0,5241	1,2664	0,3140	0,4974	14,1765	17,2945	3,1181	-46,8900	-0,0665	6,2693	-0,1337	
62,2	94,48	1,3613	0,4805	1,1612	0,2879	0,4560	15,3148	13,9921	-1,3227	32,2800	-0,0410	-2,9004	-0,0899	
40,18	54,99	2,2854	0,8067	1,9494	0,4834	0,7656	17,0978	16,0557	-1,0421	14,8100	-0,0704	-1,3612	-0,0919	
90,27	57,97	2,0085	0,7090	1,7132	0,4248	0,6728	14,4515	15,4198	0,9683	-32,3000	-0,0300	1,4391	-0,0446	
86,93	49,1	1,4989	0,5291	1,2785	0,3171	0,5021	13,6965	16,1164	2,4200	-37,8300	-0,0640	4,8195	-0,1274	
35,1	28	2,6502	0,9355	2,2606	0,5606	0,8878	18,0325	19,1281	1,0956	-7,1000	-0,1543	1,2340	-0,1738	

Bomba 30 Hz		Sundaresan-Krishnaswamy											
Abertura inicial	Abertura final	t	t1 (min)	t2(min)	td	T	Pi(psi)	Pf(psi)	Bu	M	Kp	S	S*
35	39,98	2,0503	0,7238	1,7489	0,4337	0,6869	18,2347	17,5682	-0,6665	4,9800	-0,1338	-0,9704	-0,1949
86,87	43,14	3,2253	1,1385	2,7512	0,6823	1,0805	14,6399	16,2691	1,6292	-43,7300	-0,0373	1,5079	-0,0345
70	30	3,1501	1,1120	2,6870	0,6663	1,0553	14,6312	18,7357	4,1046	-40,0000	-0,1026	3,8896	-0,0972
91,06	80	2,2781	0,8042	1,9432	0,4819	0,7632	14,1134	14,5160	0,4025	-11,0600	-0,0364	0,5275	-0,0477
86,93	57,97	2,4499	0,8648	2,0897	0,5182	0,8207	14,3587	15,5796	1,2209	-28,9600	-0,0422	1,4876	-0,0514
90,27	54,99	4,1032	1,4484	3,5000	0,8679	1,3746	14,0990	15,6155	1,5166	-35,2800	-0,0430	1,1033	-0,0313
40,18	94,48	2,0087	0,7091	1,7134	0,4249	0,6729	17,5321	14,1133	-3,4189	54,3000	-0,0630	-5,0808	-0,0936
62,2	85,3	2,6978	0,9523	2,3012	0,5707	0,9038	14,6903	14,5072	-0,1831	23,1000	-0,0079	-0,2026	-0,0088
35,1	51,32	2,6365	0,9307	2,2489	0,5577	0,8832	18,3752	15,7181	-2,6571	16,2200	-0,1638	-3,0084	-0,1855
41,73	49,1	11,9789	4,2285	10,2180	2,5339	4,0129	16,4762	16,2158	-0,2605	7,3700	-0,0353	-0,0649	-0,0088
33	86,67	1,3806	0,4874	1,1777	0,2920	0,4625	18,7514	15,0915	-3,6599	53,6700	-0,0682	-7,9132	-0,1474
85,3	39,98	1,1319	0,3995	0,9655	0,2394	0,3792	14,9302	18,1503	3,2202	-45,3200	-0,0711	8,4926	-0,1874
62,2	70	1,8219	0,6431	1,5541	0,3854	0,6103	16,0325	15,5354	-0,4971	7,8000	-0,0637	-0,8144	-0,1044
35,1	80	1,7496	0,6176	1,4924	0,3701	0,5861	18,1651	15,0235	-3,1416	44,9000	-0,0700	-5,3601	-0,1194
51,32	43,14	2,4407	0,8616	2,0819	0,5163	0,8176	16,5944	17,5479	0,9535	-8,1800	-0,1166	1,1662	-0,1426
40,18	91,06	2,8753	1,0150	2,4527	0,6082	0,9632	17,7487	14,8425	-2,9062	50,8800	-0,0571	-3,0172	-0,0593
41,73	30	6,9578	2,4561	5,9350	1,4718	2,3309	18,0820	19,5542	1,4722	-11,7300	-0,1255	0,6316	-0,0538
90,27	86,93	4,1690	1,4716	3,5561	0,8819	1,3966	15,0392	14,9906	-0,0487	-3,3400	0,0146	-0,0349	0,0104
94,48	57,97	6,6392	2,3436	5,6632	1,4044	2,2241	14,7931	16,3575	1,5645	-36,5100	-0,0429	0,7034	-0,0193
49,1	54,99	3,3027	1,1659	2,8172	0,6986	1,1064	17,1795	16,3223	-0,8572	5,8900	-0,1455	-0,7747	-0,1315
33	86,87	1,1440	0,4038	0,9758	0,2420	0,3832	17,7389	13,8997	-3,8392	53,8700	-0,0713	-10,0179	-0,1860
39,98	70	2,1419	0,7561	1,8271	0,4531	0,7175	16,6683	14,5316	-2,1368	30,0200	-0,0712	-2,9779	-0,0992
80	43,14	3,4459	1,2164	2,9394	0,7289	1,1544	14,0403	16,4394	2,3991	-36,8600	-0,0651	2,0783	-0,0564
91,06	30	3,8162	1,3471	3,2552	0,8072	1,2784	13,9203	18,4612	4,5409	-61,0600	-0,0744	3,5520	-0,0582
86,93	57,97	2,5957	0,9163	2,2142	0,5491	0,8696	14,0588	15,2892	1,2304	-28,9600	-0,0425	1,4149	-0,0489
85,3	54,99	4,8311	1,7054	4,1210	1,0219	1,6184	14,1929	15,6088	1,4159	-30,3100	-0,0467	0,8748	-0,0289
62,2	35,1	2,3253	0,8208	1,9834	0,4919	0,7790	14,9635	17,7968	2,8333	-27,1000	-0,1045	3,6373	-0,1342
51,32	40,18	2,4953	0,8808	2,1285	0,5278	0,8359	15,6615	16,9014	1,2399	-11,1400	-0,1113	1,4832	-0,1331
90,27	41,73	2,4732	0,8730	2,1096	0,5231	0,8285	14,0418	16,7020	2,6602	-48,5400	-0,0548	3,2108	-0,0661
94,48	49,1	3,0924	1,0916	2,6378	0,6541	1,0359	13,9441	15,9285	1,9844	-45,3800	-0,0437	1,9155	-0,0422

