
**PREDIÇÃO DA ROP E OTIMIZAÇÃO EM TEMPO REAL DE
PARÂMETROS OPERACIONAIS NA PERFURAÇÃO DE POÇOS
DE PETRÓLEO OFFSHORE**

RONI ABENSUR GANDELMAN



DISSERTAÇÃO DE MESTRADO
APRESENTADA AO PROGRAMA
DE PÓS-GRADUAÇÃO EM
TECNOLOGIA DE PROCESSOS
QUÍMICOS E BIOQUÍMICOS DE
ESCOLA DE QUÍMICA DA UFRJ.

ORIENTAÇÃO: PROF. MAURÍCIO BEZERRA DE SOUZA JR., D.SC.

**ESCOLA DE QUÍMICA
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO**

2012

**PREDIÇÃO DA ROP E OTIMIZAÇÃO EM TEMPO REAL DE PARÂMETROS OPERACIONAIS NA
PERFURAÇÃO DE POÇOS DE PETRÓLEO OFFSHORE**

RONI ABENSUR GANDELMAN

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Tecnologia de Processos Químicos e Bioquímicos, para a obtenção do título de Mestre em Ciências (M.Sc.).

ESCOLA DE QUÍMICA
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
Março 2012

GANDELMAN, RONI ABENSUR,

Predição da ROP e Otimização em Tempo Real de Parâmetros Operacionais na Perfuração de Poços de Petróleo Offshore. / Roni Abensur Gandelman. - Rio de Janeiro, 2012.

xx , 175 f. il.

Dissertação (Mestrado em Tecnologia de Processos Químicos e Bioquímicos) - Universidade Federal do Rio de Janeiro - UFRJ, Escola de Química - EQ, 2012.

Orientador: Maurício Bezerra de Souza Júnior.

1. Perfuração. 2. Modelagem. 3. Redes Neurais. 4. Otimização. 5. Petróleo. - Teses. I. De Souza Jr., Maurício Bezerra (Orient.). II. Universidade Federal do Rio de Janeiro. Escola de Química. III. Título.

**PREDIÇÃO DA ROP E OTIMIZAÇÃO EM TEMPO REAL DE PARÂMETROS OPERACIONAIS NA
PERFURAÇÃO DE POÇOS DE PETRÓLEO OFFSHORE**

RONI ABENSUR GANDELMAN

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO CURSO
DE PÓS-GRADUAÇÃO EM TECNOLOGIA DE PROCESSOS
QUÍMICOS E BIOQUÍMICOS DA ESCOLA DE QUÍMICA DA
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO, COMO
PARTE DOS REQUISITOS NECESSÁRIOS À OBTENÇÃO DO
GRAU DE MESTRE EM CIÊNCIAS (M.Sc.).

APROVADA POR:

Prof. Maurício Bezerra de Souza Jr., D.Sc.
Orientador

André Leibsohn Martins, D.Sc.

Prof. Luiz Fernando Lopes Rodrigues Silva, D.Sc.

Prof. Marcia Peixoto Vega Domiciano, D.Sc.

RIO DE JANEIRO, RJ - BRASIL

MARÇO DE 2012

Ao meu pai, Rubem Gandelman, à minha mãe, Sonia
Abensur (z''l) e ao meu irmão Dan Abensur
Gandelman a quem devo tudo o que sou.

AGRADECIMENTOS

Ao meu professor orientador, Maurício Bezerra de Souza Jr., por toda a orientação e incentivos, paciência e pela confiança depositada nesta nova empreitada.

Aos meus amigos André Leibsohn e Alex Waldmann, pelas discussões sobre o assunto desta dissertação, que sempre me ajudaram a esclarecer dúvidas e impasses. Agradeço a eles também a atmosfera sem igual em que trabalhamos.

À Petrobras, pelo incentivo e liberação parcial para que eu pudesse concluir esta dissertação.

Por fim, agradeço a todos os amigos de trabalho Rosana Lomba, Pedro Aranha, Maurício Folsta, e Thiago Judson que, de alguma forma, colaboraram para o desenvolvimento deste trabalho.

Resumo:

GANDELMAN, Roni Abensur. Predição da ROP e otimização em tempo real de parâmetros operacionais na perfuração de poços de petróleo offshore. Orientador: Maurício Bezerra de Souza Júnior. Rio de Janeiro: EQ/UFRJ, 2012. Dissertação (Mestrado em Tecnologia de Processos Químicos e Bioquímicos).

A análise de parâmetros operacionais em tempo real durante a perfuração de poços é uma área que vem ganhando cada vez mais popularidade entre os engenheiros de petróleo. Nos últimos anos, as operadoras (tais como Petrobras, Shell, Statoil, etc) têm feito grandes investimentos no desenvolvimento de ferramentas de medição e transmissão de diversos parâmetros operacionais, tais como pressão de bombeio, rotação da broca, peso sobre broca, vazão de fluido de perfuração, torque da coluna de perfuração, etc. Dentre as inúmeras vantagens da análise e interpretação de dados em tempo real, uma das mais importantes é a otimização dos parâmetros operacionais de forma a se obter uma taxa de penetração desejada com o menor gasto de energia possível. Dentre todos os parâmetros que influenciam a taxa de penetração, aqueles que mais facilmente podem ser manipulados para o seu controle são a rotação da broca (RPM) e o peso sobre broca (WOB). Entretanto, a grande dificuldade para a otimização destes parâmetros é a inexistência de um modelo confiável que preveja corretamente a resposta da taxa de penetração frente a variações dos demais parâmetros operacionais. Neste trabalho, fez-se uso de redes neurais para a obtenção de modelos confiáveis para a previsão da taxa de penetração com base em parâmetros operacionais, tais como vazão de fluido, profundidade do poço, rotação da broca, peso sobre broca, litologia, etc. Os modelos obtidos foram testados com dados de poços inéditos e comparados com outros dois modelos muito usados na indústria do petróleo para previsão de taxas de penetração. Após a obtenção e validação de um modelo confiável, desenvolveu-se uma metodologia para otimização da rotação da broca e peso sobre broca em tempo real durante a perfuração. A metodologia desenvolvida tem um alto potencial para aumentar a vida útil da broca e demais equipamentos de fundo de poço, bem como reduzir tempo e custos da perfuração de poços de petróleo.

Abstract:

GANDELMAN, Roni Abensur. Prediction of ROP and real time optimization of operational parameters while drilling offshore oil-wells. Supervisor: Maurício Bezerra de Souza Júnior. Rio de Janeiro: EQ/UFRJ, 2012. M.Sc. Dissertation (Graduate Program on Technology of Chemical and Biochemical Processes).

The real time operational parameters analysis is gaining popularity among the petroleum engineers. In recent years, the petroleum companies have invested a lot in the development of tools to measure and transmit real time drilling data, such as pump pressure, bit rotation, weight on bit, flow rate, torque, etc. Among the many advantages of real time data analysis, one of the most important is the optimization of drilling parameters in order to obtain a desirable setpoint of rate of penetration with the lowest energy consumption. Among the operational parameters that impact the rate of penetration, those more easily manipulable for its control are bit rotation (RPM) and weight on bit (WOB). However the difficulty in drilling parameters optimization is the lack of a reliable model to predict the behavior of the rate of penetration as a function of other operational parameters. This work deals with the use of neural networks as models to predict the rate of penetration based on operational conditions, such as drilling fluid flow rate, well depth, bit rotation, weight on bit, lithology, etc. The models obtained were validated with totally new drilling data and compared to two other common models at the petroleum industry. After the models validation, a methodology for real time drilling parameters optimization while drilling was developed. The methodology developed offers a great potential for increasing the duration of bit and other bottom hole equipments and reducing drilling job operational time and costs.

Sumário:

Capítulo 1

Introdução	1
1.1 Motivação e Objetivos.....	8
1.2 Organização.....	10

Capítulo 2

Revisão Bibliográfica	12
2.1 Apresentação	12
2.2 Variáveis envolvidas	13
2.3 Modelos para previsão da taxa de penetração	19
2.3.1 Modelo de Maurer	20
2.3.2 Modelo de Young	21
2.3.3 Modelo de Bourgoyne.....	22
2.4 Redes neuronais	26
2.4.1 Processamento matemático	28
2.4.2 Treinamento por <i>backpropagation</i>	29
2.4.3 Treinamento por <i>backpropagation</i> com gradiente conjugado	33
2.5 Aspectos relativos à otimização.....	34
2.5.1 Conceitos sobre RTO (Real Time Optimization).....	34
2.5.2 PSO (<i>Particle Swarm Optimization</i>)	36
2.5.3 Método de Monte Carlo.....	40
2.6 Uso de redes neuronais para previsão de taxa de penetração	40
2.6.1 Iniciativas anteriores no uso de redes neuronais para previsão da taxa de penetração.....	41
2.7 Otimização em tempo real na perfuração de poços de petróleo <i>offshore</i>	42

Capítulo 3

Metodologia.....	45
3.1 Apresentação	45
3.2 Dados usados	46
3.3 Modelos.....	49
3.3.1 Rede direta.....	50
3.3.2 Rede inversa	52
3.3.3 Métodos de treinamento.....	53

3.4 Otimização dos parâmetros operacionais	53
3.4.1 Determinação explícita através das redes inversas	57
3.4.2 Uso de algoritmo de otimização PSO	57
3.4.3 Busca exaustiva de todos os pares de RPM e WOB.....	60

Capítulo 4

Resultados e discussões.....	63
4.1 Apresentação	63
4.2 Melhores redes neuronais obtidas	64
4.2.1 Rede direta única	64
4.2.2 Redes diretas separadas por litologia	65
4.2.3 Rede inversa única.....	66
4.2.4 Redes inversas separadas por litologia	66
4.3 Avaliação das redes obtidas.....	67
4.3.1 Rede direta única	68
4.3.2 Redes diretas separadas por litologia.....	69
4.3.2.1.Redes diretas separadas por litologia analisadas em conjunto	69
4.3.2.2.Redes diretas separadas por litologia analisadas separadamente	71
4.3.3 Rede inversa única.....	72
4.3.4 Redes inversas separadas por litologia	73
4.3.4.1.Redes inversas separadas por litologia analisadas em conjunto ...	73
4.3.4.2.Redes inversas separadas por litologia analisadas separad.....	74
4.4 Validação das redes diretas com dados inéditos	76
4.4.1 Validação da rede direta única	77
4.4.1.1. Validação da rede direta única com dados do poço A	77
4.4.1.2. Validação da rede direta única com dados do poço B.....	78
4.4.1.3. Validação da rede direta única com dados do poço C.....	79
4.4.1.4. Validação da rede direta única com dados do poço D	81
4.4.2 Validação das redes diretas separadas por litologia	82
4.4.2.1. Validação das redes diretas separadas com dados do poço A	82
4.4.2.2. Validação das redes diretas separadas com dados do poço B.....	83
4.4.2.3. Validação das redes diretas separadas com dados do poço C.....	85
4.4.2.4. Validação das redes diretas separadas com dados do poço D	86
4.5 Comparação entre redes neuronais e demais modelos usados na indústria ...	89
4.5.1 Comparação com modelo de Bourgoyne.....	90
4.5.2 Comparação com modelo de Maurer	91
4.5.2.1. Validação do modelo de Maurer com dados do poço A	92
4.5.2.2. Validação do modelo de Maurer com dados do poço B.....	93
4.5.2.3. Validação do modelo de Maurer com dados do poço C	94
4.5.2.4. Validação do modelo de Maurer com dados do poço D	95
4.5.3 Comparação com modelo de Young.....	96
4.5.3.1. Validação do modelo de Young com dados do poço A.....	97
4.5.3.2. Validação do modelo de Young com dados do poço B	98
4.5.3.3. Validação do modelo de Young com dados do poço C.....	99
4.5.3.4. Validação do modelo de Young com dados do poço D.....	100

4.6	Otimização dos parâmetros operacionais	102
4.6.1	Otimização através da rede inversa	102
4.6.2	Otimização através do algoritmo PSO.....	103
4.6.2.1.	Otimização dos dados do poço A com algoritmo PSO.....	104
4.6.2.2.	Otimização dos dados do poço B com algoritmo PSO	105
4.6.2.3.	Otimização dos dados do poço C com algoritmo PSO	106
4.6.2.4.	Otimização dos dados do poço D com algoritmo PSO.....	107
4.6.3	Otimização através da varredura exaustiva	109
4.6.3.1.	Otimização dos dados do poço A com varredura exaustiva	110
4.6.3.2.	Otimização dos dados do poço B com varredura exaustiva.....	112
4.6.3.3.	Otimização dos dados do poço C com varredura exaustiva	114
4.6.3.4.	Otimização dos dados do poço D com varredura exaustiva	115
4.7	Comparação dos métodos de otimização	117
Capítulo 5		
Conclusões e sugestões para trabalhos futuros		121
5.1	Apresentação	121
5.2	Uso de redes neurais para previsão da taxa de penetração durante a perfuração de poços de petróleo	122
5.3	Redes Neurais inversas	123
5.4	Resultados dos métodos de otimização	124
5.5	Considerações finais.....	126
5.6	Sugestões para trabalhos futuros	126
Capítulo 6		
Referências bibliográficas.....		128
Apêndice A		
Apêndice A – Códigos em MATLAB Desenvolvidos		133
Apêndice B		
Apêndice B – Avaliação das Redes Separadas por Litologia		152
Apêndice C		
Apêndice C – Otimização Através das Redes Inversas.....		170

Lista de Figuras:

Capítulo 1

Figura 1.1. Desenho esquemático da perfuração de um poço de petróleo	2
Figura 1.2. Exemplo de janela operacional	3
Figura 1.3. Desenho esquemático das fases perfuradas em um poço de petróleo	6

Capítulo 2

Figura 2.1. Comportamento esperado da taxa de penetração com peso sobre broca .	14
Figura 2.2. Comportamento esperado da taxa de penetração com rotação da broca..	16
Figura 2.3. Comportamento da pressão de fundo como função da vazão	17
Figura 2.4. Modelo não-linear de um neurônio j da camada $k+1$	27
Figura 2.5. Os cinco níveis de controle de processo e otimização em tempo real	35
Figura 2.6. Três elementos fundamentais para o cálculo do deslocamento da partícula a cada passo de tempo	39

Capítulo 3

Figura 3.1. Tela do <i>software</i> PWDa com parte dos dados em tempo real.....	47
Figura 3.2. Parte dos dados em tempo real coletados para treinamento das redes neurais para previsão da taxa de penetração	48
Figura 3.3. Desenhos esquemáticos das arquiteturas das redes neurais direta e inversa	49
Figura 3.4. Fluxograma do método da varredura exaustiva para determinação do par ótimo de RPM e WOB	62

Capítulo 4

Figura 4.1. ROP prevista versus ROP real – rede direta única	69
Figura 4.2. ROP prevista versus ROP real – redes diretas separadas por litologias ...	70
Figura 4.3. RPM real versus RPM prevista – rede inversa única	72
Figura 4.4. WOB real versus WOB prevista – rede inversa única	72
Figura 4.5. RPM real versus RPM prevista – redes inversas separadas por litologia .	74
Figura 4.6. WOB real versus WOB prevista – redes inversas separadas por litologia	74
Figura 4.7. ROP prevista versus ROP real para o poço A – Rede direta única	78
Figura 4.8. Histograma de frequência de erros absolutos para o poço A – rede direta única.....	78
Figura 4.9. ROP prevista versus ROP real para o poço B – Rede direta única	79
Figura 4.10. Histograma de frequência de erros absolutos para o poço B – rede direta única.....	79

Figura 4.11. ROP prevista versus ROP real para o poço C – Rede direta única	80
Figura 4.12. Histograma de frequência de erros absolutos para o poço C – rede direta única.....	80
Figura 4.13. ROP prevista versus ROP real para o poço D – rede direta única.....	81
Figura 4.14. Histograma de frequência de erros absolutos para o poço D – rede direta única.....	81
Figura 4.15. ROP prevista versus ROP real para o poço A - Redes diretas separadas	83
Figura 4.16. Histograma de frequência de erros absolutos para o poço A – redes diretas separadas por litologias	83
Figura 4.17. ROP prevista versus ROP real para o poço B – Redes diretas separadas	84
Figura 4.18. Histograma de frequência de erros absolutos para o poço B – redes diretas separadas por litologias	84
Figura 4.19. ROP prevista versus ROP real para o poço C – Redes diretas separadas	85
Figura 4.20. Histograma de frequência de erros absolutos para o poço C – redes diretas separadas por litologias	86
Figura 4.21. ROP prevista versus ROP real para o poço D – Redes diretas separadas	86
Figura 4.22. Histograma de frequência de erros absolutos para o poço D – redes diretas separadas por litologias	87
Figura 4.23. ROP prevista versus ROP real para o poço A – Modelo de Maurer	92
Figura 4.24. Histograma de frequência de erros absolutos para o poço A – Modelo de Maurer	93
Figura 4.25. ROP prevista versus ROP real para o poço B – Modelo de Maurer	93
Figura 4.26. Histograma de frequência de erros absolutos para o poço B – Modelo de Maurer	94
Figura 4.27. ROP prevista versus ROP real para o poço C – Modelo de Maurer.....	94
Figura 4.28. Gráfico de frequência de erros absolutos para o poço B – Modelo de Maurer	95
Figura 4.29. ROP prevista versus ROP real para o poço D – Modelo de Maurer	96
Figura 4.30. Histograma de frequência de erros absolutos para o poço D – Modelo de Maurer	96
Figura 4.31 . ROP prevista versus ROP real para o poço A – Modelo de Young	98
Figura 4.32. Histograma de frequência de erros absolutos para o poço A – Modelo de Young	98
Figura 4.33. ROP prevista versus ROP real para o poço B – Modelo de Young.....	99
Figura 4.34. Histograma de frequência de erros absolutos para o poço B – Modelo de Young	99
Figura 4.35. ROP prevista versus ROP real para o poço C – Modelo de Young	100
Figura 4.36. Histograma de frequência de erros absolutos para o poço C – Modelo de Young	100
Figura 4.37. ROP prevista versus ROP real para o poço D – Modelo de Young.....	101
Figura 4.38. Histograma de frequência de erros absolutos para o poço D – Modelo de Young	101
Figura 4.39. RPM e WOB ao longo do tempo gerados pelo método PSO para manter a taxa de penetração em 45 m/h – Poço A.....	104

Figura 4.40. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela algoritmo PSO – Poço A.....	105
Figura 4.41. RPM e WOB ao longo do tempo gerados pelo método PSO para manter a taxa de penetração em 45 m/h – Poço B	106
Figura 4.42. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela algoritmo PSO – Poço B	106
Figura 4.43. RPM e WOB ao longo do tempo gerados pelo método PSO para manter a taxa de penetração em 45 m/h – Poço C	107
Figura 4.44. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela algoritmo PSO – Poço C.....	107
Figura 4.45. RPM e WOB ao longo do tempo gerados pelo método PSO para manter a taxa de penetração em 45 m/h – Poço D.....	108
Figura 4.46. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela algoritmo PSO – Poço D.....	108
Figura 4.47. RPM e WOB ótimas de acordo com as condições operacionais do poço A	111
Figura 4.48. Energia mecânica específica mínima ao longo do tempo para uma taxa de 45 m/h do poço A	111
Figura 4.49. RPM e WOB ótimas de acordo com as condições operacionais do poço B	112
Figura 4.50. Energia mecânica específica mínima ao longo do tempo para uma taxa de 45 m/h do poço B.....	111
Figura 4.51. RPM e WOB ótimas de acordo com as condições operacionais do poço B – litologias marcadas (resultado obtido com redes diretas separadas por litologia)	113
Figura 4.52. Rotação e peso sobre broca ótimos ao longo do tempo para o poço B e vários setpoints diferentes de taxa de penetração (resultado obtido com redes diretas separadas por litologia).....	114
Figura 4.53. RPM e WOB ótimas de acordo com as condições operacionais do poço C	115
Figura 4.54. Energia mecânica específica mínima ao longo do tempo para uma taxa de 45 m/h do poço C.....	115
Figura 4.55. RPM e WOB ótimas de acordo com as condições operacionais do poço D	116
Figura 4.56. Energia mecânica específica mínima ao longo do tempo para uma taxa de 45 m/h do poço D	116
Figura 4.57. Comparação das energias mecânicas específicas previstas pelos diferentes métodos – Poço A.....	118
Figura 4.58. Comparação das energias mecânicas específicas previstas pelos diferentes métodos – Poço B	119
Figura 4.59. Comparação das energias mecânicas específicas previstas pelos diferentes métodos – Poço C.....	119

Figura 4.60. Comparação das energias mecânicas específicas previstas pelos diferentes métodos – Poço D.....	119
---	-----

Apêndice B

Figura B.1. ROP real versus ROP prevista – Rede para Carbonato Albiano.....	153
Figura B.2. ROP real versus ROP prevista – Rede para Anidrita	154
Figura B.3. ROP real versus ROP prevista – Rede para Arenito.....	154
Figura B.4. ROP real versus ROP prevista – Rede para Calcilutito.....	155
Figura B.5. ROP real versus ROP prevista – Rede para Coquina	155
Figura B.6. ROP real versus ROP prevista – Rede para Calcarenito	156
Figura B.7. ROP real versus ROP prevista – Rede para Carnalita	156
Figura B.8. ROP real versus ROP prevista – Rede para Folhelho.....	157
Figura B.9. ROP real versus ROP prevista – Rede para Halita	157
Figura B.10. ROP real versus ROP prevista – Rede para Marga.....	158
Figura B.11. ROP real versus ROP prevista – Rede para Siltito.....	158
Figura B.12. ROP real versus ROP prevista – Rede para Taquidrita	159
Figura B.13. RPM real versus RPM prevista – rede inversa para Carbonato Albiano 159	
Figura B.14. WOB real versus WOB prevista – rede inversa para Carbonato Albiano 159	
Figura B.15. RPM real versus RPM prevista – rede inversa para Anidrita.....	160
Figura B.16. WOB real versus WOB prevista – rede inversa para Anidrita	160
Figura B.17. RPM real versus RPM prevista – rede inversa para Arenito	161
Figura B.18. WOB real versus WOB prevista – rede inversa para Arenito	161
Figura B.19. RPM real versus RPM prevista – rede inversa para Calcilutito.....	161
Figura B.20. WOB real versus WOB prevista – rede inversa para Calcilutito	162
Figura B.21. RPM real versus RPM prevista – rede inversa para Coquina	162
Figura B.22. WOB real versus WOB prevista – rede inversa para Coquina	162
Figura B.23. RPM real versus RPM prevista – rede inversa para Calcarenito.....	163
Figura B.24. WOB real versus WOB prevista – rede inversa para Calcarenito	163
Figura B.25. RPM real versus RPM prevista – rede inversa para Carnallita	164
Figura B.26. WOB real versus WOB prevista – rede inversa para Carnallita	164
Figura B.27. RPM real versus RPM prevista – rede inversa para Folhelho.....	164
Figura B.28. WOB real versus WOB prevista – rede inversa para Folhelho	165
Figura B.29. RPM real versus RPM prevista – rede inversa para Halita	165
Figura B.30. WOB real versus WOB prevista – rede inversa para Halita.....	165
Figura B.31. RPM real versus RPM prevista – rede inversa para Marga	166
Figura B.32. WOB real versus WOB prevista – rede inversa para Marga	166
Figura B.33. RPM real versus RPM prevista – rede inversa para Siltito.....	167
Figura B.34. WOB real versus WOB prevista – rede inversa para Siltito	167
Figura B.35. RPM real versus RPM prevista – rede inversa para Taquidrita	167
Figura B.36. WOB real versus WOB prevista – rede inversa para Taquidrita.....	168

Apêndice C

Figura C.1. RPM e WOB ao longo do tempo gerados pela rede inversa única para manter a taxa de penetração em 45 m/h – Poço A	171
Figura C.2. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela rede inversa única – Poço A.....	172
Figura C.3. RPM e WOB ao longo do tempo gerados pela rede inversa única para manter a taxa de penetração em 45 m/h – Poço B.....	172
Figura C.4. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela rede inversa única – Poço B.....	173
Figura C.5. RPM e WOB ao longo do tempo gerados pela rede inversa única para manter a taxa de penetração em 45 m/h – Poço C	173
Figura C.6. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela rede inversa única – Poço C	174
Figura C.7. RPM e WOB ao longo do tempo gerados pela rede inversa única para manter a taxa de penetração em 45 m/h – Poço D	175
Figura C.8. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela rede inversa única – Poço D	175

Lista de Tabelas:

Capítulo 2:

Tabela 2.1. Principais funções de ativação utilizadas em redes neurais do tipo MLP.....	29
---	----

Capítulo 4:

Tabela 4.1. Melhor rede obtida no Statistica© versão 8 para previsão de ROP tendo a litologia como uma variável de entrada categórica.....	65
Tabela 4.2. Melhores redes obtidas no Statistica© versão 8 para previsão de ROP ...	66
Tabela 4.3. Melhor rede inversa obtida no Statistica© versão 8, para previsão de RPM e WOB tendo a ROP como entrada a litologia como uma variável de entrada categórica.....	66
Tabela 4.4. Melhores redes inversas obtidas no Statistica© versão 8 para previsão de RPM e WOB tendo a ROP como entrada	67
Tabela 4.5. Parâmetros de análise da rede direta.....	69
Tabela 4.6. Parâmetros de análise da rede direta.....	70
Tabela 4.7. Parâmetros para verificação do desempenho das redes diretas separadas por litologia	71
Tabela 4.8. Parâmetros de análise da rede inversa	72
Tabela 4.9. Parâmetros de análise do desempenho da rede inversa única	74
Tabela 4.10. Parâmetros de análise do desempenho das redes separadas por litologia	76
Tabela 4.11. Parâmetros de análise do desempenho da rede direta única para a previsão da taxa de penetração	82
Tabela 4.12. Parâmetros de análise do desempenho das redes diretas separadas por litologia para a previsão da taxa de penetração	87
Tabela 4.13. Parâmetros do modelo de Maurer para as litologias testadas	91
Tabela 4.14. Parâmetros de análise do desempenho do modelo de Maurer com dados dos poços de validação	96
Tabela 4.15. Parâmetros de do modelo de Young para as litologias testadas	97
Tabela 4.16. Parâmetros de análise do desempenho do modelo de Young com dados dos poços de validação	101

Lista de Abreviaturas:

ALB	Carbonato Albiano
AND	Anidrita
ARN_MAC	Arenito
CLU	Calcilutito
COQ	Coquina
CRE	Calcarenito
CRN	Carnalita
ECD	<i>Equivalent Circulation Density</i> (Densidade Equivalente de Circulação)
EME	Energia Mecânica Específica
FLH	Folhelho
HAL	Halita
JB	Jarque-Barre
LL	Lilliefors
MLP	<i>Multilayer Perceptron</i>
MRG	Marga
PSO	<i>Particle Swarm Optimization</i> (Otimização por enxame de partículas)
RBF	<i>Radial Basis Function</i>
ROP	<i>Rate of Penetration</i> (Taxa de Penetração)
RPM	Rotação da broca
SANN	Statistica Automated Neural Network
SLT	Siltito
TQD	Taquidrita
TVD	<i>True Vertical Depth</i> (Profundidade Vertical)
WOB	<i>Weight on Bit</i> (Peso sobre Broca)
WOB _t	Peso sobre broca mínimo para iniciar a perfuração

Lista de Símbolos:

Símbolos latinos

a	Parâmetro do modelo de Maurer, m^2/N
b	Parâmetro do modelo de Maurer, N/m
c	Parâmetro do modelo de Young, adm
d	Parâmetro do modelo de Young, adm
$F_{Objetivo}$	função objetivo
d_b	Diâmetro da broca (ou da fase), m
g_p	Pressão de poros expressa em termos de densidade equivalente, kg/m^3
h	Fração desgastada do dente de broca
K	Parâmetro do modelo de Young, $m^{c+1}s^{d-1}/N^c$
N	número total de variáveis de saída na rede neuronal
NH	número de neurônios na camada escondida
NI_i	valor de saída do i -ésimo neurônio da camada de entrada
NS_i	valor de saída do i -ésimo neurônio da camada de saída
P	número total de padrões
P_{din}	Pressão dinâmica, Pa
P_h	Pressão hidrostática, Pa
q	Vazão do fluido de perfuração, m^3/s
S_i	valor de saída do i -ésimo neurônio da camada de saída
$s_{pi,k+1}$	saída (ou ativação) correspondente ao neurônio j da camada $k+1$ para um padrão p
T	Torque, N.m
$x_{p,j,k}$	signal de entrada correspondente ao padrão p , no neurônio j da camada $k+1$
$w_{k,j,i}$	peso correspondente à conexão entre o neurônio j da camada k e o neurônio i da camada $k+1$
$Yrn_{i,p}$	valor da i -ésima variável de saída da rede neuronal, para o padrão p
Y_p	vetor contendo os valores alvo de todos os padrões fornecidos a rede
$Y_{i,p}$	valor de processo obtido para a i -ésima variável de saída, para o padrão p
Yrn_p	vetor fornecido pelos neurônios de saída da rede neuronal para todos os padrões
$y_{pj,k+1}$	signal de saída correspondente ao neurônio j na camada $k+1$ para o padrão p

Símbolos gregos

∇E_{SOS}	Gradiente do erro
ΔP_{ASV}	Perdas de cargas a serem vencidas, Pa
ρ	Densidade do fluido de perfuração, kg/m ³
μ	Viscosidade aparente do fluido de perfuração, Pa.s
$\lambda_{pj,k+1}$	função auxiliar que indica a soma ponderada de todas as entradas do neurônio j da camada $k+1$ para um padrão p
Δw_{k+1}	diferença entre os pesos w obtidos para iterações adjacentes
$\theta_{j,k+1}$	<i>bias</i> ou limite interno de ativação do neurônio j da camada $k+1$
η	taxa de aprendizado
$\lambda H_{pj,k+1}$	resposta produzida pelo j -ésimo neurônio da camada escondida para o padrão p
$\lambda O_{pj,k+1}$	resposta produzida pelo j -ésimo neurônio da camada de saída para o padrão p

índices

k	número da camada anterior àquela analisada,
j	número do neurônio da camada analisada.
p	número de padrões

CAPÍTULO 1

Introdução

A perfuração de um poço de petróleo é um processo de extrema complexidade e altos custos, em que todos os esforços devem ser feitos para manter as condições operacionais dentro de limites seguros e econômicos (THOMAS, 2001).

A perfuração ocorre quando peso e rotação são impostos a uma broca, localizada na extremidade inferior de uma coluna de tubos de aço, chamada de “coluna de perfuração”. Além de ser a responsável por transmitir peso e rotação à broca, a coluna de perfuração conduz um fluido, chamado de “fluido de perfuração”, da superfície até a broca. Ao atingir o fundo do poço, o fluido de perfuração passa pelos jatos da broca e retorna à superfície pelo espaço anular entre o poço e a coluna de perfuração, carreando os sólidos gerados e permitindo que a perfuração prossiga (ROCHA e AZEVEDO, 2007). A Figura 1.1 mostra um desenho esquemático da perfuração de um poço *offshore*. As setas mostram o sentido do fluido de perfuração.

O fluido de perfuração é um elemento fundamental durante a construção de um poço e dentre suas inúmeras funções, as mais importantes são (AADNOY *et al*, 2009):

- transportar os sólidos gerados pela broca até a superfície;

- transmitir pressão hidrostática às paredes do poço, mantendo-o estável e impedindo a migração de fluidos das formações geológicas atravessadas para dentro do poço;

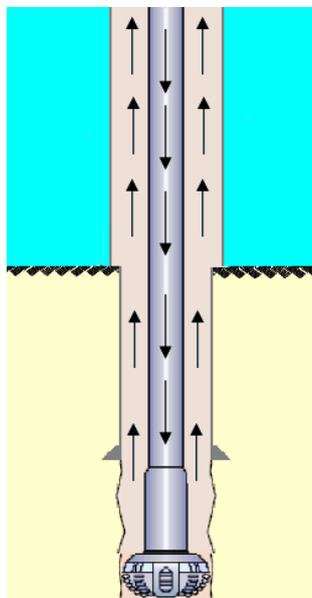


Figura 1.1. Desenho esquemático da perfuração de um poço de petróleo offshore

Durante a perfuração, dois pontos chaves devem ser acompanhados com extremo cuidado: o perfil de pressões (dinâmicas e estáticas) e a limpeza do poço (THOMAS, 2001).

As pressões devem ser mantidas sempre dentro de um range seguro chamado de “janela operacional”, cujo limite inferior é a pressão de poros e o limite superior é a pressão de fratura.

A pressão de poros é a pressão à qual estão submetidos os fluidos nativos contidos nos poros das formações geológicas atravessadas. Caso a pressão no poço atinja valores abaixo da pressão de poros, haverá uma tendência natural de migração dos fluidos nativos para dentro do poço (THOMAS, 2001). Isto representa um sério risco operacional, já que a grande maioria dos fluidos nativos são inflamáveis (óleo ou gás) ou tóxicos (gás sulfídrico).

A pressão de fratura é a pressão acima da qual as rochas perfuradas começam a fraturar. Caso a pressão no poço atinja valores acima do limite superior da janela operacional, fraturas começarão a ser induzidas, criando caminhos preferenciais para o escoamento do fluido de perfuração, o que também representa um risco operacional. As fraturas podem comunicar diferentes reservatórios criando caminhos para migração de óleo e, em casos extremos, podem comunicar reservatórios ao leito marinho, causando sérios danos ambientais (AADNOY, 2009).

A Figura 1.2 mostra um exemplo de janela operacional real de um poço de petróleo, cedida pela Petrobras. As pressões de poros e fratura, em termos de densidade equivalente, são

traçadas como função da profundidade. A densidade equivalente nada mais é do que a pressão em um determinado ponto dividida pela aceleração da gravidade e pela profundidade daquele ponto. Ou seja, para se determinar as pressões de poros e fratura reais em qualquer ponto, basta multiplicar as densidades equivalentes pela gravidade e pela profundidade. A representação da janela operacional em termos de densidade equivalente é muito útil, pois permite a determinação direta da densidade do fluido. Em um poço limpo (sem sólidos de perfuração) e sem circulação (fluido parado), o perfil de pressões ao longo da profundidade expresso em termos de densidade equivalente será constante e terá o valor da própria densidade do fluido de perfuração. Assim, um fluido de perfuração que apresente uma densidade cujo valor é inferior à densidade equivalente de pressão de poros ou superior à densidade equivalente da pressão de fratura não é adequado para a perfuração daquele poço.