Bomba 45 Hz		Sundaresan-Krishnaswamy												
Abertura inicial	Abertura final	t	t1 (min)	t2(min)	td	T	Pi(psi)	Pf(psi)	Bu	M	Kp	S	S*	
45	39,98	1,8091	0,6386	1,5432	0,3827	0,6061	37,1616	37,6017	0,4401	-5,0200	-0,0877	0,7262	-0,1447	
86,87	43,14	2,2419	0,7914	1,9124	0,4742	0,7510	31,7243	37,1587	5,4343	-43,7300	-0,1243	7,2357	-0,1655	
70	30	3,1856	1,1245	2,7173	0,6739	1,0672	33,0149	41,6811	8,6662	-40,0000	-0,2167	8,1206	-0,2030	
91,06	80	2,9001	1,0237	2,4737	0,6134	0,9715	31,7982	32,2584	0,4603	-11,0600	-0,0416	0,4738	-0,0428	
86,93	57,97	5,4387	1,9199	4,6392	1,1504	1,8220	31,9038	35,0586	3,1548	-28,9600	-0,1089	1,7315	-0,0598	
90,27	54,99	4,0603	1,4333	3,4634	0,8589	1,3602	32,0714	35,2660	3,1946	-35,2800	-0,0905	2,3486	-0,0666	
40,18	94,48	3,2583	1,1502	2,7793	0,6892	1,0915	39,0285	32,2252	-6,8033	54,3000	-0,1253	-6,2328	-0,1148	
62,2	85,3	6,5476	2,3113	5,5851	1,3850	2,1935	34,1215	32,3100	-1,8115	23,1000	-0,0784	-0,8259	-0,0358	
35,1	51,32	7,4779	2,6397	6,3786	1,5818	2,5051	39,8820	36,1428	-3,7392	16,2200	-0,2305	-1,4926	-0,0920	
41,73	49,1	6,1456	2,1694	5,2422	1,3000	2,0588	38,3598	36,2302	-2,1296	7,3700	-0,2890	-1,0344	-0,1404	
35	39,98	0,8213	0,2899	0,7006	0,1737	0,2751	41,1401	39,3389	-1,8012	4,9800	-0,3617	-6,5464	-1,3145	
86,87	43,14	1,0276	0,3627	0,8766	0,2174	0,3443	33,2210	38,0874	4,8664	-43,7300	-0,1113	14,1360	-0,3233	
70	30	1,5391	0,5433	1,3128	0,3256	0,5156	33,4170	42,8845	9,4675	-40,0000	-0,2367	18,3624	-0,4591	
91,06	80	1,3297	0,4694	1,1342	0,2813	0,4454	32,7380	33,1341	0,3961	-11,0600	-0,0358	0,8892	-0,0804	
86,93	57,97	1,7764	0,6271	1,5153	0,3758	0,5951	32,7358	35,9218	3,1860	-28,9600	-0,1100	5,3539	-0,1849	
90,27	54,99	1,7620	0,6220	1,5030	0,3727	0,5903	32,8867	35,6406	2,7539	-35,2800	-0,0781	4,6654	-0,1322	
40,18	94,48	2,7293	0,9634	2,3281	0,5773	0,9143	39,0396	32,1894	-6,8502	54,3000	-0,1262	-7,4923	-0,1380	
62,2	85,3	2,1670	0,7650	1,8485	0,4584	0,7259	34,7195	33,0309	-1,6887	23,1000	-0,0731	-2,3262	-0,1007	
35,1	51,32	1,8457	0,6515	1,5744	0,3904	0,6183	40,5948	36,2204	-4,3744	16,2200	-0,2697	-7,0748	-0,4362	
41,73	49,1	2,4716	0,8725	2,1083	0,5228	0,8280	38,5909	35,8592	-2,7317	7,3700	-0,3707	-3,2992	-0,4477	
45	39,98	0,7260	0,2563	0,6193	0,1536	0,2432	37,7379	38,3005	0,5626	-5,0200	-0,1121	2,3131	-0,4608	
86,87	43,14	1,9998	0,7059	1,7058	0,4230	0,6699	32,2686	38,2268	5,9582	-43,7300	-0,1362	8,8939	-0,2034	
70	30	1,5408	0,5439	1,3143	0,3259	0,5162	33,4013	42,3926	8,9913	-40,0000	-0,2248	17,4192	-0,4355	
91,06	80	1,1551	0,4077	0,9853	0,2443	0,3869	32,7255	33,2583	0,5329	-11,0600	-0,0482	1,3772	-0,1245	
86,93	57,97	1,4855	0,5244	1,2671	0,3142	0,4976	32,8929	35,5483	2,6554	-28,9600	-0,0917	5,3359	-0,1843	
90,27	54,99	1,7073	0,6027	1,4563	0,3611	0,5719	32,8856	35,7812	2,8956	-35,2800	-0,0821	5,0629	-0,1435	
40,18	94,48	3,9327	1,3882	3,3546	0,8319	1,3175	39,1798	32,1322	-7,0477	54,3000	-0,1298	-5,3495	-0,0985	
62,2	85,3	5,3715	1,8961	4,5819	1,1362	1,7994	34,5361	32,9231	-1,6130	23,1000	-0,0698	-0,8964	-0,0388	
35,1	51,32	7,8217	2,7611	6,6719	1,6545	2,6203	40,8691	36,6047	-4,2644	16,2200	-0,2629	-1,6275	-0,1003	
41,73	49,1	5,2955	1,8693	4,5170	1,1202	1,7740	37,9457	36,3852	-1,5606	7,3700	-0,2117	-0,8797	-0,1194	

Bomba 45 Hz		Sundaresan-Krishnaswamy												
Abertura inicial	Abertura final	t	t1 (min)	t2(min)	td	T	Pi(psi)	Pf(psi)	Bu	M	Kp	S	S*	
50	54,99	0,6266	0,2212	0,5345	0,1325	0,2099	36,1346	34,6632	-1,4714	4,9900	-0,2949	-7,0094	-1,4047	
49,1	57,97	0,5432	0,1917	0,4633	0,1149	0,1820	36,1336	34,2852	-1,8484	8,8700	-0,2084	-10,1583	-1,1452	
94,48	86,93	0,6668	0,2354	0,5688	0,1410	0,2234	31,8552	32,3355	0,4802	-7,5500	-0,0636	2,1499	-0,2848	
90,27	30	0,9487	0,3349	0,8093	0,2007	0,3178	32,0471	41,4654	9,4183	-60,2700	-0,1563	29,6341	-0,4917	
41,73	91,06	1,1945	0,4217	1,0189	0,2527	0,4002	37,6025	31,9730	-5,6295	49,3300	-0,1141	-14,0683	-0,2852	
40,18	43,14	0,9384	0,3313	0,8005	0,1985	0,3144	37,8719	37,1275	-0,7444	2,9600	-0,2515	-2,3680	-0,8000	
51,32	80	1,7587	0,6208	1,5002	0,3720	0,5892	35,9222	32,6493	-3,2729	28,6800	-0,1141	-5,5552	-0,1937	
70	35,1	7,3738	2,6030	6,2899	1,5598	2,4702	33,2090	39,9832	6,7742	-34,9000	-0,1941	2,7423	-0,0786	
62,2	39,98	2,5500	0,9002	2,1752	0,5394	0,8543	33,9721	38,6116	4,6395	-22,2200	-0,2088	5,4310	-0,2444	
85,3	86,87	3,0852	1,0891	2,6316	0,6526	1,0335	32,1166	32,0981	-0,0185	1,5700	-0,0118	-0,0179	-0,0114	
30	86,87	1,2151	0,4289	1,0365	0,2570	0,4071	41,9478	32,0817	-9,8661	56,8700	-0,1735	-24,2370	-0,4262	
85,3	39,98	0,9686	0,3419	0,8262	0,2049	0,3245	31,9839	38,0629	6,0790	-45,3200	-0,1341	18,7342	-0,4134	
62,2	70	2,9789	1,0515	2,5410	0,6301	0,9979	34,0349	33,4949	-0,5400	7,8000	-0,0692	-0,5411	-0,0694	
35,1	80	1,5996	0,5647	1,3645	0,3384	0,5359	39,8699	33,0798	-6,7902	44,9000	-0,1512	-12,6714	-0,2822	
51,32	43,14	2,2146	0,7818	1,8891	0,4685	0,7419	35,4003	38,0927	2,6924	-8,1800	-0,3291	3,6291	-0,4437	
40,18	91,06	5,2164	1,8414	4,4495	1,1034	1,7475	38,0599	32,3875	-5,6725	50,8800	-0,1115	-3,2461	-0,0638	
41,73	30	1,3312	0,4699	1,1355	0,2816	0,4460	37,9762	42,0105	4,0343	-11,7300	-0,3439	9,0465	-0,7712	
90,27	86,93	3,5048	1,2372	2,9896	0,7414	1,1741	32,1131	32,0423	-0,0709	-3,3400	0,0212	-0,0604	0,0181	
94,48	57,97	3,3335	1,1767	2,8434	0,7051	1,1167	31,9930	34,7141	2,7211	-36,5100	-0,0745	2,4367	-0,0667	
49,1	54,99	8,2745	2,9209	7,0581	1,7503	2,7720	36,3872	34,9370	-1,4501	5,8900	-0,2462	-0,5231	-0,0888	
30	86,87	1,1230	0,3964	0,9579	0,2375	0,3762	41,2118	32,3078	-8,9039	56,8700	-0,1566	-23,6684	-0,4162	
39	70	1,0847	0,3829	0,9253	0,2295	0,3634	37,4968	32,9559	-4,5409	31,0000	-0,1465	-12,4960	-0,4031	
80	43,14	1,8778	0,6629	1,6018	0,3972	0,6291	32,6983	37,6085	4,9103	-36,8600	-0,1332	7,8056	-0,2118	
91,06	30	5,0603	1,7863	4,3164	1,0704	1,6952	31,7419	41,3458	9,6039	-61,0600	-0,1573	5,6653	-0,0928	
86,93	57,97	2,6383	0,9313	2,2505	0,5581	0,8838	32,0066	34,6835	2,6769	-28,9600	-0,0924	3,0288	-0,1046	
54,99	85,3	2,7904	0,9850	2,3802	0,5903	0,9348	34,9345	32,2655	-2,6690	30,3100	-0,0881	-2,8552	-0,0942	
62,2	35,1	2,3017	0,8125	1,9633	0,4869	0,7711	34,0911	39,8799	5,7889	-27,1000	-0,2136	7,5077	-0,2770	
51,32	40,18	2,4115	0,8512	2,0570	0,5101	0,8078	35,3594	38,1256	2,7662	-11,1400	-0,2483	3,4242	-0,3074	
41,73	90,27	3,0006	1,0592	2,5595	0,6347	1,0052	37,3747	32,1826	-5,1922	48,5400	-0,1070	-5,1653	-0,1064	
94,48	49,1	5,0798	1,7932	4,3330	1,0745	1,7017	32,1690	36,1457	3,9767	-45,3800	-0,0876	2,3369	-0,0515	