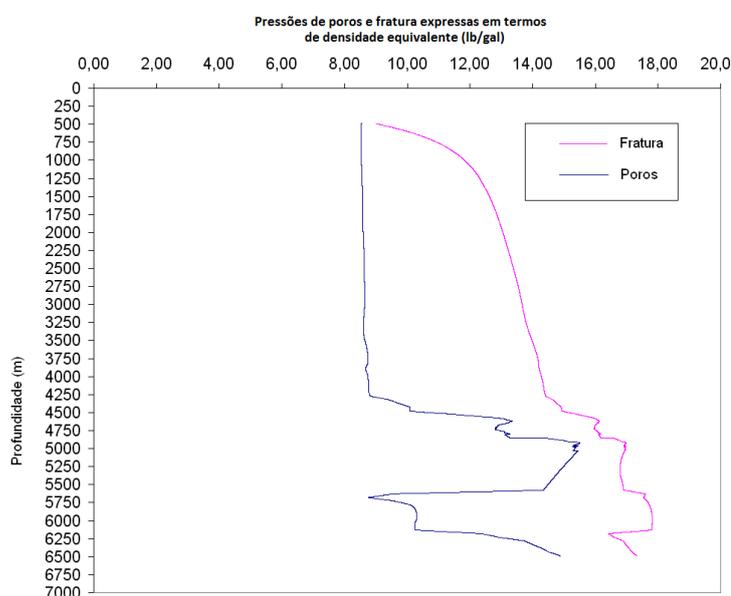


Figura 1.2. Exemplo de janela operacional

Rigorosamente, a janela operacional não é limitada apenas pelas pressões de poros e fraturas. Há outros limites relacionados à estabilidade mecânica da rocha, tais como pressão de colapso superior e inferior, que desempenham um papel importante na definição da janela operacional e da densidade do fluido de perfuração a ser usada em cada poço. Entretanto, na grande maioria das vezes, a pressão de poros é maior que a pressão de colapso inferior. O mesmo acontece com a pressão de fratura que, geralmente, é menor que a pressão de colapso superior. Desta forma, as pressões de poros e fratura são adotadas como os limites da janela operacional na grande maioria das vezes. Por este motivo, não será feita uma discussão maior sobre pressões de colapso inferior e superior nesta dissertação. Mais informações sobre estes conceitos podem ser encontradas em Bourgoyne *et al* (AADNOY, 2009).

O perfil de pressão no poço deve ser mantido dentro dos limites da janela operacional (ROCHA e AZEVEDO, 2007). Vários pontos fundamentais do projeto de um poço (tais como densidade do fluido de perfuração, profundidade final e diâmetro de cada fase) são determinados com base na previsão de janela operacional. Ainda tendo por base a Figura 1.2, na profundidade de 5250 m, é impossível perfurar o poço com um fluido de densidade igual ao fluido de perfuração usado para perfurar o poço na profundidade de 2000 m. Para manter a pressão no poço acima da pressão de poros a 5250 m, o fluido de perfuração deveria ter uma densidade tal que, a 2000 m, geraria uma pressão maior do que a pressão de fratura. Logo, necessariamente, um revestimento terá que ser posicionado e cimentado em algum ponto entre estas duas profundidades para que a perfuração possa prosseguir.

O outro ponto fundamental é a limpeza do poço. Manter condições de limpeza adequadas significa remover ao máximo os sólidos gerados pela broca. Uma concentração de sólidos elevada no espaço anular pode causar uma série de graves problemas operacionais, tais como (ARAGAO *et al*, 2005):

- Prisão de coluna (situação em que os sólidos não removidos obstruem o anular e geram um arraste excessivo para a movimentação axial da coluna de perfuração, impedindo a sua retirada do poço);
- Obstrução do espaço anular por acúmulo de sólidos, elevando sobremaneira as perdas de carga e, conseqüentemente, o perfil de pressões no poço.

Além disso, a presença de sólidos no anular aumenta a densidade aparente do fluido de perfuração, gerando maiores pressões hidrostáticas. A Equação 1.1 mostra o cálculo da pressão dinâmica em qualquer ponto do poço (GANDELMAN *et al*, 2009).

$$P_{din} = P_h + \Delta P_{ASV} \quad (1.1)$$

onde: P_{din} é pressão dinâmica em um determinado ponto do anular;

P_h é a pressão hidrostática do fluido acima daquele ponto, incluindo o efeito da presença de sólidos;

ΔP_{ASV} são as perdas de carga a serem vencidas pelo fluido em seu caminho daquele ponto até a superfície.

Assim, o projeto hidráulico de um poço de petróleo deve determinar a melhor combinação de parâmetros operacionais (reologia do fluido de perfuração, vazão e taxa de penetração), de forma a maximizar a remoção de sólidos e minimizar a pressão dinâmica no poço e o tempo (e, conseqüentemente, o custo) operacional (ROCHA e AZEVEDO, 2007).

O poço é perfurado em etapas (“fases”, no jargão da indústria de petróleo), tendo cada uma um diâmetro menor do que a anterior (THOMAS, 2001). O poço é iniciado com uma broca de determinado diâmetro que perfura as rochas até uma certa profundidade (definida em projeto), expondo as formações geológicas. Nesta “fase”, o diâmetro do poço (também chamado de diâmetro da fase ou diâmetro do poço aberto) é igual ao diâmetro da broca. Ao término da fase, um tubo de aço (chamado de “revestimento”) de diâmetro inferior ao da broca é posicionado no poço e, em seguida, o anular formado entre a parede externa do tubo e a parede do poço é cimentado. A cimentação tem como objetivo isolar as formações geológicas expostas pela perfuração, que podem conter fluidos inflamáveis, tóxicos ou apresentar instabilidade química ou mecânica (BOURGOYNE *et al*, 2001).

Evidentemente, os engenheiros projetistas tem o objetivo de perfurar o poço com o menor número de etapas possível (se possível, apenas uma), pois isso reduz significativamente o tempo e custos da operação. Entretanto, a partir de certa profundidade, torna-se impossível prosseguir com a perfuração, principalmente devido a questões mecânicas. A partir de certa profundidade, a pressão hidrostática do fluido não é mais suficiente para manter a pressão o poço acima da pressão de poros. Isto exige o aumento da densidade do fluido de perfuração. Entretanto, o aumento da densidade do fluido, além de aumentar a pressão no fundo do poço (o que é desejável), aumenta a pressão também nas profundidades mais rasas, atingindo a pressão de fratura naqueles pontos. Isto impossibilita o prosseguimento da perfuração, obrigando os engenheiros a interrompê-la a isolar as formações perfuradas até aquele momento (revestindo-as e cimentando-as) (ROCHA e AZEVEDO, 2007; BOURGOYNE *et al*, 2001; THOMAS, 2001). Desta forma, é possível aumentar a densidade do fluido na nova fase, garantindo a pressão de fundo acima da pressão de poros e sem o risco de fraturar as formações mais rasas, que encontram-se isoladas.

Após a cimentação da fase recém perfurada, uma nova broca de diâmetro inferior ao do revestimento (ou ao do “poço revestido”) é posicionada no fundo do poço e inicia-se a perfuração de uma nova fase. Ao término desta nova fase, o mesmo procedimento (revestir e cimentar) é realizado (THOMAS, 2001). Estas etapas são repetidas até que se atinja a profundidade final do poço, ou seja, que se atinja o alvo desejado (a rocha reservatório portadora do óleo ou gás).

A Figura 1.3 mostra um desenho esquemático da perfuração de um poço com suas fases. Note que, para o poço mostrado na figura, cinco fases foram perfuradas, revestidas e cimentadas e a sexta fase está em perfuração. O fluido de perfuração é representado pela cor laranja, o cimento pela cor cinza, a formação geológica pela cor amarela clara e a água do mar pela cor azul. Os triângulos cinza escuros representam a profundidade final de cada revestimento, também chamada de profundidade da “sapata”.

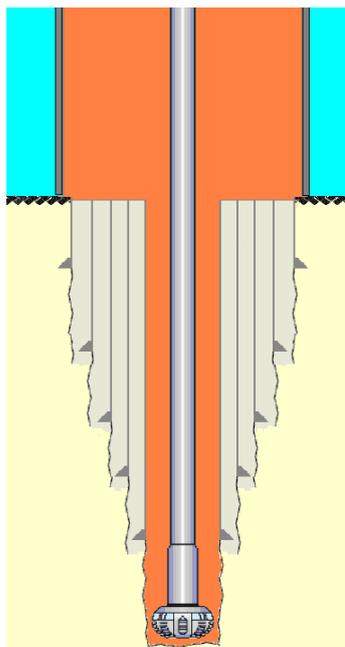


Figura 1.3. Desenho esquemático das fases perfuradas em um poço de petróleo offshore - o fluido de perfuração é representado pela cor laranja, o cimento pela cor cinza, a formação geológica pela cor amarela clara e a água do mar pela cor azul

Em poços *offshore*, como os mostrados nas Figuras 1.1 e 1.3, uma tubulação de grande diâmetro conecta o fundo do mar à sonda de perfuração. Esta tubulação, chamada de “*riser*”, é a responsável por conduzir o fluido de perfuração que sai do poço carregando os cascalhos até a sonda de perfuração, onde os sólidos são separados e o fluido retorna a um tanque para ser, novamente, succionado e reinjetado no interior da coluna de perfuração (THOMAS, 2001). Os cascalhos separados do fluido são tratados para descarte apropriado. Dependendo do tipo de fluido e do ambiente em que o poço está sendo perfurado, os sólidos podem ser descartados no mar ou trazidos à terra para descarte em locais específicos. Na Figura 1.3, as paredes do *riser* são representadas por traços cinzas mais grossos. Não há descontinuidade entre o anular do poço revestido (formado pela coluna de perfuração e o último revestimento posicionado no poço) e o anular do *riser* (formado pelas paredes internas do *riser* e a coluna de perfuração), exceto por

equipamentos de segurança de poço que, muitas vezes, são posicionados entre estes dois anulares.

A taxa de penetração (*rate of penetration* ou simplesmente ROP) é a velocidade com que a broca perfura as rochas. Este é um parâmetro importantíssimo que, sempre que possível, deve ser maximizado. Atualmente, o custo médio de uma sonda de perfuração é cerca de US\$ 1.600.000,00 por dia. Este custo extremamente elevado torna desejável que a perfuração do poço se dê o mais rápido possível, ou seja, maximizando-se a ROP. Entretanto, em cenários de janela operacional estreita (pressão de fratura muito próxima da pressão de poros), a concentração de sólidos no anular deve ser controlada de forma a não aumentar excessivamente a pressão no poço (ARAGAO *et al*, 2005; GANDELMAN *et al*, 2009; GANDELMAN *et al*, 2010). Consequentemente, a ROP deve ser limitada a um determinado valor. Há também situações em que não é possível obter condições adequadas para remoção dos sólidos. Nestes cenários, a ROP também deve ser limitada a um valor tal que a quantidade de sólidos gerada pela broca possa ser removida adequadamente pelo fluido de perfuração, reduzindo riscos de problemas operacionais.

Assim, o controle da ROP é uma das tarefas mais importantes durante a perfuração do poço, seja para maximizá-la ou para mantê-la em um valor limite.

Diversas variáveis têm um impacto direto na ROP, tais como vazão, rotação da broca (RPM), peso sobre broca (*weight on bit*, ou simplesmente WOB), diâmetro da broca, entre outros (BOURGOYNE *et al*, 2001; ROCHA e AZEVEDO, 2007). Entretanto, deve-se evitar a manipulação de determinados parâmetros para o controle da ROP, pois outras variáveis podem ser afetadas. A vazão, por exemplo, é escolhida de forma a maximizar as condições de limpeza do poço e não para se obter uma certa taxa de penetração. Sendo assim, os parâmetros de manipulação mais fáceis (e também mais efetivos) para o controle da ROP são a rotação da broca (RPM) e o peso sobre broca (WOB).

Entretanto, nota-se, na prática, que existem múltiplas combinações de RPM e WOB que levam a uma mesma resposta na taxa de penetração. A otimização dos parâmetros operacionais durante a perfuração de um poço consiste em determinar a melhor escolha possível de RPM e WOB de forma a se obter a ROP desejada.

A escolha da combinação ideal de parâmetros operacionais para se atingir uma determinada ROP é uma tarefa bastante difícil. Uma escolha inadequada pode levar a um gasto excessivo de energia, com aumento excessivo da vibração de coluna e consequente redução da vida útil da broca e demais equipamentos de fundo de poço. O par de RPM e

WOB ideal é aquele que leva à taxa desejada com o menor gasto de energia possível (BOURGOYNE *et al*, 2001). Hoje em dia, a escolha destes parâmetros é feita na base da tentativa e erro e não existe uma metodologia bem definida para este propósito (AADNOY, 2009). Esta dissertação trata do desenvolvimento de uma metodologia para a escolha do par ótimo de RPM e WOB, em tempo real, durante a perfuração de poços de petróleo.

1.1 Motivação e Objetivos

A análise de dados em tempo real é uma questão que vem ganhando extrema importância na indústria do petróleo (GANDELMAN *et al*, 2010; OORT e BRADY, 2011; ARAGAO *et al*, 2005). As operadoras têm feito vultuosos investimentos em sensores e infraestrutura para a disponibilização de parâmetros operacionais em tempo real durante a perfuração. A análise destes dados, quando bem feita, é uma ferramenta extremamente poderosa para a detecção e prevenção de problemas, o que leva, evidentemente, a uma redução de tempo de perfuração, custos e riscos (GANDELMAN, *et al*, 2009; ROMMETVEIT e VEFRING, 2004). Assim, entende-se que o desenvolvimento de uma metodologia para otimização dos parâmetros operacionais em tempo real, de forma a se atingir a ROP desejada com o mínimo gasto de energia, trará enormes benefícios para a indústria. Além disso, a perfuração de um poço é um processo intrinsecamente transiente, onde as condições operacionais (vazão, torque, taxa de penetração, litologia, profundidade, etc) mudam constantemente. Isto dificulta muito a previsão dos parâmetros operacionais ótimos na etapa de projeto, tornando ainda mais importante o uso de uma metodologia de otimização em tempo real com base nos parâmetros operacionais correntes. Entretanto, não existe ainda uma metodologia eficaz para tal.

A otimização da taxa de penetração (ROP) é uma das questões mais difíceis e importantes durante a perfuração de poços de petróleo. A maximização da ROP é, na maioria das vezes, o objetivo dos engenheiros de perfuração. Entretanto, existem alguns fatores que obrigam os engenheiros e projetistas envolvidos na operação a limitar a velocidade de avanço da broca, tais como pressão de fundo de poço, limite operacional dos equipamentos de fundo de poço e condições inadequadas de limpeza de poço. Assim, muitas vezes, é necessário fixar um limite máximo para a ROP (ROCHA e AZEVEDO, 2007). A ROP depende de uma série de parâmetros operacionais, sendo que os únicos cuja manipulação é possível são vazão, pressão de fundo de poço, peso sobre broca e rotação da broca.

Vazão e pressão de fundo estão diretamente ligados a dois pontos de extrema criticidade durante a perfuração: limpeza e segurança de poço. Desta forma, vazão e pressão de fundo são definidas, em projeto, de modo a atender estes dois requisitos e não a ROP, o que torna impossível ou muito limitada suas manipulações para este fim. Assim, os únicos parâmetros disponíveis para controle da taxa de penetração são peso sobre broca e rotação da broca.

Porém, verifica-se na prática que existem múltiplas combinações possíveis de rotação e peso sobre broca que, mantendo-se constantes os demais parâmetros operacionais, geram uma mesma taxa de penetração. É muito comum, durante uma perfuração, que o sondador (pessoa responsável por controlar a rotação, peso sobre broca, vazão, etc) se veja obrigado a limitar um dos parâmetros operacionais, seja por problemas ou por limitações dos equipamentos. Um problema no *topdrive* (equipamento responsável por transmitir rotação à coluna de perfuração), por exemplo, pode obrigar o sondador a reduzir a rotação da broca. Em um caso como este, para evitar uma redução da taxa de penetração, o sondador compensa a perda (ou redução) da rotação aumentando o peso sobre broca.

Por outro lado, uma escolha errada do par de rotação e peso sobre broca pode levar a um desgaste excessivo da broca e da coluna de perfuração ou a um gasto de energia desnecessário na perfuração (AADNOY, 2009). Dependendo da rotação e do peso sobre broca escolhidos, pode-se gerar vibrações excessivas ou flambagem na coluna de perfuração, que são extremamente nocivas para a broca e outros equipamentos de poço, reduzindo a vida útil destas ferramentas e aumentando a quantidade de manobras (retirada de coluna) para substituição das mesmas. Dependendo da profundidade do poço, uma manobra pode durar cerca de 50 horas, o que representa um aumento substancial no custo do poço.

Para medir a quantidade de energia disponibilizada na broca durante a perfuração das formações geológicas, usa-se o conceito de Energia Mecânica Específica (EME) (BOURGOYNE *et al*, 1991). Durante a perfuração, busca-se sempre trazer a energia mecânica específica na broca ao valor mínimo necessário para perfurar a formação geológica em questão. Uma energia mecânica específica muito elevada é um indício de que uma parte da energia aplicada à broca para a perfuração está sendo perdida na geração de vibração excessiva, flambagem de coluna e desgaste de broca. Se, para uma mesma taxa de penetração, existir um par de rotação e peso sobre broca que gere uma energia mecânica específica menor, este par deve ser usado em detrimento daqueles que gerem um maior gasto de energia.

Isto torna evidente a necessidade de otimização dos parâmetros operacionais (especialmente peso sobre broca e rotação da broca) para manter a taxa de penetração nos

níveis desejados durante a perfuração de poços, de forma a minimizar a energia mecânica específica na broca. Entretanto, a busca pelo par ótimo de rotação e peso sobre broca depende fortemente de um modelo confiável para previsão da taxa de penetração.

A principal dificuldade para o desenvolvimento deste tipo de metodologia é a falta de um modelo confiável para previsão da ROP. Existem na literatura alguns poucos modelos para a previsão da taxa (MAURER, 1965; YOUNG, 1969; BOURGOYNE e YOUNG, 1974). Porém, estes modelos ou são extremamente restritos (conseguem prever bem o comportamento esperado para a taxa apenas nas regiões para as quais foram desenvolvidos) ou são extremamente complexos, necessitando de parâmetros (tais como tempo de trânsito), que raramente estão disponíveis em tempo real, o que inviabiliza seu uso para este fim.