Bomba 45 Hz		Sundaresan-Krishnaswamy												
Abertura inicial	Abertura final	t	t1 (min)	t2(min)	td	T	Pi(psi)	Pf(psi)	Bu	M	Kp	S	S*	
45	39,98	1,5063	0,5317	1,2849	0,3186	0,5046	37,1520	39,0025	1,8505	-5,0200	-0,3686	3,6672	-0,7305	
86,87	43,14	1,2393	0,4375	1,0571	0,2621	0,4152	33,0263	38,5162	5,4898	-43,7300	-0,1255	13,2232	-0,3024	
70	30	3,5716	1,2608	3,0465	0,7555	1,1965	33,3073	43,0174	9,7101	-40,0000	-0,2428	8,1155	-0,2029	
91,06	80	2,9682	1,0478	2,5319	0,6279	0,9944	32,6910	33,4254	0,7344	-11,0600	-0,0664	0,7386	-0,0668	
86,93	57,97	6,3098	2,2273	5,3822	1,3347	2,1138	32,7767	35,7118	2,9351	-28,9600	-0,1014	1,3886	-0,0479	
90,27	54,99	2,5699	0,9072	2,1921	0,5436	0,8609	33,0826	35,4151	2,3324	-35,2800	-0,0661	2,7092	-0,0768	
40,18	94,48	2,8719	1,0138	2,4497	0,6075	0,9621	38,8713	33,2182	-5,6531	54,3000	-0,1041	-5,8759	-0,1082	
62,2	85,3	1,5463	0,5458	1,3190	0,3271	0,5180	34,5888	32,5278	-2,0609	23,1000	-0,0892	-3,9787	-0,1722	
35,1	51,32	2,6525	0,9363	2,2626	0,5611	0,8886	41,2865	36,3561	-4,9303	16,2200	-0,3040	-5,5486	-0,3421	
45	39,98	1,2635	0,4460	1,0778	0,2673	0,4233	37,7844	39,8603	2,0759	-5,0200	-0,4135	4,9044	-0,9770	
86,87	43,14	1,2633	0,4459	1,0776	0,2672	0,4232	33,2698	38,1052	4,8354	-43,7300	-0,1106	11,4261	-0,2613	
70	30	2,5031	0,8836	2,1352	0,5295	0,8385	33,2239	43,6450	10,4212	-40,0000	-0,2605	12,4277	-0,3107	
91,06	80	1,5702	0,5543	1,3394	0,3321	0,5260	32,3805	33,2675	0,8870	-11,0600	-0,0802	1,6863	-0,1525	
86,93	57,97	1,8105	0,6391	1,5444	0,3830	0,6065	32,9541	35,3754	2,4213	-28,9600	-0,0836	3,9921	-0,1378	
90,27	54,99	1,4272	0,5038	1,2174	0,3019	0,4781	33,3386	36,6306	3,2920	-35,2800	-0,0933	6,8857	-0,1952	
40,18	94,48	2,7252	0,9620	2,3246	0,5765	0,9129	39,3860	32,7139	-6,6721	54,3000	-0,1229	-7,3084	-0,1346	
62,2	85,3	2,0358	0,7186	1,7365	0,4306	0,6820	34,9360	33,3018	-1,6342	23,1000	-0,0707	-2,3963	-0,1037	
35,1	51,32	1,8434	0,6507	1,5724	0,3899	0,6175	40,6153	36,3440	-4,2713	16,2200	-0,2633	-6,9167	-0,4264	
41,73	49,1	16,6620	5,8817	14,2127	3,5245	5,5818	38,3449	36,9846	-1,3603	7,3700	-0,1846	-0,2437	-0,0331	
45	39,98	1,7049	0,6018	1,4543	0,3606	0,5711	38,1133	39,0406	0,9273	-5,0200	-0,1847	1,6235	-0,3234	
86,87	43,14	1,1718	0,4137	0,9996	0,2479	0,3926	32,8325	38,2091	5,3766	-43,7300	-0,1229	13,6960	-0,3132	
70	30	2,2914	0,8089	1,9546	0,4847	0,7676	33,6375	42,1809	8,5434	-40,0000	-0,2136	11,1296	-0,2782	
91,06	80	1,9840	0,7004	1,6924	0,4197	0,6646	32,6512	32,8695	0,2183	-11,0600	-0,0197	0,3284	-0,0297	
86,93	57,97	1,3222	0,4667	1,1278	0,2797	0,4	33,2884	35,5316	2,2432	-28,9600	-0,0775	5,0644	-0,1749	
90,27	54,99	-2,2787	-0,8044	-1,9437	-0,4820	-0,7634	32,2516	35,6000	3,3484	-35,2800	-0,0949	-4,3864	0,1243	
40,18	94,48	1,9180	0,6771	1,6361	0,4057	0,6425	38,8266	32,0844	-6,7422	54,3000	-0,1242	-10,4932	-0,1932	
62,2	85,3	2,8330	1,0000	2,4165	0,5993	0,9490	34,9849	33,0108	-1,9741	23,1000	-0,0855	-2,0801	-0,0900	
35,1	51,32	2,0792	0,7340	1,7736	0,4398	0,6965	40,7734	35,9001	-4,8733	16,2200	-0,3004	-6,9964	-0,4313	
41,73	49,1	7,6172	2,6889	6,4975	1,6113	2,5518	38,8296	36,8719	-1,9578	7,3700	-0,2656	-0,7672	-0,1041	

Bomba 60 Hz		Sundaresan-Krishnaswamy											
Abertura inicial	Abertura final	t	t1 (min)	t2(min)	td	T	Pi(psi)	Pf(psi)	Bu	M	Kp	S	S*
35	39,98	1,0074	0,3556	0,8593	0,2131	0,3375	69,4351	67,3380	-2,0971	4,9800	-0,4211	-6,2140	-1,2478
86,87	43,14	1,1086	0,3913	0,9456	0,2345	0,3714	57,3444	66,2934	8,9490	-43,7300	-0,2046	24,0968	-0,5510
70	30	1,9084	0,6737	1,6278	0,4037	0,6393	59,2886	72,7708	13,4823	-40,0000	-0,3371	21,0888	-0,5272
91,06	80	1,6379	0,5782	1,3971	0,3465	0,5487	57,3309	57,8241	0,4932	-11,0600	-0,0446	0,8988	-0,0813
86,93	57,97	1,9038	0,6720	1,6239	0,4027	0,6378	57,2952	61,7069	4,4118	-28,9600	-0,1523	6,9175	-0,2389
90,27	54,99	2,2389	0,7903	1,9097	0,4736	0,7500	56,6561	62,0942	5,4382	-35,2800	-0,1541	7,2507	-0,2055
40,18	94,48	2,0009	0,7063	1,7067	0,4232	0,6703	68,1475	56,6952	-11,4524	54,3000	-0,2109	-17,0858	-0,3147
62,2	85,3	2,3602	0,8332	2,0133	0,4993	0,7907	60,5891	57,5882	-3,0009	23,1000	-0,1299	-3,7953	-0,1643
35,1	51,32	1,6664	0,5882	1,4214	0,3525	0,5582	69,3717	63,7275	-5,6442	16,2200	-0,3480	-10,1107	-0,6233
41,73	49,1	1,6291	0,5751	1,3896	0,3446	0,5458	66,8659	64,2960	-2,5699	7,3700	-0,3487	-4,7088	-0,6389
35	39,98	1,2234	0,4319	1,0435	0,2588	0,4098	68,9906	66,4424	-2,5482	4,9800	-0,5117	-6,2178	-1,2485
86,87	43,14	1,2549	0,4430	1,0704	0,2654	0,4204	56,8989	65,0255	8,1267	-43,7300	-0,1858	19,3319	-0,4421
70	30	1,3732	0,4847	1,1713	0,2905	0,4600	58,0846	72,2419	14,1572	-40,0000	-0,3539	30,7751	-0,7694
91,06	80	1,0825	0,3821	0,9233	0,2290	0,3626	56,2404	57,9479	1,7075	-11,0600	-0,1544	4,7086	-0,4257
86,93	57,97	2,1541	0,7604	1,8375	0,4557	0,7216	57,1287	61,1468	4,0181	-28,9600	-0,1387	5,5681	-0,1923
90,27	54,99	1,3512	0,4770	1,1526	0,2858	0,4527	56,6967	61,9867	5,2900	-35,2800	-0,1499	11,6864	-0,3312
40,18	94,48	1,3646	0,4817	1,1640	0,2886	0,4571	66,6226	56,4758	-10,1468	54,3000	-0,1869	-22,1969	-0,4088
62,2	85,3	2,6687	0,9420	2,2764	0,5645	0,8940	60,1059	57,2235	-2,8825	23,1000	-0,1248	-3,2242	-0,1396
35,3	51,32	1,1458	0,4045	0,9774	0,2424	0,3838	69,5751	62,7682	-6,8069	16,0200	-0,4249	-17,7335	-1,1070
41,73	49,1	1,1875	0,4192	1,0129	0,2512	0,3978	66,4504	63,9657	-2,4847	7,3700	-0,3371	-6,2458	-0,8475
35	39,98	1,3224	0,4668	1,1280	0,2797	0,4430	68,7021	66,1522	-2,5499	4,9800	-0,5120	-5,7560	-1,1558
86,87	43,14	0,7867	0,2777	0,6710	0,1664	0,2635	56,3918	65,2038	8,8120	-43,7300	-0,2015	33,4385	-0,7647
70	30	1,3510	0,4769	1,1524	0,2858	0,4526	58,2219	72,6002	14,3784	-40,0000	-0,3595	31,7685	-0,7942
91,06	80	1,0568	0,3730	0,9014	0,2235	0,3540	56,1531	57,5805	1,4274	-11,0600	-0,1291	4,0320	-0,3646
86,93	57,97	1,1669	0,4119	0,9954	0,2468	0,3909	56,6969	61,0642	4,3673	-28,9600	-0,1508	11,1718	-0,3858
90,27	54,99	1,1196	0,3952	0,9551	0,2368	0,3751	56,5878	61,6284	5,0405	-35,2800	-0,1429	13,4386	-0,3809
40,18	94,48	1,1768	0,4154	1,0038	0,2489	0,3942	66,0189	56,1810	-9,8379	54,3000	-0,1812	-24,9552	-0,4596
62,2	85,3	1,3878	0,4899	1,1838	0,2936	0,4649	60,0641	57,3268	-2,7372	23,1000	-0,1185	-5,8876	-0,2549
35,1	51,32	1,3073	0,4615	1,1151	0,2765	0,4379	69,4247	61,9185	-7,5062	16,2200	-0,4628	-17,1399	-1,0567
41,73	49,1	1,1190	0,3950	0,9545	0,2367	0,3749	65,4804	62,9829	-2,4975	7,3700	-0,3389	-6,6626	-0,9040