Este trabalho tem como objetivo o desenvolvimento de uma metodologia para otimização de parâmetros operacionais (peso sobre broca e rotação da broca), com a utilização de redes neurais para a previsão da taxa de penetração. Este tipo de análise é difícil de ser feita, mas, ao mesmo tempo, bastante importante. Uma metodologia capaz fornecer a combinação ótima de rotação e peso sobre broca para uma determinada taxa de penetração tem não só o potencial de reduzir consideravelmente os custos de uma perfuração como também de reduzir o tempo de operação. Uma vez que se reduz o tempo de perfuração, reduz-se também o tempo em que as formações geológicas ficam expostas, reduzindo as chances de desestabilização e diminuindo drasticamente os riscos operacionais.

1.2 Organização

Os capítulos desta dissertação estão dispostos da seguinte forma:

O capítulo de *Revisão Bibliográfica* apresenta as variáveis envolvidas no problema de previsão de taxas de penetração durante a perfuração de poços de petróleo. É feita também uma revisão sobre modelos comumente usados por engenheiros de perfuração para a previsão de taxas de penetração. É apresentada, por fim, uma breve revisão de fundamentos sobre redes neurais e sobre o algoritmo de otimização PSO, que será testado para a otimização de parâmetros operacionais.

O Capítulo de *Metodologia* mostra os dados usados para o desenvolvimento das redes, bem como sua procedência e o tratamento realizado para eliminar ruídos que poderiam influenciar as análises de resultados e conclusões. São mostrados também os tipos de

arquitetura de redes neuronais testadas neste trabalho. Por fim, são apresentadas metodologias para a otimização dos parâmetros em tempo real a serem testadas.

No capítulo de *Resultados e Discussões*, são apresentadas as melhores redes obtidas para cada arquitetura proposta bem como o desempenho de cada uma delas. É feita também uma comparação entre a eficiência das redes neuronais e de outros modelos conhecidos na indústria do petróleo para a previsão de taxas de penetração. Os métodos de otimização de parâmetros operacionais a fim de se obter uma determinada taxa de penetração com EME mínima são testados e comparados entre si.

No capítulo de *Conclusões e Sugestões para Trabalhos Futuros*, é feita uma discussão sobre o desempenho das redes neuronais em prever as taxas de penetração e em prever rotação e peso sobre broca para uma dada taxa de penetração. É feita também uma discussão sobre a eficiência dos métodos propostos para a obtenção de RPM e WOB e suas capacidades em prever corretamente o par ótimo destes parâmetros. Por fim, são feitas considerações finais sobre os resultados obtidos nesta dissertação e recomendações para trabalhos futuros.

CAPÍTULO 2

Revisão Bibliográfica

2.1 Apresentação

Este capítulo se inicia com a apresentação das variáveis envolvidas no processo e suas influências na taxa de penetração. Em seguida, é feita uma revisão sobre os três modelos para previsão de taxa de penetração mais conhecidos e usados por engenheiros de petróleo para este fim. É feita também uma discussão prévia sobre o uso de redes neurais para a previsão de taxas de penetração e do uso deste tipo de paradigma computacional na indústria do petróleo em geral. Por fim, é feita uma revisão sobre redes neurais, retropropagação ou *backpropagation* (método de treinamento de redes usado neste trabalho) e sobre o algoritmo PSO (otimização por enxame de partículas), método de otimização, também testado nesta dissertação.

2.2 Variáveis envolvidas

Diversos parâmetros devem ser considerados no desenvolvimento de qualquer modelo para previsão da ROP. Dentre os inúmeros parâmetros operacionais presentes na perfuração de um poço de petróleo, alguns têm influência direta na ROP. A seguir, é feita uma discussão sobre cada um dos parâmetros e a forma com eles influenciam na taxa de penetração.

- **Peso sobre broca (WOB):** Parte do peso da coluna de perfuração é sustentada por um gancho, localizado em superfície, na plataforma. A outra parte do peso é transmitido diretamente à broca. Em superfície, o “sondador” é responsável por controlar o peso transmitido à broca, o que é feito reduzindo ou aumentando a fração do peso da coluna sustentada no gancho, conforme a necessidade e as condições operacionais. Ao se reduzir a fração de peso sustentado no gancho, aumenta-se o peso sobre broca e vice versa. O peso total de uma coluna de perfuração varia muito com a composição da mesma e a profundidade do poço. Um poço de cerca de 5000 m de profundidade tem, tipicamente, uma coluna de perfuração com cerca de 100 toneladas (THOMAS, 2001). O peso aplicado à broca também varia muito, dependendo do tipo de formação e da ROP desejada. Valores típicos variam de zero (quando se deseja interromper a perfuração) a cerca de 30 toneladas. O peso sobre broca tem uma influência direta sobre a taxa de penetração. Quanto maior o peso aplicado à broca, maior será a pressão exercida sobre a formação e mais facilmente ela será perfurada. Este é o parâmetro que tem a maior influência na taxa de penetração e, por isso, é o primeiro a ser variado quando se deseja aumentar ou reduzir a velocidade da perfuração (AADNOY *et al*, 2009). O efeito do peso sobre broca na taxa de penetração tem sido estudado por vários autores, tanto em laboratório quanto em campo. A Figura 2.1 mostra o comportamento geralmente observado da ROP com a variação do peso sobre broca, mantendo-se todos os demais parâmetros operacionais constantes. Nenhuma taxa de penetração significativa é obtida até que se atinja um valor mínimo de peso sobre broca (abaixo do qual, a broca não consegue transmitir à rocha energia necessária para quebrá-la), o que acontece no ponto A. Em seguida, a taxa de penetração cresce rapidamente com o aumento do peso sobre broca (segmento AB), até que um comportamento linear é obtido (segmento BC). Entretanto, a partir de um determinado valor de peso

sobre broca, os ganhos na taxa de penetração observados com o aumento do peso começam a ser reduzidos (segmento CD). Em alguns casos, chega-se a observar uma queda na taxa de penetração para valores de pesos sobre broca muito elevados (segmento DE). A perda de eficiência na taxa de penetração com o aumento do peso sobre broca se deve a dois fatores. O primeiro deles é a queda na eficiência de remoção de sólidos do poço. Uma taxa de penetração elevada gera uma quantidade de sólidos muito grande, que não é removida adequadamente. Assim, a broca necessita retrabalhar sólidos já perfurados (e não removidos), o que reduz sua eficiência. O segundo fator é que um peso excessivamente alto sobre a broca causa flambagem e vibração de coluna, dissipando parte da energia que deveria ser transmitida à broca para o corte das formações geológicas (BOURGOYNE *et al*, 1991).

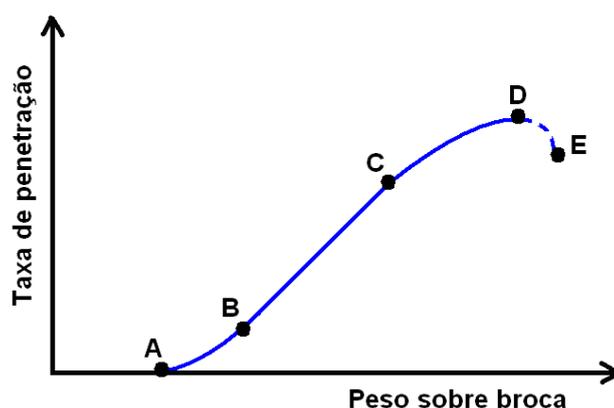


Figura 2.1. Comportamento esperado da taxa de penetração com o peso sobre broca

- Diâmetro da broca: O diâmetro da broca (ou diâmetro da fase) é outro fator que tem influência direta sobre a taxa de penetração. Um poço de petróleo é perfurado em fases de diâmetros cada vez menores. Quando se aplica um peso sobre a broca, o mesmo é transmitido à formação através da área de contato entre a broca e a mesma. Assim, quanto maior for o diâmetro da broca, menor será a pressão aplicada à formação. Ou seja, para um mesmo valor de peso sobre broca, quanto menor for o diâmetro da fase, mais facilmente as formações geológicas serão perfuradas (maior será a ROP) (AADNOY *et al*, 2009). Apesar de ter grande influência na ROP, não se pode manipular o diâmetro da broca para o controle da taxa de penetração, uma vez que este diâmetro é definido, em projeto, com base em uma série de outros pontos tais como, janela

operacional, extensão de cada fase, profundidade final do poço, tipo de óleo e de reservatório, etc (ROCHA e AZEVEDO, 2007).

- Diferencial de pressão poço-formação (*overbalance*): Todas as formações geológicas perfuradas contêm fluidos (gases ou líquidos) em seus poros e, conseqüentemente, têm uma “pressão de poros”. Conforme citado anteriormente, durante a perfuração de um poço, a pressão no mesmo deve ser mantida acima da pressão de poros para evitar o influxo dos fluidos nativos para dentro do poço, pois isso representa um sério risco operacional. Assim, em uma perfuração convencional, existe sempre um diferencial positivo de pressão entre o poço e as formações perfuradas, também chamado de *overbalance* (THOMAS, 2001). Quanto maior for o diferencial de pressão entre poço e formação, maior será a pressão mantendo os sólidos recém (ou prestes a serem) perfurados aderidos à parede do poço. Logo, quanto maior for o *overbalance*, maior será a dificuldade de a broca cortar as formações. O *overbalance* também não é uma variável que se possa manipular para o controle da ROP. O *overbalance* aplicado no poço é determinado em projeto e leva em conta questões de segurança de poço, integridade das formações e do reservatório (WALDMANN, 2005).
- Rotação da broca (RPM): Junto com o peso sobre broca (WOB) a rotação é um dos parâmetros com maior influência na taxa de penetração. O aumento da rotação da broca aumenta a energia transmitida à formação o que ajuda no corte da mesma (BOURGOYNE, 1991). Entretanto, há um limite para o efeito do aumento da rotação da broca. O aumento excessivo da rotação pode causar vibrações na coluna de perfuração, dissipando parte da energia que deveria ser transmitida à broca. Isto causa a redução da taxa de penetração, além de desgaste da broca, dos equipamentos de fundo e, em casos extremos, fadiga e quebra da coluna de perfuração (WOLF; ARIAN, 1985). A Figura 2.2 mostra o comportamento típico esperado da taxa de penetração com a rotação da broca, mantendo-se constante todos os demais parâmetros operacionais. É esperado um aumento linear da taxa de penetração até um determinado valor de rotação da broca (Ponto B), a partir do qual a eficiência de corte diminui. Assim como no caso do peso sobre broca, a queda da eficiência na taxa de penetração se deve a

dois fatores: baixa eficiência na remoção dos sólidos gerados pela broca e dissipação de energia por vibração de coluna.

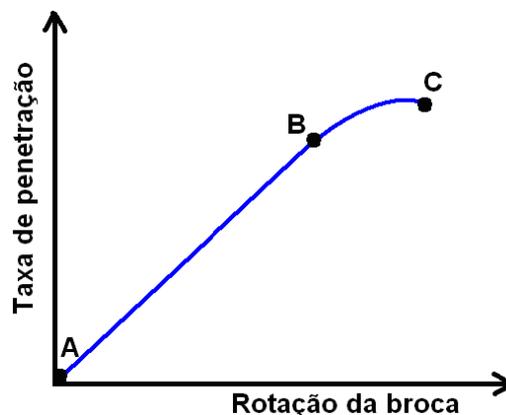


Figura 2.2. Comportamento esperado da taxa de penetração com a rotação da broca

- **Vazão:** A vazão pode atuar de duas formas distintas e antagônicas na taxa de penetração. Ao passar pelos jatos da broca, parte da energia do fluido é convertida em energia de impacto hidráulico, o que auxilia o corte da formação. Assim, um aumento da vazão leva a um aumento da energia hidráulica de impacto o que causa um aumento da taxa de penetração (JAMES *et al*, 2003). Entretanto, nos cenários perfurados atualmente, as profundidades de água estão cada vez maiores, bem como as profundidades finais dos poços. Isto gera uma perda de carga muito elevada (tanto no interior da coluna quanto no anular), fazendo com que as pressões de bombeio atingidas cheguem perto dos limites dos equipamentos disponíveis no mercado e obrigando os engenheiros projetistas de perfuração a abrir mão da força de impacto e usar brocas com jatos de diâmetros maiores. Por outro lado, deve-se levar em conta também o efeito da vazão na pressão de fundo de poço. Um aumento ou diminuição na pressão causada pela vazão também vai influenciar na ROP. O aumento da vazão leva a um aumento das perdas de carga no anular do poço, o que tende a aumentar a pressão de fundo. Entretanto, o aumento da vazão também leva a melhora nas condições de limpeza do poço, ou seja, redução da concentração volumétrica de sólidos, o que, por sua vez, tende a reduzir a pressão de fundo. Assim, o efeito líquido da variação da vazão na pressão de fundo (e, conseqüentemente, na ROP) não é obvio e dependerá de variáveis tais como reologia do fluido de perfuração, faixa de vazão em que a análise é feita, nível de concentração de sólidos e geometria do poço (ARAGAO *et al*, 2005). A Figura 2.3

mostra o comportamento esperado da pressão com a vazão. Assim, o efeito líquido da vazão na taxa de penetração depende da soma de dois efeitos antagônicos. Seu aumento geralmente leva a uma melhora da taxa de penetração, mas o contrário também pode acontecer, dependendo das condições do processo.

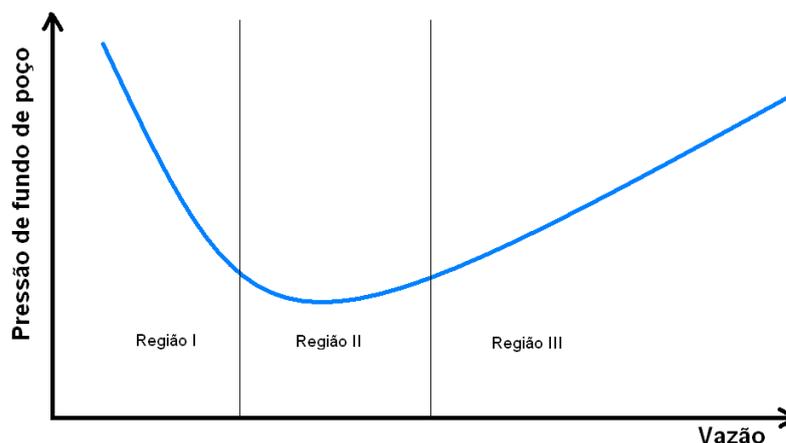


Figura 2.3. Comportamento da pressão de fundo como função da vazão

- Profundidade vertical do poço: Quanto maior a profundidade vertical do poço, maior é o peso exercido sobre as camadas geológicas e mais compactadas estarão as rochas. Assim, as rochas localizadas em regiões mais profundas tenderão a exigir uma energia maior para serem perfuradas. Em outras palavras, o aumento da profundidade geralmente torna as rochas mais difíceis de serem perfuradas (BOURGOYNE, 2001). Desta forma, à medida que a profundidade vertical do poço aumenta, é esperada uma redução na taxa de penetração, mantendo-se constante os demais parâmetros operacionais.
- Litologia: A litologia, junto com rotação e peso sobre broca, é um dos fatores que mais influenciam a taxa de penetração. De fato, a litologia é a variável que mais afeta a ROP. Diferentes litologias requerem diferentes valores de energia para serem perfurados. Por exemplo, arenitos e folhelhos são rochas relativamente fáceis de serem perfuradas. Já margas e carbonatos albianos costumam apresentar uma dificuldade grande durante a perfuração. Evidentemente, a litologia não é uma variável que se possa manipular para o controle da taxa. Assim, este parâmetro é uma importante entrada de qualquer modelo para previsão de ROP e os demais parâmetros manipuláveis (RPM e

WOB) deverão ter seus valores alterados de forma a manter a taxa de penetração no *setpoint* e anular as perturbações causadas pelas mudanças de formação (MOHRIAK *et al.*, 2009).

- Tempo de Trânsito: O tempo de trânsito é uma variável extremamente importante e útil para a estimativa da perfurabilidade (facilidade em se perfurar) de uma rocha. Uma formação geológica será tão mais fácil de se perfurar quanto menos densa e compactada for. O tempo de trânsito é uma medida obtida por uma ferramenta chamada “sônico”, que é posicionada logo acima da broca. A ferramenta de sônico emite uma onda sonora que se propaga pelas formações geológicas. A própria ferramenta mede a velocidade de propagação da onda. Quanto mais densa for a formação, mais rapidamente a onda se propagará, ou seja, menor será o tempo de trânsito. Assim, geralmente, quanto menor o tempo de trânsito de uma determinada rocha, mais difícil será sua perfuração (BOURGOYNE, 2001). O problema do uso desta informação é que na grande maioria dos poços não se faz uso da ferramenta de sônico e, portanto, esta informação não está disponível. Mesmo naqueles poços em que a ferramenta de sônico está presente, estes dados não são disponibilizados em tempo real, servindo apenas para fins de retro análises.
- Composição da coluna de perfuração: A coluna de perfuração é, basicamente, constituída por três elementos principais: comandos (*drill collars*), tubos pesados (*heavy weights*) e tubos de perfuração (*drill pipes*). Os comandos são tubos de aço que possuem uma parede de grande espessura. São extremamente pesados e sua função é gerar peso sobre a broca. Por possuírem paredes muito grossas, são muito pouco flexíveis. Os tubos de perfuração, em contraste com os comandos, são tubos de aço que possuem uma parede de pequena espessura. Seu peso é significativamente inferior aos do comando e são muito flexíveis. Sua principal função é a de permitir a perfuração de poços direcionais, ou seja, com ângulos em relação à vertical que podem chegar a até 90° (no caso de poços horizontais), o que exige flexibilidade das colunas de perfuração. Os tubos pesados são idênticos aos tubos de perfuração, mas possuem um diâmetro interno menor, o que os torna mais pesados e menos flexíveis que os primeiros. Sua função é funcionar como um elemento de transição dentre os comandos

(bastante rígidos) e os tubos de perfuração (bastante flexíveis), evitando flambagem excessiva da coluna. Em um poço vertical, geralmente, os comandos são posicionados acima da broca, seguidos dos tubos pesados e pelos tubos de perfuração, nesta ordem. Em poços inclinados e horizontais, a configuração da coluna segue um padrão inverso. Os comandos são, geralmente, posicionados acima dos tubos pesados, pois se fossem posicionados no trecho horizontal, perderiam a capacidade de transmitir peso à broca. A composição da coluna de perfuração é um ponto chave no projeto de qualquer poço de petróleo. A eficiência da coluna em transmitir energia à broca é função da quantidade de cada um destes elementos e de suas posições. Uma coluna composta apenas por tubos de perfuração seria extremamente flexível e apresentaria má eficiência na transmissão de energia à broca. Já uma coluna composta apenas por comandos, seria muito rígida e apresentaria alta eficiência na transmissão de energia à broca, mas geraria uma pressão de bombeio proibitiva e impossibilitaria a construção de poços direcionais (ROCHA e AZEVEDO, 2007). As quantidades de comandos, tubos pesados e tubos de perfuração devem ser definidas de forma a maximizar a transmissão de peso sobre broca e minimizar a perda de carga. A composição ideal de uma coluna de perfuração depende de uma série de fatores, tais como profundidade final e geometria do poço e quanto peso se espera aplicar à broca durante a perfuração. Uma coluna de perfuração mal projetada gerará muita flambagem, o que reduz o peso efetivo aplicado à broca e, conseqüentemente, reduz a taxa de penetração (BOURGOYBE, 2001).

2.3 Modelos para previsão da taxa de penetração

Existem, na literatura, alguns modelos para previsão da taxa de penetração com base nos parâmetros operacionais. Entretanto, a eficiência destes modelos é muito limitada. Na grande maioria, os modelos tratam o fenômeno de forma bastante simplificada e são desenvolvidos para a previsão da ROP em uma determinada região e sob condições muito específicas. A generalização do uso destes modelos para outras regiões e outras condições leva a resultados totalmente diferentes dos observados na prática.

Três modelos são muito difundidos e usados na indústria do petróleo: os modelos de Maurer, Young e Bourgoyne, que serão descritos a seguir.

2.3.1 Modelo de Maurer

Maurer (MAURER, 1965) desenvolveu um modelo para a previsão da taxa de penetração com base no diâmetro da broca, perfurabilidade (dificuldade em se perfurar) da rocha e nos dois parâmetros que mais a influenciam: peso sobre broca (WOB) e rotação da broca (RPM). Embora o modelo tenha sido desenvolvido para um tipo específico de broca, chamadas de brocas tricônicas, ele é geralmente empregado para qualquer tipo de broca. A equação foi desenvolvida com base nas seguintes observações, feitas em experimentos em escala de bancada:

- 1) O aumento da rotação da broca leva a um aumento da velocidade de avanço da mesma.
- 2) Só existe avanço da broca (ROP) a partir de um determinado valor de peso.

Assim, Maurer sugeriu a relação mostrada na Equação 2.1 para a previsão da taxa de penetração.

$$ROP = a \cdot (RPM) \cdot \left(\frac{WOB}{d_b} - b \right)^2 \quad (2.1)$$

onde: d_b é o diâmetro da broca; a e b são constantes características de cada tipo de rocha e que devem ser determinadas experimentalmente.

A perfurabilidade da rocha (característica de cada tipo de formação geológica) está embutida nos parâmetros a e b . Quanto mais difícil for a perfuração de uma determinada rocha, menor será a e maior será b . A dificuldade na determinação de a e b é que pode haver uma grande variação destes parâmetros mesmo para uma única litologia. As condições às quais uma rocha está submetida podem causar uma variação pronunciada em sua perfurabilidade. Por exemplo, um afloramento de arenito em superfície tem uma perfurabilidade muito maior do que um arenito localizado a 3000m de profundidade. A 3000m de profundidade, o mesmo arenito está submetido a uma pressão (gerada por todas as rochas acima) extremamente elevada, que causa uma compactação significativa, aumentando em muito a dificuldade em perfurá-lo. Além disso, um arenito submetido a tensões geradas por movimentos tectônicos, por exemplo, também apresentará uma perfurabilidade muito diferente de um arenito localizado em uma região sem tectonismo.

Desta forma, as constantes a e b do modelo de Maurer não podem ser determinadas para um tipo geral de rocha, mas sim para cada tipo específico de rocha encontrada no poço em análise.

Outra limitação do modelo é que não são levadas em conta variáveis que, sabidamente, afetam a taxa de penetração, tais como vazão, *overbalance* e diâmetro de broca.

Entretanto, mesmo com as limitações observadas, o modelo de Maurer é muito utilizado para previsões de taxa de penetração. Costuma-se utilizar valores padrão de a e b para cada região (Golfo do México, Bacia de Campos, Mar do Norte, etc). Eventualmente, bons resultados são obtidos para baixos valores de peso sobre broca (correspondentes ao segmento AB da Figura 2.1) e baixos valores de rotação da broca (correspondente ao segmento AB) da Figura 2.2.

2.3.2 Modelo de Young

O modelo de Maurer é incapaz de prever o comportamento não linear da taxa de penetração com a rotação da broca. Segundo o modelo mostrado na Equação 2.1, a taxa de penetração aumenta indefinidamente com o aumento da rotação, o que não é real. Young (YOUNG, 1969) foi pioneiro no desenvolvimento de um sistema de controle computadorizado para a perfuração e propôs um novo modelo para a previsão da taxa de penetração, mostrado na Equação 2.2.

$$ROP = K \left(\frac{WOB}{d_b} \right)^c (RPM)^d \quad (2.2)$$

onde: K , c e d são constantes do modelo que devem ser determinadas para cada tipo de rocha.

A exemplo do que ocorre no modelo de Maurer, a perfurabilidade da rocha é refletida nos valores das constantes do modelo. Quanto mais fácil for a perfuração de uma determinada rocha, maiores serão os valores de K , c e d . Porém, como citado anteriormente, um mesmo tipo de rocha pode apresentar perfurabilidades extremamente diferentes, dependendo das condições às quais está submetida. Assim, novamente as constantes do modelo devem ser determinada para cada tipo de rocha contida em um determinado poço.

Além disso, o modelo de Young apresenta muitas das limitações observadas no modelo de Maurer. Apesar de ser capaz de prever o comportamento não linear da ROP com a rotação da broca, o modelo de Young também não leva em conta parâmetros importantes para a taxa de penetração, tais como a vazão, *overbalance* e o diâmetro da broca.

Assim como o que ocorre com o modelo de Maurer, o modelo de Young também costuma ser usado com valores padrões de K , c e d para cada região.

2.3.3 Modelo de Bourgoyne

Os modelos de Maurer e Young, apesar de largamente utilizados na indústria do petróleo, apresentam sérias limitações e seus resultados são geralmente incompatíveis com o que se observa em campo. O principal problema dos dois modelos é que eles tentam descrever um processo de extrema complexidade de forma muito simplificada. Para tentar obter previsões mais acuradas para a taxa de penetração, Bourgoyne e Young (BOURGOYNE e YOUNG, 1974) propuseram um novo modelo para descrever o comportamento da ROP, muito mais abrangente e complexo.

Os autores observaram que o comportamento da taxa de penetração com os demais parâmetros operacionais se aproxima muito de uma curva exponencial, seja de crescimento ou de decaimento. Por exemplo, mantendo-se, na medida do possível, todos os parâmetros operacionais constantes, observa-se que a taxa de penetração decai exponencialmente com o aumento da profundidade do poço. Da mesma forma, observou-se que a taxa decai exponencialmente com o aumento da força compressiva (parâmetro relacionado à perfurabilidade) da rocha.

Assim, os autores propuseram um modelo que tenta descrever este tipo de comportamento da taxa de penetração com 8 parâmetros que consideraram chaves: 1) Perfurabilidade da rocha; 2) Profundidade; 3) Compactação; 4) *Overbalance*; 5) Peso sobre broca dividido pelo diâmetro da broca; 6) Rotação da broca; 7) Desgaste da broca e 8) Vazão.

As Equações 2.3 a 2.10 mostram o modelo proposto.

$$ROP = \exp \left(a_1 + \sum_{j=2}^8 a_j x_j \right) \quad (2.3)$$

A previsão do comportamento da taxa de penetração em uma dada formação geológica é feito usando-se a Equação 2.3 e determinando-se as constantes a_1 a a_8 para aquela formação específica. As constantes devem ser obtidas através de uma regressão múltipla com dados reais de perfuração.

A constante a_1 representa o efeito da força compressiva da rocha e é inversamente proporcional ao logaritmo neperiano do quadrado da perfurabilidade (MAURER, 1962). A perfurabilidade da rocha é um parâmetro extremamente difícil de se determinar na prática. Existem correlações para a determinação da perfurabilidade com base nos dados de Sônico (tempo de trânsito). Entretanto, na grande maioria das operações, não se dispõe de uma ferramenta de Sônico. Mesmo naquelas operações em que o Sônico é usado, estes dados não estão disponíveis em tempo real. Isto inviabiliza o uso deste modelo para aplicações em tempo real.

Os termos a_2x_2 e a_3x_3 representam o efeito da profundidade e da compactação na taxa de penetração. x_2 é definido pela Equação 2.4.

$$x_2 = 3.048 - TVD \quad (2.4)$$

tal que TVD (*True Vertical Depth*) é a profundidade vertical do poço, em metros.

A Equação 2.4 assume um decaimento exponencial da ROP em uma formação de compactação normal (MURRAY, 1955; COMBS, 1970).

x_3 é definido pela Equação 2.5.

$$x_3 = TVD^{0.69} (g_p - 1078) \quad (2.5)$$

tal que g_p é a pressão de poros em termos de densidade equivalente.

O número 1078 se refere à pressão de poros (em termos de densidade equivalente e em unidade de kg/m^3) normal, ou seja, a pressão de poros esperada de acordo com a profundidade considerando um histórico geológico de compactação normal. Note que o efeito de compactação, $\exp(a_2x_2 + a_3x_3)$, é normalizado para o valor unitário para o caso de compactação normal a 3.048 m de profundidade vertical.

O termo a_4x_4 modela o efeito do *overbalance*. x_4 é definido pela Equação 2.6.

$$x_4 = TVD(g_p - ECD) \quad (2.6)$$

tal que ECD (*Equivalent Circulation Density*) é a pressão dinâmica no fundo do poço em termos de densidade equivalente.

Note que o termo $(g_p - ECD)$ nada mais é do que o *overbalance*, expresso em termos de densidade equivalente. A Equação 2.6 prevê um decaimento exponencial da taxa de penetração com o aumento do *overbalance*. Dados de campo apresentados por Vidrine e Benit (VIDRINE; BENIT, 1968) e Combs (COMBS, 1970), bem como dados coletados em laboratório por Cunningham e Eenink (CUNNINGHAN; EENINK, 1959) e por Garnier e van Lingen (GARNIER; LINGEN, 1959) confirmam uma relação exponencial entre a taxa de penetração e o *overbalance* observado.

O termo a_5x_5 modela o efeito do peso sobre broca e do diâmetro da fase na taxa de penetração. x_5 é definido pela Equação 2.7.

$$x_5 = \ln \left(\frac{\frac{WOB}{d_b} - \frac{WOB_t}{d_b}}{4 - \frac{WOB_t}{d_b}} \right) \quad (2.7)$$

tal que WOB_t é o peso sobre broca mínimo, abaixo do qual não se observa uma taxa de penetração significativa.

A Equação 2.7 assume que a taxa de penetração é diretamente proporcional ao termo $(WOB/d_b)^{a_5}$, o que é confirmado por dados coletados por Edwards (EDWARDS, 1964), Galle e Woods (GALLE; WOODS, 1963) e Jorden e Shirley (JORDEN; SHIRLEY, 1966).

O termo a_6x_6 modela o efeito da rotação da broca. x_6 é definido pela Equação 2.8.

$$x_6 = \ln \left(\frac{RPM}{100} \right) \quad (2.8)$$

A Equação 2.8 assume que a taxa de penetração é diretamente proporcional à rotação da broca elevada a a_6 , o que é confirmado por dados coletados em campo e o estudo realizado por Combs (COMBS, 1970).

O termo a_7x_7 modela o desgaste de broca. x_7 é definido pela Equação 2.9.

$$x_7 = -h \quad (2.9)$$

tal que h é a fração de altura do mordente da broca que foi desgastado.

Na prática, porém, é extremamente complicado determinar h . O desgaste de broca depende do material de que ela é feita, das condições operacionais e da abrasividade da formação perfurada. Não existe nenhuma correlação confiável para este tipo de estimativa e é impossível medir este parâmetro em tempo real durante a perfuração. Isto representa uma grande dificuldade para o uso do modelo de Bourgoyne.

Por fim, o termo a_8x_8 modela o efeito da vazão na taxa de penetração. x_8 é definido pela Equação 2.10.

$$x_8 = \frac{\rho q}{\mu} \quad (2.10)$$

tal que ρ é a densidade do fluido de perfuração, q é a vazão de fluido de perfuração e μ é a viscosidade aparente do fluido de perfuração no fundo do poço.

O modelo de Bourgoyne contempla uma quantidade muito maior de parâmetros quando comparado aos modelos de Maurer e Young e, por este motivo, gera resultados muito mais próximos dos observados na prática. Entretanto, as constantes a_1 a a_8 precisam ser determinadas para cada poço, o que é um inconveniente. Além disso, o modelo exige um conhecimento sobre o desgaste de broca e sobre a força de compressão das rochas perfuradas, estimada com base no tempo de trânsito.

Embora extremamente difícil, em alguns casos, é possível estimar a força de compressão das rochas (quando os dados de sônico estão presentes em tempo real com base em dados de poços de correlação). Mas dificilmente será possível prever o desgaste de broca. Isso,

virtualmente, inviabiliza o uso deste tipo de modelo para a previsão da taxa de penetração em tempo real.

2.4 Redes Neurais

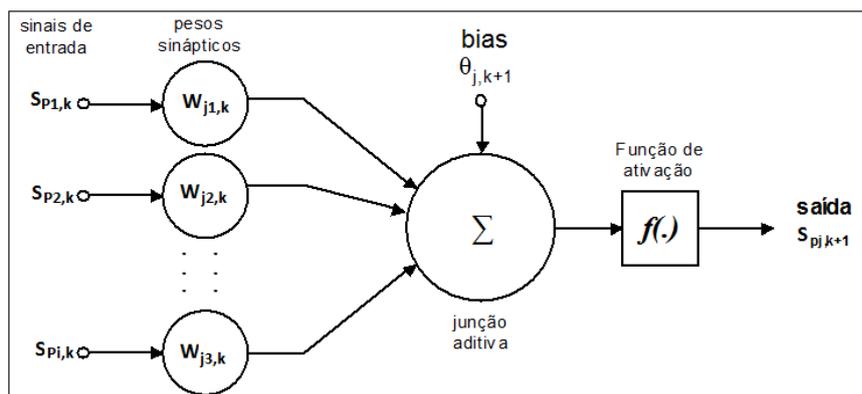
As redes neuronais são compostas por unidades processadoras, ou neurônios, ligadas umas às outras e que interagem localmente através de múltiplas conexões. Em uma rede multicamadas, os neurônios são organizados em camadas e um sinal se propaga pela rede neuronal através das camadas sendo processado em cada unidade processadora. Um neurônio típico recebe uma série de sinais, pré-processados pelos neurônios das camadas anteriores, os soma e processa o somatório através de uma função de ativação. O sinal processado (saída do neurônio) é, então, propagado para os neurônios das camadas seguintes, onde o processo se repete. Os neurônios utilizados em redes neuronais artificiais foram definidos em analogia aos neurônios encontrados em organismos biológicos. Assim, as redes neuronais constituem uma metodologia com capacidade de aprender e reconhecer padrões operacionais (BAGAJEWICZ, 2001).

Estes modelos são identificados através de uma arquitetura, especificada pela característica funcional dos neurônios, pela topologia da rede e pelo algoritmo de treinamento utilizado (HOSKINS; HIMMELBLAU, 1988).

Uma rede neuronal é um processador paralelamente distribuído constituído de unidades de processamento simples, que, analogamente aos neurônios biológicos, tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso (HAYKIN, 2001). O “conhecimento” e o “aprendizado” são armazenados nos valores dos pesos, *bias* e funções contidas em cada uma das conexões e em cada neurônio.

Portanto, todos os neurônios executam sua parcela computacional, onde cada um deles recebe sequencialmente p estímulos externos e possui um limite de ativação inerente (*bias*), gerando uma saída em função deste limite.

Os elementos básicos de um neurônio podem ser vistos na Figura 2.4, apresentando a transformação dos estímulos em uma informação, através do recebimento dos sinais de entrada, da respectiva ponderação pelas sinapses (pesos), da adição ocorrida dentro do elemento principal (*bias*) e da restrição na amplitude de saída de acordo com a função de ativação do mesmo.



Fonte: HAYKIN, 2001.

Figura 2.4. Modelo não-linear de um neurônio j da camada $k+1$

A rede neuronal pode ter inúmeras camadas e inúmeros neurônios em cada uma das camadas. O tamanho e a complexidade da rede refletem o nível de complexidade do processamento da informação. As entradas são sinais recebidos em neurônios específicos (da camada de entrada) e se propagam pela rede até gerar uma ou mais saídas. As entradas podem ser variáveis contínuas ou categóricas (no presente caso: litologias).

Aplicada a um processo industrial, a rede deve ser capaz de fornecer respostas baseadas em um conhecimento adquirido, fornecido em uma etapa de aprendizado prévia. Em linhas gerais, esta rede é constituída por uma camada de entrada, recebendo as informações do processo, uma ou mais camadas escondidas, processando internamente as informações através de suas funções de ativação, produzindo as sinapses, e uma camada de saída, disponibilizando o resultado da análise.