Bomba 60 Hz		Sundaresan-Krishnaswamy											
Abertura inicial	Abertura final	t	t1 (min)	t2(min)	td	T	Pi(psi)	Pf(psi)	Bu	M	Kp	S	S*
30	39,98	0,9212	0,3252	0,7858	0,1949	0,3086	71,0359	66,0454	-4,9905	9,9800	-0,5001	-16,1719	-1,6204
86,87	43,14	2,1682	0,7654	1,8495	0,4586	0,7264	56,4554	65,0749	8,6196	-43,7300	-0,1971	11,8668	-0,2714
70	91,06	1,1533	0,4071	0,9837	0,2440	0,3863	58,4780	56,0155	-2,4625	21,0600	-0,1169	-6,3738	-0,3026
80	62,2	1,9285	0,6808	1,6450	0,4079	0,6460	57,3306	59,5880	2,2573	-17,8000	-0,1268	3,4941	-0,1963
49,1	94,48	3,0333	1,0707	2,5874	0,6416	1,0161	62,9647	55,4754	-7,4893	45,3800	-0,1650	-7,3703	-0,1624
40,18	54,99	5,4095	1,9095	4,6143	1,1443	1,8122	66,6592	61,2286	-5,4307	14,8100	-0,3667	-2,9968	-0,2023
90,27	57,97	3,2405	1,1439	2,7641	0,6855	1,0856	56,1528	60,9254	4,7725	-32,3000	-0,1478	4,3964	-0,1361
86,93	85,3	1,8738	0,6615	1,5984	0,3964	0,6277	55,9240	56,4100	0,4860	-1,6300	-0,2982	0,7743	-0,4750
35,1	51,32	3,4451	1,2161	2,9387	0,7288	1,1541	68,9245	62,4849	-6,4396	16,2200	-0,3970	-5,5797	-0,3440
35	39,98	1,2176	0,4298	1,0386	0,2576	0,4079	69,5956	66,9032	-2,6925	4,9800	-0,5407	-6,6007	-1,3254
86,87	43,14	0,9354	0,3302	0,7979	0,1979	0,3134	57,1483	65,5482	8,4000	-43,7300	-0,1921	26,8056	-0,6130
70	30	2,2530	0,7953	1,9218	0,4766	0,7547	58,7422	72,4969	13,7547	-40,0000	-0,3439	18,2245	-0,4556
91,06	80	0,9304	0,3284	0,7937	0,1968	0,3117	56,2364	57,8611	1,6247	-11,0600	-0,1469	5,2125	-0,4713
86,93	57,97	2,1099	0,7448	1,7997	0,4463	0,7068	57,0473	61,2847	4,2374	-28,9600	-0,1463	5,9952	-0,2070
90,27	54,99	1,2559	0,4433	1,0713	0,2657	0,4207	56,0639	61,4656	5,4017	-35,2800	-0,1531	12,8387	-0,3639
40,18	94,48	1,5679	0,5535	1,3374	0,3316	0,5252	67,4226	57,2939	-10,1287	54,3000	-0,1865	-19,2843	-0,3551
62,2	85,3	1,6117	0,5689	1,3748	0,3409	0,5399	60,6729	57,3824	-3,2905	23,1000	-0,1424	-6,0946	-0,2638
35,1	51,32	1,5104	0,5332	1,2884	0,3195	0,5060	69,5675	62,6702	-6,8973	16,2200	-0,4252	-13,6316	-0,8404
41,73	49,1	2,2552	0,7961	1,9237	0,4770	0,7555	66,4093	63,6076	-2,8017	7,3700	-0,3801	-3,7085	-0,5032
60	86,87	0,4875	0,1721	0,4158	0,1031	0,1633	61,3855	56,7532	-4,6323	26,8700	-0,1724	-28,3660	-1,0557
39,98	70	0,6583	0,2324	0,5615	0,1393	0,2205	67,0885	58,9191	-8,1693	30,0200	-0,2721	-37,0441	-1,2340
80	43,14	0,8351	0,2948	0,7123	0,1766	0,2797	57,9489	65,5161	7,5671	-36,8600	-0,2053	27,0504	-0,7339
91,06	30	1,1676	0,4122	0,9959	0,2470	0,3911	57,0903	72,4739	15,3837	-61,0600	-0,2519	39,3307	-0,6441
86,93	57,97	1,1422	0,4032	0,9743	0,2416	0,3826	57,0020	61,4021	4,4001	-28,9600	-0,1519	11,4994	-0,3971
40,18	54,99	1,0978	0,3875	0,9364	0,2322	0,3678	67,0059	62,1805	-4,8254	14,8100	-0,3258	-13,1213	-0,8860
94,48	49,1	1,3240	0,4674	1,1294	0,2801	0,4436	56,6716	64,6021	7,9305	-45,3800	-0,1748	17,8795	-0,3940
90,27	41,73	1,4725	0,5198	1,2560	0,3115	0,4933	56,8669	66,7591	9,8923	-48,5400	-0,2038	20,0539	-0,4131
62,2	35,1	1,3041	0,4603	1,1124	0,2758	0,4369	60,2157	69,4721	9,2564	-27,1000	-0,3416	21,1885	-0,7819
85,3	51,32	3,3014	1,1654	2,8161	0,6983	1,1060	57,6696	62,5696	4,8999	-33,9800	-0,1442	4,4304	-0,1304