Através de uma rede simples com estrutura *feedforward* (em que os sinais se propagam sempre das camadas mais anteriores para as posteriores), cada neurônio de uma camada recebe as ativações correspondentes às saídas da camada anterior, processando os estímulos enviados pela camada de entrada ao longo das camadas escondidas até a camada de saída, produzindo a resposta (HOSKINS; HIMMELBLAU, 1988). Estas redes são normalmente chamadas de perceptrons de múltipla camada (*Multilayer Perceptron*, MLP) e têm sido aplicadas com sucesso em processos industriais *online*.

Vários autores descreveram a teoria das redes neuronais (DE SOUZA JR, 1993; BISHOP, 1995; HAYKIN, 2001; FORTUNA *et al*, 2007;), incluindo diferentes abordagens e variantes, algoritmos de treinamento e áreas de aplicação. No entanto, as técnicas mais utilizadas em processos industriais são as redes *feedforward* do tipo MLP, com ampla capacidade de generalização, conforme a complexidade da topologia da rede (KADLEC; GABRYS; STRANDT, 2009).

2.4.1 Processamento matemático

A Equação 2.11 mostra o processamento de informação em um neurônio. As saídas (sinais) de cada neurônio da camada anterior são ponderadas individualmente pelo peso (w) correspondente as suas respectivas conexões sinápticas, somadas e adicionadas a um valor limite interno de ativação do neurônio receptor ou *bias* (θ). Na primeira camada da rede, os sinais que cada neurônio recebe são as próprias variáveis de entrada normalizadas. Cada neurônio da camada de entrada é responsável por receber o sinal de apenas uma entrada. Assim, o número de neurônios da primeira camada é igual ao número de variáveis de entrada.

$$\lambda_{pj,k+1} = \left[\sum_{i=1}^{n_k} w_{jik} * s_{pi,k} \right] + \theta_{j,k+1} \quad (2.11)$$

onde: $\lambda_{pj,k+1}$, é a soma ponderada de todas as entradas sinápticas, acrescentado do *bias*, do j -ésimo neurônio da camada $k+1$ analisada, para o padrão p ;

w_{jik} , é o peso correspondente à conexão entre o i -ésimo neurônio da camada k anterior e o j -ésimo neurônio da camada analisada;

$s_{pi,k}$, é o valor de ativação correspondente ao i -ésimo neurônio da camada k anterior;

$\theta_{j,k+1}$, é o limite interno de ativação do j -ésimo neurônio da camada $k+1$ analisada;

k , é o número da camada de neurônios anterior àquela analisada;

j , é o número do neurônio da camada analisada;

p , é o número do padrão entrada-saída;

n_k , é o número total de neurônios da camada anterior àquela analisada.

A resposta calculada pela Equação 2.11 é processada por uma função de ativação, gerando o sinal de saída do neurônio em análise, conforme apresentado na Equação 2.12.

$$s_{pj,k+1} = f_{j,k+1}(\lambda_{pj,k+1}) \quad (2.12)$$

onde $s_{pj,k+1}$, é o sinal de saída correspondente ao padrão p produzido pelo j -ésimo neurônio da camada $k+1$ analisada, após a aplicação da função de ativação;

$f_{j,k+1}(\cdot)$, é a função de ativação correspondente ao neurônio j da camada $k+1$ analisada;

$\lambda_{pj,k+1}$, é a soma ponderada de todas as entradas sinápticas, acrescentado do *bias*, do j -ésimo neurônio da camada $k+1$ analisada, para o padrão p .

As equações responsáveis pelo processamento matemático correspondente à função de ativação do neurônio podem ser funções não-lineares suaves, como por exemplo a logística, a tangente hiperbólica, o seno ou a exponencial (Equações 2.13 a 2.16), ou lineares, como por exemplo as funções identidade (Equação 2.17) (HAYKIN, 2001). A Tabela 2.1 apresenta as equações das principais funções de ativação utilizadas em redes MLP de múltiplas camadas.

Tabela 2.1. Principais funções de ativação utilizadas em redes neuronais do tipo MLP

Função	Equação
logística	$f_{j,k+1}(\lambda_{pj,k+1}) = \frac{1}{1 + e^{-\lambda_{pj,k+1}}}$ (2.13)
tangente hiperbólica	$f_{j,k+1}(\lambda_{pj,k+1}) = \tanh(\lambda_{pj,k+1})$ (2.14)
exponencial	$f_{j,k+1}(\lambda_{pj,k+1}) = e^{\lambda_{pj,k+1}}$ (2.15)
seno	$f_{j,k+1}(\lambda_{pj,k+1}) = \sin(\lambda_{pj,k+1})$ (2.16)
Identidade	$f_{j,k+1}(\lambda_{pj,k+1}) = \lambda_{pj,k+1}$ (2.17)

onde k , é o número da camada anterior àquela analisada;

j , é o número do neurônio da camada analisada;

p , é o número do padrão entrada-saída.

2.4.2 Treinamento por backpropagation

Definida a topologia (número de camadas e número de neurônios em cada camada) e as funções de ativação, a rede neuronal passa por uma etapa de treinamento. O treinamento nada mais é do que o ajuste dos pesos e *biases* de modo a que a rede gere as respostas esperadas de um determinado sistema. Em um método de treinamento assistido, uma série de padrões, cujas entradas e saídas são conhecidas, é apresentada a uma rede neuronal e seus parâmetros são ajustados de forma a reproduzir os padrões. Em outras palavras, o treinamento nada mais é do que o processo de “aprendizagem” da rede neuronal. Durante esta etapa, são calculados os parâmetros das funções de ativação de cada neurônio, permitindo que cada nó alcance o grau de ativação correto para uma determinada matriz de padrões. Uma técnica heurística para

o treinamento das redes MLP é denominada de *backpropagation* (RUMELHART; MCCLELLAND, 1986).

A técnica heurística de *backpropagation*, utilizada no treinamento de redes neurais do tipo MLP, é baseada na minimização de uma função erro, apresentada na Equação 2.18.

A função erro é utilizada para avaliar o desempenho da rede neuronal ao longo do treinamento, comparando os valores fornecidos como alvo à rede com os resultados preditos pela mesma ao adotar uma determinada parametrização. Uma das funções de erro utilizadas em testes de desempenho para modelos de redes neurais é a soma do quadrado dos erros (BISHOP, 1995). Quanto menor o erro, melhor o desempenho da rede. A Equação 2.18 mostra a função utilizada pelo pacote *Statistica Automated Neural Networks* (SANN), disponível no *software* Statistica[®] versão 8, a partir do qual foram realizados os estudos desta dissertação.

$$E_{SOS} = \sum_{p=1}^P \sum_{i=1}^N (Y_{i,p} - Yrn_{i,p})^2 \quad (2.18)$$

onde E_{SOS} , é a função soma do quadrado dos erros;

$Y_{i,p}$, é o valor de processo obtido para a i -ésima variável de saída, para o padrão p ;

$Yrn_{i,p}$, é o valor calculado pela rede neuronal para a i -ésima variável de saída, para o padrão p ;

N , é número total de variáveis de saída na rede neuronal;

P , é número total de padrões.

As redes treinadas por *backpropagation* empregam os métodos de otimização do gradiente descendente e/ou gradiente conjugado (LEONARD; KRAMER, 1990). Neles, inicialmente, todos os parâmetros das funções de ativação (pesos e *biases*) da rede selecionada são definidos em um valor real, entre $-0,5$ e $0,5$, escolhidos aleatoriamente. Um dos padrões é fornecido aos neurônios de entrada e propagado ao longo da rede, produzindo um vetor Yrn_p . Se o erro encontrado para este padrão for menor do que um valor de tolerância, os pesos são mantidos, caso contrário, os pesos são recalculados iterativamente, de acordo com a Equação 2.19 (BISHOP, 1995). Essas iterações ocorrem sucessivamente, com o intuito de reduzir o erro ao longo do treinamento, até que o gradiente seja menor do que a tolerância admitida, definindo os valores ótimos para cada parâmetro (RUMELHART e MCCLELLAND, 1986).

$$\Delta w_{k+1} = -\eta \nabla E_{SOS} \quad (2.19)$$

onde: Δw_{k+1} , é a diferença entre os pesos w obtidos para iterações adjacentes;

η , é a taxa de aprendizado, um valor positivo com magnitude geralmente inferior a 1
(DE SOUZA JR,1993);

∇E_{SOS} , é o gradiente do erro na iteração $k+1$.

A primeira fase do método de treinamento é a propagação dos sinais de entrada de um padrão pela rede (desde a camada inicial até a última). Para cada padrão p ($p = 1, 2, \dots, N_p$), tem-se um conjunto de entradas $s_{pj,0}$ ($j = 1, 2, \dots, n_i$) - onde n_i corresponde ao número de neurônios na camada de entrada - e um conjunto de saídas desejadas t_{pi} ($i = 1, 2, \dots, n_i$) - onde n_i corresponde ao número de neurônios na camada de saída. Apresenta-se um padrão p , por vez, à rede (DE SOUZA JR,1993).

A passagem pela primeira camada de neurônios, produz as ativações, mostradas na Equação 2.20, em que $j = 1, 2, 3, \dots, n_i$.

$$S_{pj,1} = f(S_{pj,0}) \quad (2.20)$$

Onde f é a função de ativação dos neurônios, dadas pelas Equações 2.13 a 2.17.

Na saída da camada escondida, tem-se as ativações mostradas nas Equações 2.21.

$$S_{pj,2} = f(\lambda_{pj,2}) \quad (2.21)$$

Sendo $\lambda_{pj,2}$ é dado pela Equação 2.22.

$$\lambda_{pj,2} = \left[\sum_{i=1}^{n_i} W_{ji1} S_{pi,1} \right] + \theta_{j,2} \quad (2.22)$$

Em que $j = 1, 2, 3, \dots, n_h$. n_h corresponde ao número de neurônios da camada escondida.

Na saída da última camada da rede (saída da rede), tem-se:

$$S_{pj,L} = f(\lambda_{pj,L}) \quad (2.23)$$

Em que $\lambda_{pj,L}$ é dado pela Equação 2.24.

$$\lambda_{pj,L} = \left[\sum_{i=1}^{n_h} W_{ji2} S_{pi,2} \right] + \theta_{j,L} \quad (2.24)$$

Isto encerra a primeira fase do método (a propagação do sinal do padrão).

Após a primeira fase, inicia-se a segunda fase: a propagação do erro no sentido inverso ao da propagação dos sinais de entrada do padrão (da última camada até a primeira).

O erro obtido na saída da rede é propagado para trás para atualizar os pesos e *biases*. Primeiro corrigem-se os valores dos pesos entre a camada escondida e a camada de saída e depois, entre a camada de escondida e a camada de entrada (DE SOUZA JR,1993).

Para a atualização dos pesos das conexões entre as camadas escondida e a camada de saída, W_{ji2} , calcula-se o gradiente do erro mostrado na Equação 2.19. É necessário o cálculo de todas as derivadas parciais com relação a cada um dos pesos a serem atualizados. A derivada obtida é mostrada na Equação 2.25.

$$\frac{\partial E}{\partial W_{ji2}} = \sum_{p=1}^{N_p} \frac{\partial E_p}{\partial S_{pj,L}} \frac{\partial S_{pj,L}}{\partial \lambda_{pj,L}} \frac{\partial \lambda_{pj,L}}{\partial W_{ji2}} = \sum_{p=1}^{N_p} (s_{pj,L} - t_{pj}) f'(\lambda_{pj,L}) S_{pi,2} \quad (2.25)$$

Para a atualização dos *biases* da última camada, $\theta_{j,L}$, calcula-se as derivadas parciais do erro em função de cada *bias*. A derivada obtida é mostrada na Equação 2.26.

$$\frac{\partial E}{\partial \theta_{j,L}} = \sum_{p=1}^{N_p} \frac{\partial E_p}{\partial S_{pj,L}} \frac{\partial S_{pj,L}}{\partial \lambda_{pj,L}} \frac{\partial \lambda_{pj,L}}{\partial \theta_{j,L}} = \sum_{p=1}^{N_p} (s_{pj,L} - t_{pj}) f'(\lambda_{pj,L}) \quad (2.26)$$

O mesmo procedimento é adotado para a atualização dos pesos entre a camada de entrada e a camada escondida, W_{ji1} . A derivada obtida para este caso é mostrada na Equação 2.27.

$$\frac{\partial E}{\partial W_{ji1}} = \sum_{p=1}^{N_p} \sum_{l=1}^{n_l} \frac{\partial E_p}{\partial S_{p1,L}} \frac{\partial S_{p1,L}}{\partial \lambda_{p1,L}} \frac{\partial \lambda_{p1,L}}{\partial S_{pj,2}} \frac{\partial S_{pj,2}}{\partial \lambda_{pj,2}} \frac{\partial \lambda_{pj,2}}{\partial W_{ji1}} = \sum_{p=1}^{N_p} \left(\sum_{l=1}^{n_l} (S_{p1,L} - t_{pl}) f'(\lambda_{p1,L}) W_{lj2} \right) f'(\lambda_{pj,2}) S_{pil} \quad (2.27)$$

Para a atualização dos *biases* da última camada, $\theta_{j,2}$, calcula-se as derivadas parciais do erro em função de cada *bias*. A derivada obtida é mostrada na Equação 2.28.

$$\frac{\partial E}{\partial \theta_{j,2}} = \sum_{p=1}^{N_p} \sum_{l=1}^{n_l} \frac{\partial E_p}{\partial S_{p1,L}} \frac{\partial S_{p1,L}}{\partial \lambda_{p1,L}} \frac{\partial \lambda_{p1,L}}{\partial S_{pj,2}} \frac{\partial S_{pj,2}}{\partial \lambda_{pj,2}} \frac{\partial \lambda_{pj,2}}{\partial \theta_{j,2}} = \sum_{p=1}^{N_p} \left(\sum_{l=1}^{n_l} (S_{p1,L} - t_{pl}) f'(\lambda_{p1,L}) W_{lj2} \right) f'(\lambda_{pj,2}) \quad (2.28)$$

As etapas de propagação do sinal do padrão (da primeira à última camada) e de propagação do erro (da última à primeira camada) é repetida e os pesos e *biases* vão sendo atualizados até que o erro obtido seja inferior a uma tolerância pré-estabelecida. Enquanto houver uma diferença entre a saída prevista pela rede e a saída real do sistema, um sinal de erro será propagado da última camada à primeira e será usado para atualização dos pesos e *biases* (DE SOUZA JR,1993).

Após o término do treinamento, a rede está pronta para ser usada. Tem-se, então, apenas a etapa de propagação *feedforward* (da primeira à última camada) dos sinais de entrada.

2.4.3 Treinamento por backpropagation com gradiente conjugado

O método do gradiente descendente com passo fixo, adotado no método de *backpropagation* padrão, é ineficiente. Tem-se muita dificuldade de convergência em função da escolha do tamanho do passo fixo η . Passos pequenos conduzem a uma convergência extremamente lenta - principalmente perto da solução (DE SOUZA JR,1993) - e passos grandes, a oscilações nas variáveis independentes de otimização.

Com o intuito de evitar essas oscilações nos pesos, pode-se somar ao lado direito da Equação 2.19 um termo de momento (RUMELHART e MCCLELLAND, 1986), conforme mostrado na Equação 2.29.

$$\Delta w_{k+1} = -\eta \nabla E_{SOS} + \varepsilon \Delta E_{SOS} \quad (2.29)$$

A modificação acima pode não ser suficiente para resolver o problema de oscilações, para ε tomado fixo.

Dessa forma, apareceram na literatura vários trabalhos com propostas que objetivavam superar as dificuldades de convergência no treinamento via *backpropagation*.

O método de *backpropagation* com gradiente conjugado (LEONARD e KRAMER, 1990), no qual η e ε são ajustados dinamicamente. Neste método, a direção de busca s_{k+1} na iteração $k+1$ é gerada recursivamente conforme as Equações 2.30 a 2.32.

$$s_0 = -\nabla E(W_0) \quad (2.30)$$

$$s_{k+1} = -\nabla E(W_{k+1}) + \varepsilon s_k \quad (2.31)$$

$$\varepsilon = \frac{\nabla E(W_{k+1})^T \nabla E(W_{k+1})}{\nabla E(W_k)^T \nabla E(W_k)} \quad (2.32)$$

O vetor de pesos W_{k+1} é determinado usando-se uma busca unidimensional (interpolação quadrática) para η (LEONARD e KRAMER, 1990), conforme a Equação 2.33.

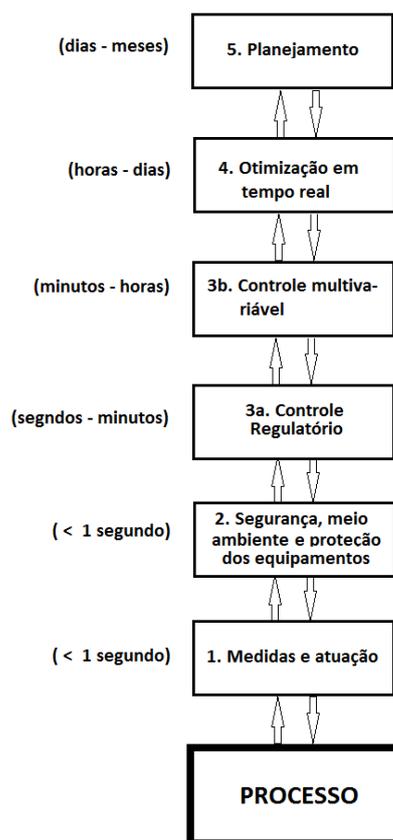
$$W_{k+1} = W_k + \eta s_k \quad (2.33)$$

Ao fazer os ajustes automáticos de η e ε este método pode eliminar as oscilações do gradiente descendente com passo fixo, convergindo mais confiavelmente (DE SOUZA JR, 1993).

2.5 Aspectos relativos à otimização

2.5.1 Conceitos sobre RTO (Real Time Optimization)

A Figura 2.5 mostra os cinco níveis na hierarquia de controle, onde otimização, controle, monitoramento e aquisição de dados são empregados. A escala de tempo relativa a cada um dos níveis também é mostrada. Dados de um processo químico típico (tais como vazões, temperaturas, composições) são usados para a tomada de decisão em tempo real.



Fonte: Seborg *et al*, 2011.

Figura 2.5. Os cinco níveis de controle de processo e otimização em tempo real

O nível mais alto da Figura 2.5 (planejamento) tem o objetivo de atender às demandas logísticas e restrições do processo. O planejamento geralmente tem uma escala de tempo elevada e está desacoplado dos demais níveis.

No nível 4, a otimização em tempo real (RTO) é usada para coordenar as unidades do processo e para fornecer *setpoints* ótimos para cada uma delas. Para controle multivariável com restrições, mudanças nos *setpoints* são feitas no nível 3b. Para controle *single-loop* e *multi-loop*, o controle regulatório é feito no nível 3a.

O nível 2 (segurança, meio ambiente e proteção de equipamentos) inclui alarmes e procedimentos de emergência relativos ao processo e equipamentos.

O nível 1 (medidas e atuação) é responsável pela aquisição de dados e análises e atuações *on-line*. Idealmente há uma comunicação bidirecional entre os níveis, com os níveis mais elevados fornecendo metas para os níveis mais baixos e estes comunicando restrições e performance aos mais elevados. A escala de tempo para tomada de decisões no nível mais elevado é de meses, enquanto que para o nível mais baixo é de segundos.

Historicamente, o foco da otimização em plantas de processos químicos tem sido na fase de planejamento. Porém, desde a década de 1990 isso vem mudando, pois a performance pode ser aumentada otimizando-se as condições operacionais. O mesmo pode ser aplicado à perfuração de poços de petróleo.

Em plantas grandes, o aumento na performance conseguido com otimização em tempo real pode ser substancial. O ponto ótimo de operação pode variar de um dia para o outro ou mesmo ao longo de um dia (SEBORG, 2011). Mudanças que requerem otimização periódica das condições operacionais incluem variações na qualidade e custos dos produtos das correntes de entrada do processo, limites de armazenamento e processamento da planta e demandas de produtos. Fazendo um paralelo com a perfuração de poços, variações que podem requerer otimizações periódicas são: mudança na litologia perfurada, identificação de problemas de limpeza, mudanças climáticas (que podem levar a um *heave* maior do mar), problemas operacionais nas bombas (que podem limitar a vazão de fluido) ou do *topdrive* (que pode limitar a rotação da coluna), etc.

Com avanços recentes na informática, a otimização em tempo real pode ser facilmente incorporada em *softwares* de sistemas de controle. Problemas com mais de 100.000 variáveis e diversas restrições podem ser rapidamente resolvidos (SEBORG, 2011).

No caso desta dissertação, o modelo do processo (velocidade de corte das formações geológicas com base em parâmetros operacionais) é extremamente não linear. Por este motivo, optou-se por um método de otimização heurístico, como o *Particle Swarm Optimization* (PSO), que será explicado a seguir.

2.5.2 PSO (Particle Swarm Optimization)

Particle Swarm Optimization (Otimização por Enxame de Partículas, ou simplesmente PSO) é um método iterativo inspirado no comportamento biológico de cooperação de enxames de abelhas. É um método bastante efetivo para problemas fortemente não lineares.

No método PSO, um “ponto de interesse” corresponde a um mínimo ou máximo (dependendo do tipo de problema em questão) local de uma determinada função, definida em um espaço de busca. Tal função pode ser dada por uma fórmula matemática, um algoritmo, um modelo de rede neuronal ou mesmo pelas saídas de um processo (real ou simulado). O importante é que se possa calcular o valor da função em cada ponto do espaço (KENEDDY e EBERHART, 2001).

Entretanto, o objetivo do método não é achar “pontos interessantes” (máximos ou mínimos locais), mas sim o ponto mais interessante, isto é, o ponto ótimo (máximo ou mínimo) global da função. Para isso, o método PSO se inspira no comportamento cooperativo de abelhas, que, através de um código de movimentos, são capazes de comunicar às demais a posição exata e a qualidade de locais ricos em pólen para que as demais o explorem. Assim, como as abelhas, as partículas do enxame do método PSO comunicam às demais a posição e a qualidade (valor) do ponto mais interessante que cada uma conhece. A cada passo de tempo, uma dada partícula pode receber, de diversas informantes simultaneamente, informações sobre diversos máximos ou mínimos locais, melhores ou piores do que o seu próprio. Cada partícula se beneficia das informações que recebe para definir sua próxima direção de busca (KENEDDY e EBERHART, 2001). Esta operação de síntese de informações para a tomada de decisões e ações ainda não foi totalmente elucidada em sistemas biológicos, mas, no método PSO, é a inspiração para o desenvolvimento de um algoritmo bastante simples de otimização. Apesar de inspirado em comportamento de sistemas biológicos, o algoritmo PSO não modela o comportamento real de abelhas ou de nenhum outro organismo vivo, mas é muito efetivo para a resolução de problemas matemáticos de otimização.

O primeiro passo do método é definir o tamanho do enxame, ou seja, o número de partículas. Tipicamente, o número de partículas usado varia de 20 a 40 (CLERC, 2006). No início da busca, as partículas encontram-se na mesma posição do espaço amostral. Após o primeiro passo de tempo, porém, as partículas estarão dispersas randomicamente. Na ausência de qualquer informação, a distribuição randômica é a melhor escolha. A distribuição das partículas depende da velocidade de cada uma, que, no primeiro passo de tempo, também é randômica.

Também é necessário definir, para cada partícula, quais são suas partículas informantes. Automaticamente, também são determinadas as informantes de cada partícula. Este processo também é feito de forma aleatória (CLERC, 2006).

Se cada partícula recebesse e transmitisse informações de e para todas as demais, toda a informação adquirida seria disseminada pelo enxame imediatamente. Dispondo sempre das mesmas informações, as partículas apresentariam um comportamento uniforme, o que é arriscado. Em problemas altamente não lineares, este comportamento não é efetivo. Por outro lado, se cada partícula tiver poucos informantes, um comportamento mais diversificado seria obtido, mas há o risco de as informações serem transmitidas de forma ineficiente pelo enxame. É importante que, uma vez que uma partícula encontre um ponto promissor, todas as demais sejam informadas para que possam se beneficiar desta informação (KENEDDY e EBERHART, 2001).

Assim, existem dois critérios: diversidade, que aumenta à medida que o número de informantes por partícula diminui, e propagação, que se torna mais rápida e mais completa à medida que o número de informantes por partícula aumenta.

Geralmente, a determinação do número de informantes de cada partícula é feita de forma aleatória escolhendo-se dois ou três informantes para cada uma a cada passo de tempo. Outro método é escolher os informantes de cada partícula de forma aleatória, porém permanente (sem variação a cada passo de tempo).

A cada passo de tempo, cada partícula transmite duas informações: a posição do melhor ponto de interesse identificado pela mesma e seu valor.

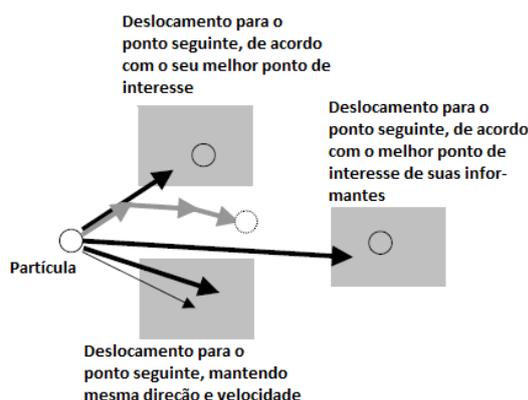
O passo seguinte é também o mais difícil de modelar: a forma como cada partícula, depois de informada, calcula o seu próximo deslocamento. Note que, uma vez que é também uma informante, cada partícula conhece o seu próprio “melhor ponto de interesse”, além dos “melhores pontos de interesse” de suas informantes (KENEDDY e EBERHART, 2001).

Em um caso extremo, a partícula movimenta-se de forma própria, sem levar em conta as informações obtidas em suas explorações e nas informações recebidas de suas informantes. Ou seja, a partícula atribui confiabilidade nula para as informações de suas informantes e para suas próprias. Assim, a partícula segue aproximadamente a mesma direção e velocidade que já vinha seguindo. Este caso extremo está relacionado à inércia da partícula (SCHWAAB e PINTO, 2007). Em um segundo extremo, a partícula conferirá grande confiabilidade em seu próprio melhor ponto de interesse e confiabilidade nula aos pontos de interesse de suas informantes. Assim, tenderá a retornar ao mesmo ponto de forma incessante. Em um terceiro caso extremo, a partícula confere confiabilidade nula às suas próprias informações e se desloca sempre segundo o melhor dos melhores pontos de interesse de suas informantes (CLERC, 2006).

Tem-se, assim, três opções extremas de deslocamentos para cada partícula em cada passo de tempo. A Figura 2.6 mostra os três vetores de velocidade referentes aos três casos extremos expostos. A forma mais simples de calcular o deslocamento da partícula consiste em dar pesos a cada um dos três vetores de velocidade com a ajuda de coeficientes de confiabilidade para cada um.

A eficiência do algoritmo PSO será tanto maior quanto mais bem escolhidos forem os critérios de confiabilidades adotados para a determinação dos pesos de cada um dos três vetores mostrados na Figura 2.5. A formulação do algoritmo PSO é mostrada no capítulo 3 desta dissertação.

No algoritmo PSO, as informações não são sempre transmitidas e mesmo as informações que o são, as mesmas são distorcidas. Esta é uma das vantagens do método.



Fonte: CLERC, 2006.

Figura 2.6. Três vetores fundamentais para o cálculo do deslocamento da partícula a cada passo de tempo

Note que as partículas transmitem apenas o melhor ponto de interesse pelo qual passou em sua exploração pelo espaço de busca. Considere uma partícula A que transmite à partícula B seu ótimo local conhecido. Em geral, a partícula B tem outros informantes. Considere que A não seja a melhor informante de B em um determinado passo de tempo. Neste caso, B não levará em conta a informação de A. Logo a informação transmitida por B para o próximo passo de tempo não conterá nada do que foi informado por A.

Em um segundo caso, A é a melhor informante de B. Assim, B modificará sua posição em função da informação de A. Há, então, duas possibilidades. Ao modificar sua posição de acordo com as informações recebidas de A, a partícula B chega a um ponto pior do que o melhor ponto de interesse que ela própria conhece. Neste caso, a informação transmitida por B no próximo espaço de tempo também não conterá nada da informação recebida por A. A outra possibilidade é que a nova posição de B (obtida seguindo as informações de A) é melhor que seu melhor ponto de interesse prévio. Neste caso, a informação transmitida por B às demais partículas é resultante daquilo que A havia lhe informado, mas de forma distorcida, já que a informação será o resultado da mistura de outros vários outros elementos.

Isto leva a uma maior diversidade de comportamento, o que é muito efetivo na resolução de problemas altamente não lineares (CLERC, 2006).

Em resumo, o modelo de PSO foi desenvolvido com base o exemplo de troca de informações entre abelhas. Cada partícula faz uma combinação linear de três elementos para decidir seus próximos movimentos: sua velocidade corrente, a melhor posição conhecida por ela e a melhor posição obtida de seus informantes. Isto leva a uma distorção na transmissão das informações pelo enxame, o que, por sua vez, leva a uma diversidade maior no comportamento das partículas. Esta diversidade no comportamento é um trunfo poderoso na resolução de problemas altamente não lineares.

Mais detalhes sobre a formulação do algoritmo podem ser encontrados nos trabalhos de Clerc (CLERC, 2006) e Kennedy e Eberhart (KENEDDY e EBERHART, 2001).

2.5.3 Método de Monte Carlo

Um método de otimização bastante adequado para este tipo de problema é o Método de Monte Carlo. O Método de Monte Carlo é um procedimento de busca totalmente aleatório, que pode ser usado para encontrar o ponto ótimo de uma função qualquer. A busca consiste em sortear aleatoriamente um número significativamente grande de pontos numa região de busca e considerar o melhor ponto encontrado como o melhor candidato a ponto ótimo. O procedimento pode ser repetido um número grande de vezes, até que se satisfaçam os critérios de convergência. É simples e robusto, contudo uma desvantagem do método é a necessidade de um número muito grande de avaliações da função objetivo para que se possa ter uma alta probabilidade de que o ponto ótimo tenha sido encontrado com uma precisão razoável (SCHWAAB e PINTO, 2007). Isso eleva muito o custo computacional deste tipo de solução, equiparando-a ao método da varredura exaustiva.

2.6 Uso de Redes Neurais para previsão da taxa de penetração

Os itens 2.3.1 a 2.3.3 descrevem os três modelos mais utilizados na indústria do petróleo para a previsão da taxa de penetração com base nos parâmetros operacionais. Os modelos de Maurer e de Young tratam o fenômeno (corte das formações geológicas) de forma bastante simplificada, o que leva a uma imprecisão extremamente elevada e prejudica em muito a confiabilidade dos resultados obtidos. O modelo de Bourgoyne, por sua vez, traz uma abordagem bem mais completa, mas leva em conta parâmetros cuja medição, na prática, é extremamente difícil ou mesmo impossível. Isto inviabiliza o uso do modelo. Esta situação retrata a grande dificuldade na previsão da taxa de penetração. A perfuração das formações geológicas é um processo de extrema complexidade. Os modelos existentes na literatura são excessivamente simplistas (o que leva a perda de precisão) ou excessivamente complexos (o que dificulta seu uso).

O uso de redes neurais para a previsão da taxa de penetração é uma opção para a modelagem do fenômeno. Redes neurais podem ser treinadas *online*, tendo os pesos e *biases* atualizados à medida que a perfuração ocorre ou podem ser treinadas com base em poços já perfurados e aplicadas a poços da mesma região (com um histórico geológico semelhante).

Entretanto, um cuidado deve ser tomado quando se utilizam redes neuronais, tanto no treinamento quanto na previsão da ROP. O desgaste de broca desempenha um papel fundamental da taxa de penetração e, como comentado anteriormente, é um parâmetro cuja medida direta é virtualmente impossível. Assim, ao se selecionar dados para o treinamento de rede, deve-se assegurar de que não houve desgaste prematuro da broca e que este parâmetro não afetou o comportamento da taxa de penetração. Da mesma forma, ao se utilizar o modelo obtido para a previsão em poços futuros, deve-se ter em mente que, caso haja um desgaste prematuro da broca, o comportamento da taxa será diferente daquele previsto pela rede.

Outro cuidado é que a coluna litológica do poço analisado deve ser conhecida ou, pelo menos, estimada, já que o tipo de formação perfurada (arenito, folhelho, taquidrita, calcilutito, etc) tem grande influência na taxa.

2.6.1 Iniciativas anteriores no uso de redes neuronais para previsão da taxa de penetração

O uso de redes neuronais para a previsão de taxa de penetração é algo relativamente novo na indústria do petróleo e existem poucas iniciativas parecidas.

Uma das primeiras iniciativas neste sentido foi feita por Bilgesu (BILGESU, 1997). Em seu trabalho, Bilgesu usou redes neuronais para prever o desgaste de brocas e, com base nisso, estimar a taxa de penetração com outros modelos. Para isso, usou como entradas da rede variáveis como torque, litologia, peso sobre broca, rotação da broca e a própria taxa de penetração instantânea. A idéia era a obtenção de um modelo para previsão do desgaste de broca e o uso deste modelo para alimentar um outro modelo (o de Bourgoyne, por exemplo) para a previsão da ROP. A limitação do trabalho de Bilgesu é que o modelo foi obtido para um único tipo de formação geológica e um único tipo de broca (tricônica). Logo, a rede neuronal obtida é válida apenas em situações muito restritas.

Mais recentemente, Hedayatzadeh e Hamidi (HEDAYATZADEH e HAMIDI, 2010) desenvolveram um modelo com base em redes neuronais para a previsão da eficiência de turbinas em formações de baixíssima perfurabilidade em poços localizados no Irã. Entretanto, o modelo desenvolvido visava apenas a previsão da eficiência da perfuração (e não da taxa de penetração) em um formação geológica muito específica.

Fora estas iniciativas, para o conhecimento do autor, não foram relatadas outras tentativas do uso de redes neuronais para a previsão de taxas de penetração.

2.7 Otimização em Tempo Real na Perfuração de Poços de Petróleo Offshore

A otimização de parâmetros operacionais em tempo real é um campo da engenharia de petróleo que vem ganhando cada vez mais importância e investimentos, seja para maximizar a taxa de penetração, para maximizar as condições de limpeza de poço ou para aumentar a vida útil dos equipamentos de fundo e de superfície. Os primeiros trabalhos relativos à otimização em tempo real datam da década de 1980 (SIMMONS, 1986), quando foi feita a primeira tentativa de se otimizar os parâmetros operacionais da perfuração para melhorar as condições de limpeza do poço e a performance da taxa de penetração.

Nos anos 2000, JOHN *et al* (2002) mostraram, pela primeira vez, como um grupo de especialistas era capaz de auxiliar os engenheiros de perfuração remotamente com base em informações de parâmetros operacionais recebidas da sonda de perfuração em tempo real. Hoje em dia, este tipo de arquitetura se difundiu pelas companhias operadoras, que construíram Centros de Suporte à Decisão em tempo real (CSD), onde uma equipe multidisciplinar de especialistas acompanham diversos poços, auxiliando o pessoal em sonda a tomar decisões.

Entretanto, este tipo de auxílio é feito de forma extremamente subjetiva. A interpretação dos parâmetros e o diagnóstico, necessários para uma tomada de decisão, dependem do especialista, sua experiência e seus critérios. Ou seja, a análise é feita de forma subjetiva, sem critérios quantitativos.