Bomba 60 Hz		Sundaresan-Krishnaswamy												
Abertura inicial	Abertura final	t	t1 (min)	t2(min)	td	T	Pi(psi)	Pf(psi)	Bu	M	Kp	S	S*	
40	85,3	0,8851	0,3124	0,7550	0,1872	0,2965	66,1505	56,1669	-9,9836	45,3000	-0,2204	-33,6717	-0,7433	
62,2	35,1	0,8204	0,2896	0,6998	0,1735	0,2748	59,3504	69,2621	9,9117	-27,1000	-0,3657	36,0650	-1,3308	
51,32	40,18	2,9416	1,0384	2,5092	0,6222	0,9854	61,9385	65,9996	4,0611	-11,1400	-0,3645	4,1211	-0,3699	
49,1	90,27	1,0446	0,3687	0,8910	0,2210	0,3499	62,8602	56,8669	-5,9933	41,1700	-0,1456	-17,1268	-0,4160	
41,73	94,48	1,4126	0,4986	1,2049	0,2988	0,4732	65,4899	56,5303	-8,9596	52,7500	-0,1699	-18,9338	-0,3589	
54,99	86,93	0,9151	0,3230	0,7805	0,1936	0,3065	61,4265	56,3401	-5,0864	31,9400	-0,1592	-16,5928	-0,5195	
57,97	30	1,7155	0,6056	1,4633	0,3629	0,5747	60,8186	72,2313	11,4126	-27,9700	-0,4080	19,8592	-0,7100	
91,06	43,14	1,8462	0,6517	1,5748	0,3905	0,6185	56,4171	65,1341	8,7170	-47,9200	-0,1819	14,0947	-0,2941	
80	39,98	2,8074	0,9910	2,3947	0,5939	0,9405	56,9062	66,8572	9,9511	-40,0200	-0,2487	10,5808	-0,2644	
70	86,87	4,8509	1,7124	4,1379	1,0261	1,6251	58,2659	56,7635	-1,5023	16,8700	-0,0891	-0,9245	-0,0548	
45	86,87	1,0576	0,3733	0,9022	0,2237	0,3543	64,0099	56,2364	-7,7735	41,8700	-0,1857	-21,9400	-0,5240	
39,98	70	54,1710	19,1224	46,2079	11,4588	18,1473	65,9408	57,8350	-8,1058	30,0200	-0,2700	-0,4467	-0,0149	
80	43,14	7,5710	2,6726	6,4581	1,6015	2,5363	56,8630	64,4340	7,5710	-36,8600	-0,2054	2,9851	-0,0810	
91,06	30	15,8972	5,6117	13,5603	3,3627	5,3256	55,5565	71,4537	15,8972	-61,0600	-0,2604	2,9851	-0,0489	
86,93	57,97	3,7853	1,3362	3,2289	0,8007	1,2681	56,6196	60,4050	3,7853	-28,9600	-0,1307	2,9851	-0,1031	
85,3	54,99	4,0517	1,4302	3,4561	0,8571	1,3573	56,8990	60,9507	4,0517	-30,3100	-0,1337	2,9851	-0,0985	
62,2	35,1	8,6848	3,0657	7,4081	1,8371	2,9094	59,9011	68,5859	8,6848	-27,1000	-0,3205	2,9851	-0,1102	
51,32	40,18	4,7034	1,6603	4,0120	0,9949	1,5756	62,0159	66,7193	4,7034	-11,1400	-0,4222	2,9851	-0,2680	
90,27	41,73	9,3841	3,3126	8,0047	1,9850	3,1437	55,7767	65,1608	9,3841	-48,5400	-0,1933	2,9851	-0,0615	
94,48	49,1	7,1804	2,5347	6,1249	1,5189	2,4054	55,5958	62,7763	7,1804	-45,3800	-0,1582	2,9851	-0,0658	
35	62,2	1,7026	0,6010	1,4523	0,3601	0,5704	65,4899	57,5288	-7,9611	27,2000	-0,2927	-13,9582	-0,5132	
80	49,1	1,1955	0,4220	1,0197	0,2529	0,4005	55,9047	60,8786	4,9739	-30,9000	-0,1610	12,4200	-0,4019	
94,48	30	1,6852	0,5949	1,4375	0,3565	0,5645	54,5762	69,2799	14,7038	-64,4800	-0,2280	26,0454	-0,4039	
91,06	40,18	1,5167	0,5354	1,2937	0,3208	0,5081	55,1029	64,5366	9,4337	-50,8800	-0,1854	18,5668	-0,3649	
70	54,99	3,2007	1,1299	2,7302	0,6771	1,0722	56,6798	59,8805	3,2007	-15,0100	-0,2132	2,9851	-0,1989	
41,73	90,27	-8,8955	-3,1401	-7,5879	-1,8817	-2,9800	64,1478	55,2523	-8,8955	48,5400	-0,1833	2,9851	0,0615	
51,32	43,14	3,0311	1,0700	2,5855	0,6412	1,0154	61,0012	64,0323	3,0311	-8,1800	-0,3705	2,9851	-0,3649	
35,1	85,3	-11,6803	-4,1231	-9,9633	-2,4707	-3,9129	67,3607	55,6804	-11,6803	50,2000	-0,2327	2,9851	0,0595	
57,97	86,93	-4,0753	-1,4386	-3,4763	-0,8621	-1,3652	59,7589	55,6836	-4,0753	28,9600	-0,1407	2,9851	0,1031	
39,98	86,87	-9,3304	-3,2936	-7,9588	-1,9737	-3,1257	65,4961	56,1657	-9,3304	46,8900	-0,1990	2,9851	0,0637	

Anexo F – Parâmetros calculados pelos métodos de Ziegler-Nichols e Cohen-Coon.

Quadro 5 - Para kick de gás.

Permeabilidade 40%	Ziegler-Nichols		Cohen-Coon	
Abertura choke	Kc	Ti	Kc	Ti
95	0,04	2,85	0,03	1,26
55	0,04	2,84	0,03	1,26
25	0,04	2,88	0,03	1,27
Permeabilidade 50%	Ziegler-Nichols		Cohen-Coon	
Abertura choke	Kc	Ti	Kc	Ti
95	0,04	2,89	0,03	1,28
55	0,04	2,98	0,04	1,32
25	0,04	2,95	0,03	1,31
Permeabilidade 60%	Ziegler-Nichols		Cohen-Coon	
Abertura choke	Kc	Ti	Kc	Ti
95	0,05	2,89	0,04	1,28
55	0,05	2,94	0,04	1,30
25	0,05	2,86	0,04	1,27

Quadro 6 - Para perda de circulação.

Permeabilidade 40%	Ziegler-Nichols		Cohen-Coon	
Abertura choke	Kc	Ti	Kc	Ti
95	-0,26	2,93	-0,21	1,30
55	-0,26	2,82	-0,20	1,25
25	-0,30	2,84	-0,23	1,26
Permeabilidade 50%	Ziegler-Nichols		Cohen-Coon	
Abertura choke	Kc	Ti	Kc	Ti
95	-0,27	2,84	-0,21	1,26
55	-0,22	2,90	-0,18	1,28
25	-0,18	2,83	-0,14	1,25
Permeabilidade 60%	Ziegler-Nichols		Cohen-Coon	
Abertura choke	Kc	Ti	Kc	Ti
95	-0,21	2,91	-0,17	1,29
55	-0,23	2,84	-0,18	1,26
25	-0,18	2,82	-0,14	1,25

Quadro 7 - Para variação de vazão.

<i>Choke 95%</i>		<i>Ziegler - Nichols</i>		<i>Cohen-Coon</i>	
Bomba de água (Hz)	Bomba de lama (Hz)	Kc	Ti	Kc	Ti
30	40	1,40	2,82	1,06	1,25
40	50	1,15	2,82	0,87	1,25
50	60	1,04	2,82	0,79	1,25
60	50	1,03	2,82	0,78	1,25
50	40	1,05	2,83	0,80	1,25
40	30	1,39	3,11	1,32	1,38
<i>Choke 55%</i>		<i>Ziegler - Nichols</i>		<i>Cohen-Coon</i>	
Bomba de água (Hz)	Bomba de lama (Hz)	Kc	Ti	Kc	Ti
30	40	1,27	2,83	0,97	1,25
40	50	1,05	2,83	0,81	1,25
50	60	0,97	2,81	0,73	1,24
60	50	0,98	2,81	0,74	1,24
50	40	1,05	2,82	0,80	1,25
40	30	1,26	3,06	1,14	1,35
<i>Choke 25%</i>		<i>Ziegler - Nichols</i>		<i>Cohen-Coon</i>	
Bomba de água (Hz)	Bomba de lama (Hz)	Kc	Ti	Kc	Ti
30	40	1,08	2,82	0,82	1,25
40	50	0,92	2,82	0,70	1,25
50	60	0,86	2,81	0,65	1,25
60	50	0,89	2,82	0,67	1,25
50	40	0,91	2,82	0,69	1,25
40	30	1,06	2,83	0,81	1,26

Quadro 8 - Para variação do índice de abertura da válvula *choke*.

Bomba 30 Hz		Ziegler-Nichols		Cohen-Coon	
Abertura inicial	Abertura final	Kc	Ti	Kc	Ti
35	39,98	-12,81	4,28	-22,35	1,89
86,87	43,14	-25,61	2,08	-10,59	0,92
70	30	-14,22	4,30	-25,04	1,90
91,06	80	-120,84	2,31	-61,67	1,02
86,93	57,97	-33,58	4,23	-57,28	1,87
90,27	54,99	-36,39	3,68	-46,97	1,63
40,18	94,48	-25,14	4,76	-54,34	2,11
85,3	62,2	34,12	4,96	80,26	2,20
35,1	51,32	-11,15	6,47	-44,56	2,86
41,73	49,1	-14,10	4,77	-30,67	2,11
75	40,18	-20,17	0,69	-0,93	0,31
51,32	35,1	-12,20	0,78	-0,70	0,34
62,2	85,3	-40,92	0,81	-2,54	0,36
49,1	94,48	-28,18	0,77	-1,58	0,34
41,73	90,27	-24,39	0,79	-1,44	0,35
54,99	86,93	-26,84	0,89	-2,03	0,39
57,97	30	-11,59	1,91	-4,05	0,85
91,06	43,14	-23,94	0,81	-1,51	0,36
80	39,98	-19,88	1,42	-3,81	0,63
70	87	-28,79	3,06	-25,75	1,36
65	39,98	-19,56	1,45	-3,90	0,64
86,87	43,14	-27,93	1,27	-4,28	0,56
70	30	-13,14	2,03	-5,16	0,90
91,06	80	-71,53	1,60	-17,37	0,71
86,93	57,97	-30,17	2,35	-15,84	1,04
90,27	54,99	-35,85	1,85	-11,68	0,82
40,18	94,48	-25,32	1,62	-6,33	0,72
62,2	85,3	-39,56	1,96	-14,50	0,87
35,1	51,32	-12,39	4,70	-26,15	2,08
41,73	49,1	-8,69	4,67	-18,06	2,07

Quadro 9 - Para variação do índice de abertura da válvula *choke*. (continuação)

Bomba 45 Hz		Ziegler-Nichols		Cohen-Coon	
Abertura inicial	Abertura final	Kc	Ti	Kc	Ti
45	39,98	-16,26	1,27	-2,52	0,56
86,87	43,14	-11,47	1,58	-2,73	0,70
70	30	-6,58	2,24	-3,16	0,99
91,06	80	-34,25	2,04	-13,64	0,90
86,93	57,97	-13,08	3,83	-18,33	1,70
90,27	54,99	-15,74	2,86	-12,29	1,27
40,18	94,48	-11,38	2,30	-5,72	1,02
62,2	85,3	-18,18	4,61	-36,90	2,04
35,1	51,32	-6,18	5,27	-16,37	2,33
41,73	49,1	-4,93	4,33	-8,82	1,92
35	39,98	-3,94	0,58	-0,13	0,26
86,87	43,14	-12,81	0,72	-0,64	0,32
70	30,00	-6,02	1,08	-0,68	0,48
91,06	80,00	-39,80	0,94	-3,33	0,41
86,93	57,97	-12,96	1,25	-1,94	0,55
90,27	54,99	-18,26	1,24	-2,69	0,55
40,18	94,48	-11,30	1,92	-3,99	0,85
62,2	85,30	-19,50	1,53	-4,34	0,68
35,1	51,32	-5,29	1,30	-0,85	0,58
41,73	49,10	-3,85	1,74	-1,11	0,77
45	39,98	-12,72	0,51	-0,32	0,23
86,87	43,14	-10,46	1,41	-1,98	0,62
70	30	-6,34	1,09	-0,71	0,48
91,06	80	-29,58	0,81	-1,87	0,36
86,93	57,97	-15,54	1,05	-1,62	0,46
90,27	54,99	-17,37	1,20	-2,40	0,53
40,18	94,48	-10,98	2,77	-8,04	1,23
62,2	85,3	-20,41	3,78	-27,89	1,68
35,1	51,32	-5,42	5,51	-15,71	2,44
41,73	49,1	-6,73	3,73	-8,94	1,65

Quadro 10 - Para variação do índice de abertura da válvula *choke*. (continuação)

Bomba 60 Hz		Ziegler-Nichols		Cohen-Coon	
Abertura inicial	Abertura final	Kc	Ti	Kc	Ti
30	39,98	-2,85	0,65	-0,11	0,29
86,87	43,14	-7,23	1,53	-1,61	0,68
70	91,06	-12,19	0,81	-0,77	0,36
80	62,2	-11,24	1,36	-1,98	0,60
49,1	94,48	-8,64	2,14	-3,76	0,95
40,18	54,99	-3,89	3,81	-5,39	1,69
90,27	57,97	-9,65	2,28	-4,80	1,01
86,93	85,3	-4,78	1,32	-0,79	0,58
35,1	51,32	-3,59	2,43	-2,02	1,07
35	39,98	-2,64	0,86	-0,19	0,38
86,87	43,14	-7,42	0,66	-0,31	0,29
70	30	-4,14	1,59	-1,00	0,70
91,06	80	-9,70	0,66	-0,40	0,29
86,93	57,97	-9,74	1,49	-2,05	0,66
90,27	54,99	-9,31	0,88	-0,70	0,39
40,18	94,48	-7,64	1,10	-0,89	0,49
62,2	85,3	-10,01	1,14	-1,23	0,50
35,1	51,32	-3,35	1,06	-0,36	0,47
41,73	49,1	-3,75	1,59	-0,90	0,70
60	86,87	-8,27	0,34	-0,09	0,15
39,98	70	-5,24	0,46	-0,11	0,21
80	43,14	-6,94	0,59	-0,23	0,26
91,06	30	-5,66	0,82	-0,37	0,36
86,93	57,97	-9,38	0,80	-0,58	0,36
40,18	54,99	-4,37	0,77	-0,25	0,34
94,48	49,1	-8,16	0,93	-0,68	0,41
90,27	41,73	-6,99	1,04	-0,72	0,46
62,2	35,1	-4,17	0,92	-0,34	0,41
85,3	51,32	-9,88	2,33	-5,10	1,03

Anexo G - Gráficos de controle via rede neuronal – método indireto.

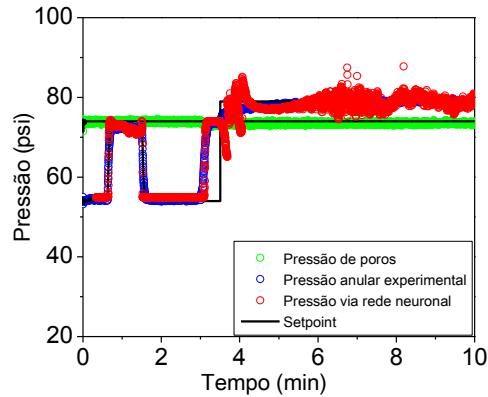


Figura 166 – Kick de gás com 40% de permeabilidade da rocha reservatório.

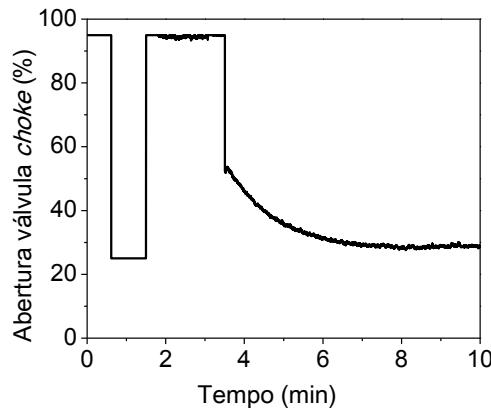


Figura 167 – Resposta da variável manipulada.

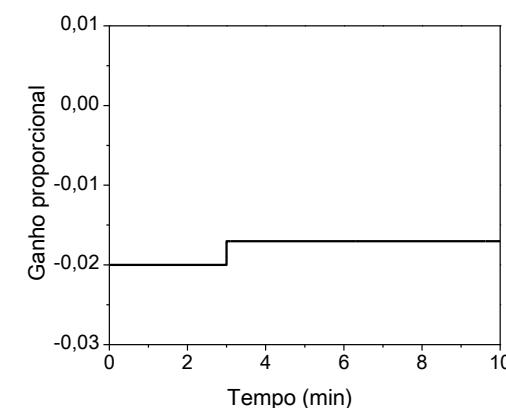


Figura 168 – Gанho do controlador.

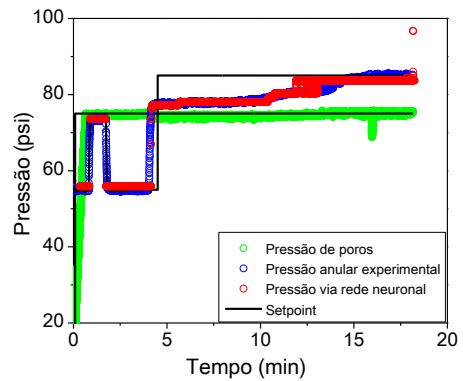


Figura 169 – Kick de gás com 50% de permeabilidade da rocha reservatório.

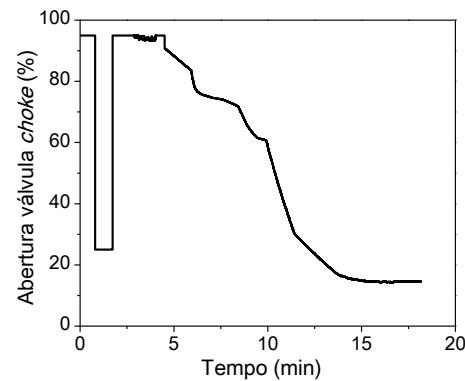


Figura 170 – Resposta da variável manipulada.

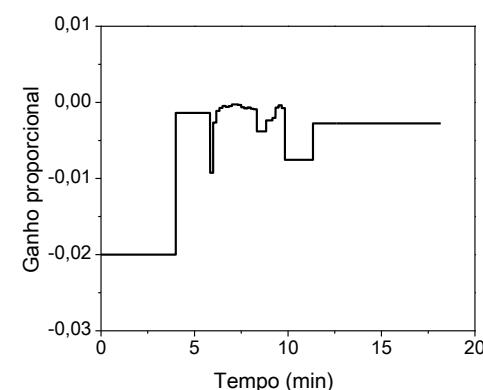


Figura 171 – Gанho do controlador.

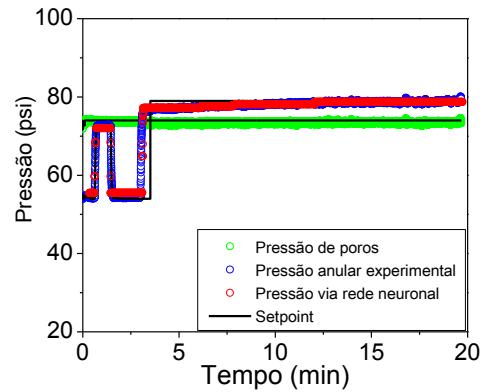


Figura 172 – Kick de gás com 50% de permeabilidade da rocha reservatório.

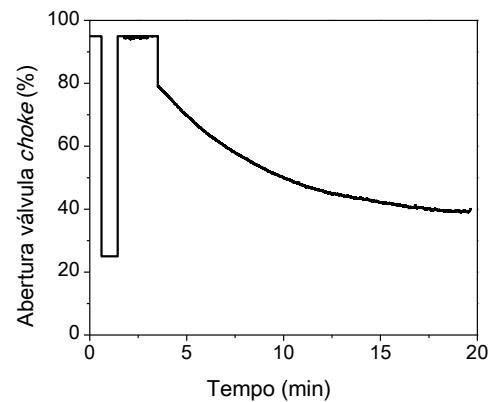


Figura 173 – Resposta da variável manipulada.

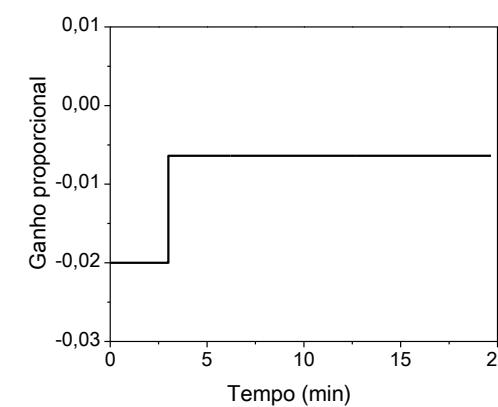


Figura 174 – Ganho do controlador.

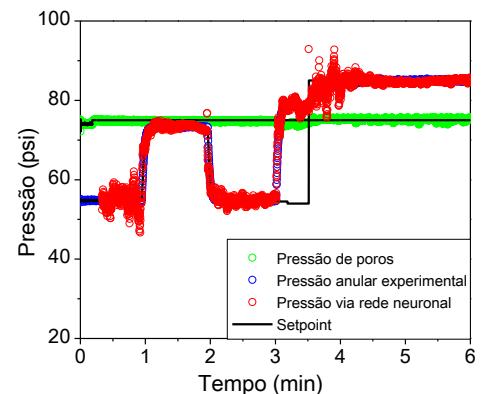


Figura 175 – Kick de gás com 60% de permeabilidade da rocha reservatório.

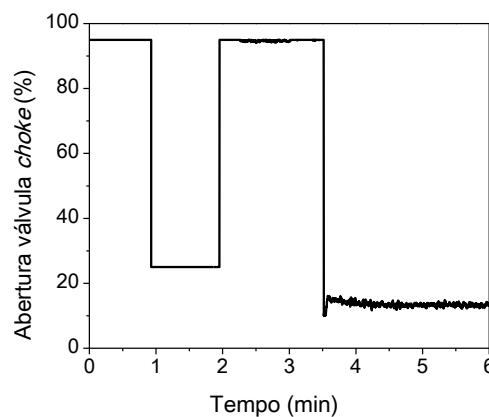


Figura 176 – Resposta da variável manipulada.

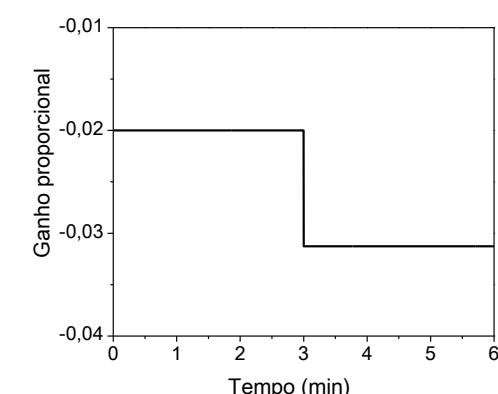


Figura 177 – Ganho do controlador.

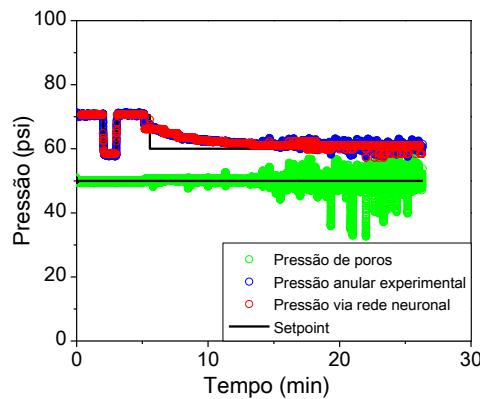


Figura 178 – Perda de circulação com 50% de permeabilidade da rocha reservatório.

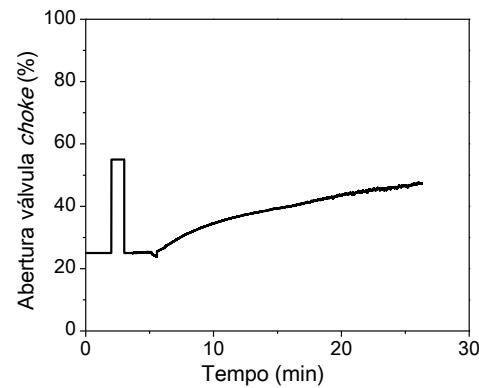


Figura 179 – Resposta da variável manipulada.

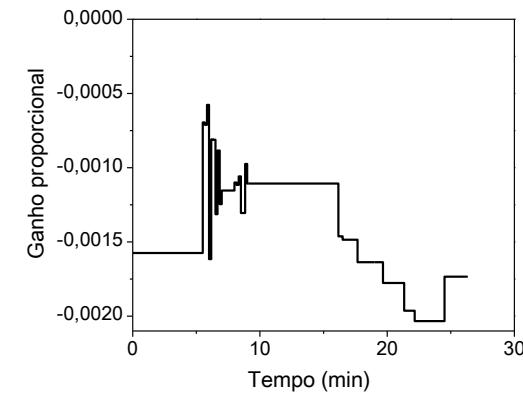


Figura 180 – Ganho do controlador.

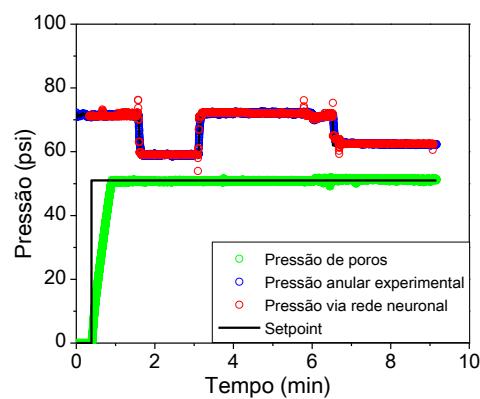


Figura 181 – Perda de circulação com 60% de permeabilidade da rocha reservatório.

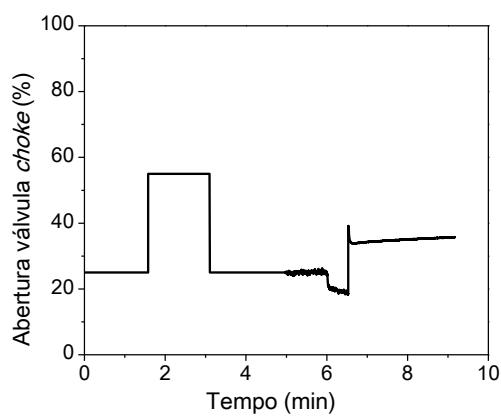


Figura 182 – Resposta da variável manipulada.

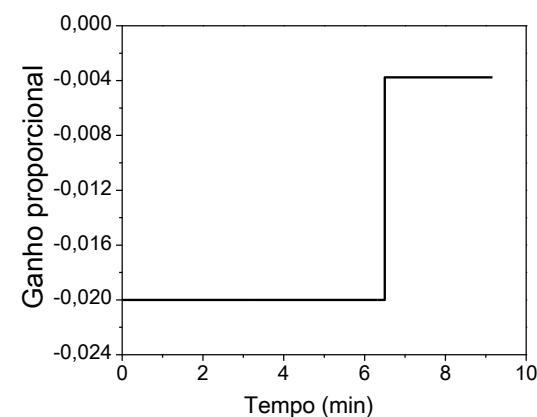


Figura 183 – Ganho do controlador.

Anexo H - Gráficos de controle via rede neuronal inversa – método direto.

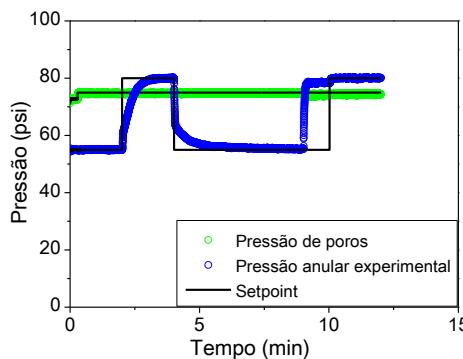


Figura 184 – Controle da pressão anular frente kick de gás com válvula de permeabilidade em 50%.

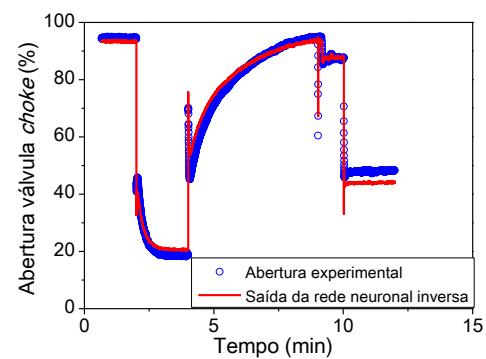


Figura 185 – Resposta do controlador neuronal inverso.

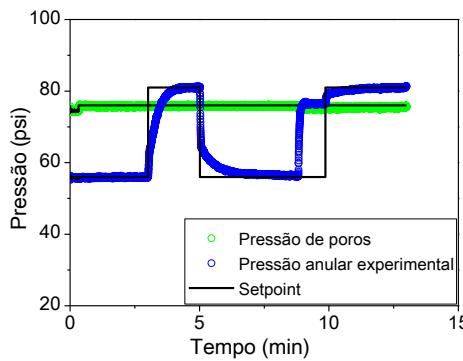


Figura 186 – Controle da pressão anular frente kick de gás com válvula de permeabilidade em 50%.

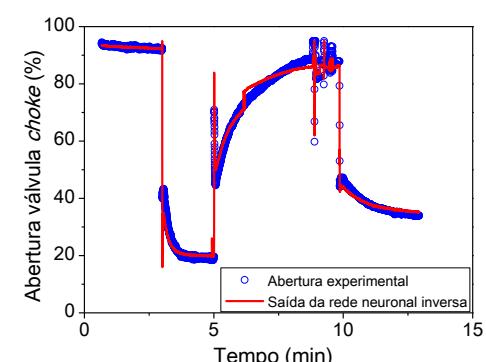


Figura 187 – Resposta do controlador neuronal inverso.

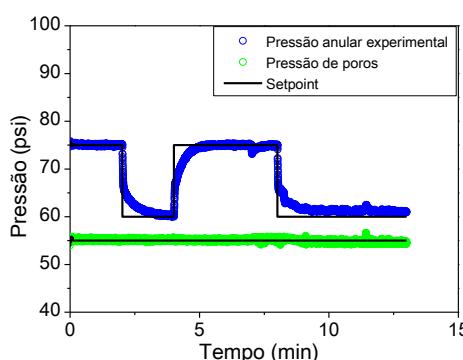


Figura 188 – Controle da pressão anular frente a perda de circulação com válvula de permeabilidade em 40%.

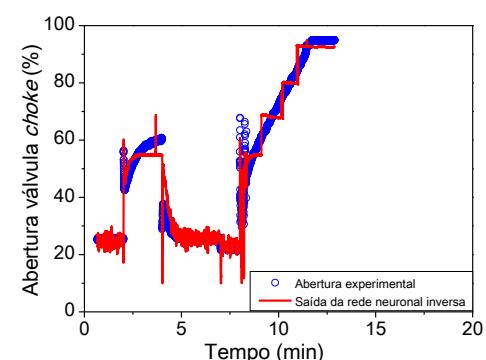


Figura 189 – Resposta do controlador neuronal inverso.

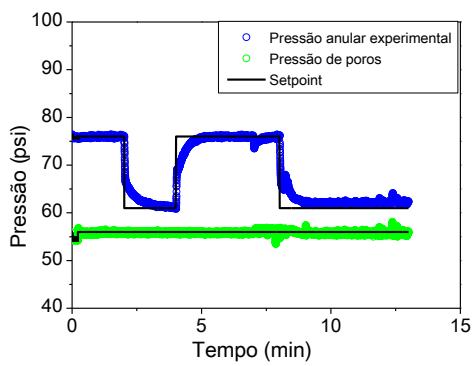


Figura 190 – Controle da pressão anular frente a perda de circulação com válvula de permeabilidade em 50%

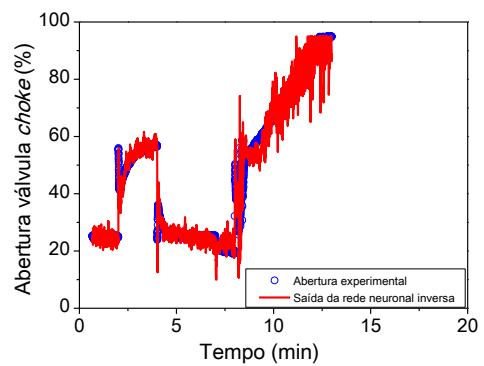


Figura 191 – Resposta do controlador neuronal inverso.

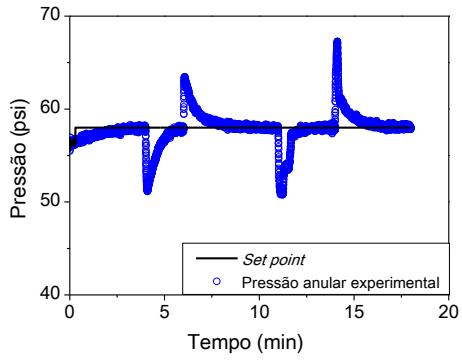


Figura 192 – Controle da pressão anular para procedimento de conexão de tubos.

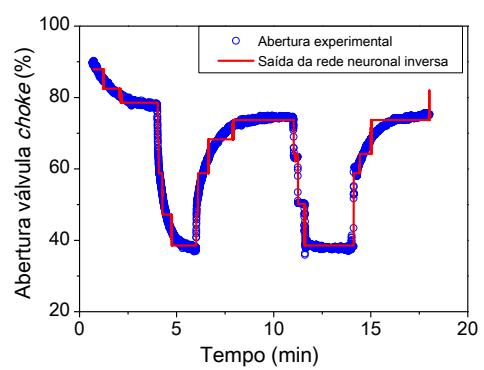


Figura 193 – Resposta do controlador neuronal inverso.

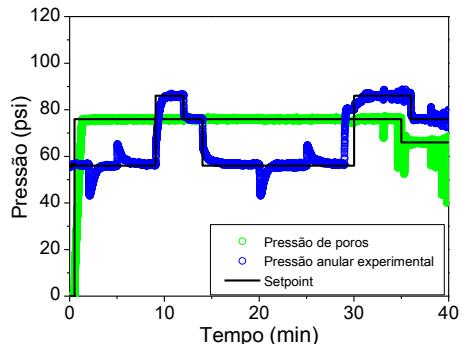


Figura 194 – Controle da pressão anular durante processo de perfuração.

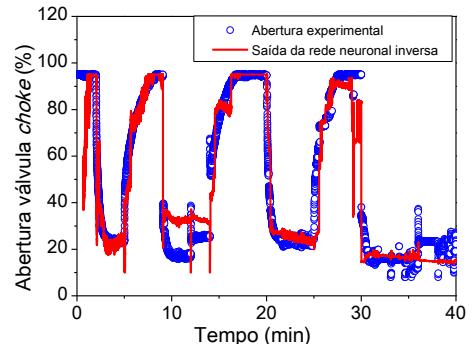


Figura 195 – Resposta do controlador neuronal inverso.