Algumas iniciativas vêm sendo tomadas para eliminar a subjetividade do processo de análise dos parâmetros em tempo real e melhorar as metodologias de otimização de parâmetros operacionais. GANDELMAN *et al* (2009); GANDELMAN *et al* (2010) e ARAGAO *et al* (2005) vêm desenvolvendo uma metodologia automatizada para análise e interpretação de parâmetros de perfuração para diagnóstico de problemas operacionais com base em critérios quantitativos. A metodologia foi implementada em um *software* (chamado de PWDa - *Pressure While Drilling Analyser*), que vem sendo usado com bons resultados pela Petrobras como uma ferramenta de auxílio à tomada de decisão. O objetivo do *software* é otimizar a perfuração como um todo, reduzindo o tempo perdido e, conseqüentemente, reduzindo o tempo de perfuração e custos operacionais. Entretanto, não há uma metodologia para a otimização da taxa de penetração no *software*. A otimização da perfuração é feita com base na otimização de parâmetros que evitem problemas operacionais relacionados a questões de limpeza de poço, estabilidade mecânica, química e outros aspectos.

Outra iniciativa muito similar foi tomada por Rommetveit *et al* (ROMMETVEIT *et al*, 2004), que vêm desenvolvendo um *software* (chamado de eDrilling) extremamente similar ao PWDa com os mesmos propósitos. O eDrilling é uma ferramenta comercial que vem sendo usado também com sucesso por operadoras como a Statoil, Total e ConocoPhillips.

Ambos os *softwares* (PWDa e eDrilling) possuem uma série de modelos transientes para transporte de sólidos, hidráulica, difusão de calor, torque e arraste, etc. Com base nos parâmetros operacionais em tempo real (tais como vazão, ROP, rotação da coluna, rotação da broca, peso sobre broca, profundidade do poço, profundidade da broca, propriedades reológicas do fluido de perfuração, etc), fazem previsões das condições do poço e de outros parâmetros operacionais, tais como ECD de fundo, torque arraste e pressão de bombeio. Os parâmetros previstos são comparados com os parâmetros reais (medidos pelos sensores de superfície e subsuperfície). Caso ambos (previsto e real) apresentem a mesma tendência ao longo do tempo, isso é um indicativo de que a perfuração corre de acordo com o previsto. Caso as curvas previstas e reais apresentem tendências divergentes ao longo do tempo, isso é um indicativo de que algo não previsto pela modelagem está ocorrendo, o que pode ser ou vir a causar um problema operacional. Quando isso ocorre, o *software* cruza diversas informações e parâmetros para tentar identificar, com base em critérios quantitativos, a causa do comportamento anômalo (GANDELMAN *et al*, 2010).

Outra iniciativa neste sentido foi tomada por Oort e Brady (OORT e BRADY, 2011). Ambos vêm desenvolvendo o *software* DrillEdge, que tem os mesmos propósitos do PWDa e eDrilling (o diagnóstico de problemas operacionais em tempo real), mas utiliza uma metodologia de reconhecimento de padrões, bastante diferente da dos demais *softwares*. O DrillEdge vem sendo testado em operadoras como A Shell e ExxonMobil, também com sucesso.

A quarta e última iniciativa neste sentido vem sendo desenvolvida pelo IRIS (*Intertational Research Institute of Stavanger*), instituto de pesquisa norueguês (ROMMETVEIT e VEFRING, 2004). Eles vêm desenvolvendo o *software* DrillScene que possui uma metodologia bastante similar às do PWDa e eDrilling. Entretanto, diferentemente dos demais *softwares*, o DrillScene não se propõe a identificar problemas operacionais. O *software* apenas faz predição de parâmetros operacionais, tais como ECD, torque, arraste e pressão de bombeio, os compara com os parâmetros reais (medidos) e alarma o operador caso tendências divergentes entre as curvas reais e previstas sejam identificadas. A interpretação para o diagnóstico da causa do comportamento anômalo cabe ao operador.

Entretanto, nenhuma destas iniciativas apresenta uma metodologia específica para otimização de parâmetros com o intuito de se atingir uma determinada ROP com a melhor

eficiência possível. A otimização da perfuração é feita ao se reduzir problemas operacionais e otimização das condições de limpeza do poço. A melhora da taxa de penetração se dá de forma indireta, ou seja, com a redução do tempo não produtivo (devido a problemas operacionais), evidentemente se obterá uma taxa de penetração global mais elevada ao final da perfuração. Mas nada é feito no sentido de otimização de parâmetros operacionais diretamente ligados à taxa. Isto ocorre principalmente pela falta de um modelo abrangente e confiável para previsão da ROP. Todas as iniciativas e tentativas no sentido de se otimizar os parâmetros operacionais ligados à taxa de penetração são feitas com base em tentativa e erro ou na experiência adquirida em campos conhecidos. Não existe uma metodologia bem definida para tal.

CAPÍTULO 3

Metodologia

3.1 Apresentação

Este capítulo mostra inicialmente os dados usados neste trabalho, sua procedência, e os tratamentos realizados para eliminar ruídos e dados incoerentes. Depois, apresentam-se os tipos de arquitetura de redes neurais: redes para previsão direta da ROP (única e específicas por litologia), e redes inversas para previsão de RPM e WOB tendo a ROP como entrada (única e específicas por litologias). Na seqüência, é feita uma discussão prévia sobre otimização de parâmetros em tempo real na perfuração de poços de petróleo e que conceitos e variáveis devem ser levadas em conta para este propósito. Por fim, introduzem-se de três métodos diferentes que serão testados para a otimização dos parâmetros operacionais neste trabalho.

3.2 Dados usados

A falta de um modelo confiável e robusto para a previsão da taxa de penetração é um dos principais problemas enfrentados pelos engenheiros e projetistas de perfuração para a otimização dos parâmetros operacionais. Nesta dissertação, avalia-se o uso de redes neurais para a modelagem do comportamento da taxa com os demais parâmetros operacionais relevantes. Sete variáveis foram consideradas como entradas: rotação da broca (RPM), peso sobre broca (WOB), profundidade vertical do poço (TVD), vazão de bombeio, *overbalance*, diâmetro da broca e litologia. Todas as variáveis são contínuas, à exceção da litologia, que é categórica. A saída da rede é a taxa de penetração (ROP), como uma variável contínua.

Para a obtenção de modelos para a previsão da taxa de penetração selecionou-se dados de dez poços de petróleo perfurados na costa brasileira, incluindo poços do pós e pré-sal. Seis poços foram usados para o treinamento e seleção das redes neurais (poços de treinamento) e quatro foram separados para a validação dos modelos obtidos (poços de validação).

Os dados de uma perfuração são amostrados a cada 15 a 30 segundos. Para cada instante de tempo, são enviados dados de todos os parâmetros operacionais, incluindo as variáveis citadas acima. Os dados usados neste trabalho foram obtidos através do *software* PWDa, desenvolvido na Petrobras para o acompanhamento de perfuração em tempo real (GANDELMAN, 2009). O PWDa é um *software* que recebe diversos dados de perfuração em tempo real, analisa-os e identifica problemas operacionais, alertando o usuário para que medidas corretivas e/ou preventivas sejam tomadas. A Figura 3.1 mostra uma tela do PWDa durante o acompanhamento de um poço real. Na figura, é possível ver valores de rotação da broca, pressão de bombeio, ECD (pressão dinâmica expressa em termos de densidade equivalente) e outros parâmetros operacionais plotados como função do tempo. Vale ressaltar que todos os dados usados neste trabalho são provenientes de poços perfurados pela Petrobras e que foram cedidos por esta companhia.

Os dados brutos de uma perfuração real, entretanto, não possuem qualidade adequada para serem usados diretamente no treinamento de uma rede neuronal. Falhas nos sensores, que causam uma grande quantidade de ruídos, são muito comuns e isso compromete muito a qualidade e interpretação destes dados. Por exemplo, não são raras as falhas na transmissão do dado do sensor de peso sobre broca, gerando dados inválidos, nulos ou absurdamente altos. Estes dados, que evidentemente comprometeriam a obtenção de um modelo confiável, devem ser identificados e eliminados para não prejudicar o treinamento da rede. São comuns também falhas nos sensores de rotação da broca, pressão de fundo e vazão.

Isto exigiu um grande trabalho preliminar para eliminação de todos os pontos inválidos e incoerentes antes de usar os dados recolhidos no treinamento das redes.

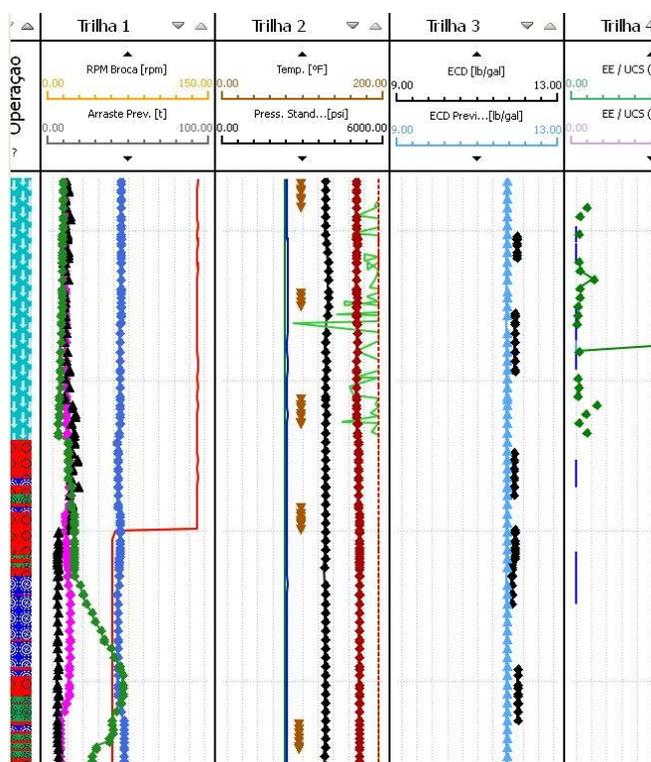


Figura 3.1. Tela do *software* PWDa com parte dos dados em tempo real

Após o tratamento (feito manualmente), restaram, nos seis poços de treinamento, 43.524 dados válidos e de qualidade adequada para o treinamento de uma rede neuronal. Isso corresponde a aproximadamente 200 horas de operação. Por exemplo, todos os pontos em que o peso sobre broca eram nulos e havia uma taxa de penetração positiva não nula foram eliminados (já que fisicamente é impossível haver taxa de penetração quando não se tem peso sobre broca). Erros como estes são devido a falhas nos sensores, que deixam de enviar alguns dados ou enviam dados ruidosos. Nestes dados válidos restantes, havia doze litologias diferentes. Nos dados dos poços de validação, após o tratamento, restaram 23.949 dados de qualidade adequada, o que corresponde a aproximadamente 120 horas de operação.

A Figura 3.2 mostra uma parte dos dados reais de perfuração coletados e usados no treinamento das redes. Note que, para este caso, novos dados eram recebidos a cada 30 segundos. A oitava coluna possui os dados de ECD (*Equivalent Circulation Density*), que nada mais é do que a pressão dinâmica no fundo do poço expressa em termos de densidade equivalente (em unidades de lb/gal). A nona coluna contém os dados de gradiente de pressão de poros, que é a pressão de poros da formação perfurada (no fundo do poço) também em termos de densidade

equivalente (em lb/gal). A décima coluna é a diferença entre o ECD e o gradiente de pressão de poros, ou seja, este é o diferencial de pressão poço-formação em termos de densidade equivalente (*overbalance*).

Um cuidado extra que se teve ao selecionar os dados foi garantir que, nos poços escolhidos para o treinamento das redes, não foi detectada nenhuma redução da taxa de penetração atribuída ao desgaste da broca. Não é raro, depois de atravessar formações abrasivas ou de enfrentar vibrações excessivas, que os cortadores da broca se desgastem, levando a uma redução na taxa de penetração. Dados com taxas de penetração reduzida devido ao desgaste de broca devem ser evitados, pois não representam bem o comportamento real do sistema. Nenhum dos poços usados para o treinamento da rede apresentou este problema. É importante ter o cuidado para garantir que também nenhum dos poços utilizados para a validação das redes apresente este problema.

Outro cuidado que se deve ter na escolha dos poços para validação das redes é garantir que não haja nenhuma litologia diferente das doze existentes nos dados para treinamento.

Hora hh:mm:ss	Litologia	Rotação coluna (rpm)	Peso sob. broca (ton)	Prof poço (m)	Vazão (gal/min)	Taxa de Penetração (m/h)	ECD (lb/gal)	Grad. Press. Poros (lb/gal)	Dif Poço-formação (lb/gal)	Diametro broca (m)
11:01:30	FLH	101.70	21.34	5814.48	672.72	12.63	11.69	9.00	2.69	12.25
11:02:00	FLH	101.70	20.68	5814.73	672.72	12.50	11.68	9.00	2.68	12.25
11:02:30	FLH	101.70	20.09	5814.98	672.72	12.41	11.66	9.00	2.66	12.25
11:03:00	FLH	101.70	20.54	5815.22	672.72	12.49	11.67	9.00	2.67	12.25
11:03:30	FLH	101.70	20.71	5815.47	672.72	12.48	11.69	9.00	2.69	12.25
11:04:00	FLH	101.70	20.16	5815.72	672.72	12.37	11.67	9.00	2.67	12.25
11:04:30	FLH	101.70	19.79	5815.96	672.72	12.23	11.69	9.00	2.69	12.25
11:05:00	FLH	101.70	20.82	5816.20	672.72	12.62	11.65	9.00	2.65	12.25
11:05:30	FLH	101.70	21.43	5816.45	672.72	12.63	11.69	9.00	2.69	12.25
11:06:00	FLH	101.70	21.14	5816.70	672.72	12.62	11.68	9.00	2.68	12.25
11:06:30	FLH	101.70	20.76	5816.95	672.72	12.45	11.70	9.00	2.70	12.25
11:07:00	FLH	101.70	21.86	5817.20	672.72	12.87	11.65	9.00	2.65	12.25
11:07:30	FLH	101.70	22.33	5817.45	672.72	12.87	11.69	9.00	2.69	12.25
11:08:00	FLH	101.70	21.79	5817.71	672.72	12.81	11.67	9.00	2.67	12.25
11:08:30	FLH	101.70	21.48	5817.96	672.72	12.68	11.68	9.00	2.68	12.25
11:09:00	FLH	101.70	21.29	5818.22	672.72	12.69	11.66	9.00	2.66	12.25
11:09:30	FLH	101.70	20.95	5818.47	672.72	12.55	11.68	9.00	2.68	12.25
11:10:00	FLH	101.70	20.83	5818.72	672.72	12.58	11.66	9.00	2.66	12.25
11:10:30	FLH	101.70	20.62	5818.96	672.72	12.51	11.66	9.00	2.66	12.25
11:11:00	FLH	101.70	21.03	5819.21	672.72	12.63	11.66	9.00	2.66	12.25
11:11:30	FLH	101.70	20.89	5819.46	672.72	12.55	11.68	9.00	2.68	12.25
11:12:00	FLH	101.70	20.92	5819.71	672.72	12.57	11.67	9.00	2.67	12.25
11:12:30	FLH	101.70	21.07	5819.96	672.72	12.53	11.69	9.00	2.69	12.25
11:13:00	FLH	101.70	21.15	5820.21	672.72	12.55	11.69	9.00	2.69	12.25
11:13:30	FLH	101.70	21.02	5820.46	672.72	12.62	11.66	9.00	2.66	12.25
11:14:00	FLH	101.70	21.44	5820.71	672.72	12.66	11.68	9.00	2.68	12.25
11:14:30	FLH	101.70	21.71	5820.96	672.72	12.72	11.68	9.00	2.68	12.25
11:15:00	FLH	101.70	21.67	5821.21	672.72	12.81	11.65	9.00	2.65	12.25
11:15:30	FLH	101.70	20.55	5821.47	672.72	12.40	11.69	9.00	2.69	12.25
11:16:00	FLH	101.70	20.10	5821.71	672.72	12.40	11.65	9.00	2.65	12.25
11:16:30	FLH	101.70	19.13	5821.96	672.72	12.13	11.66	9.00	2.66	12.25
11:17:00	FLH	101.70	10.74	5822.20	672.56	9.46	11.66	9.00	2.66	12.25
11:17:30	FLH	97.20	12.93	5822.38	670.73	10.09	11.68	9.00	2.68	12.25
11:18:00	FLH	97.20	13.10	5822.58	671.61	10.18	11.67	9.00	2.67	12.25
11:18:30	FLH	97.20	9.28	5822.78	670.71	8.76	11.68	9.00	2.68	12.25
11:19:00	FLH	97.20	4.62	5822.96	670.06	6.46	11.69	9.00	2.69	12.25
11:19:30	FLH	97.20	5.43	5823.09	669.66	6.94	11.69	9.00	2.69	12.25

Figura 3.2. Parte dos dados em tempo real coletados para treinamento das redes neurais para previsão da taxa de penetração

3.3 Modelos baseados em redes neurais

Para a previsão do comportamento da taxa com os demais parâmetros operacionais, foram treinadas redes neurais diretas (cujas entradas são as variáveis independentes e a saída é a taxa de penetração) e redes neurais inversas (cujas entradas incluem a taxa de penetração e as demais variáveis independentes, exceto a rotação e peso sobre broca, que passam a ser as saídas). Para a obtenção de cada rede neuronal, cem redes foram treinadas no Statistica[®] versão 8 e o *software* escolheu aquela que apresentou o melhor desempenho. As melhores redes, segundo o *software*, foram escolhidas e usadas neste trabalho. Para a escolha da melhor rede, o Statistica[®] versão 8 adota como critério o menor razão SD. Razão SD é a razão entre o desvio padrão dos erros e o desvio padrão dos dados. Assim, quanto menor for este parâmetro, melhor é a eficiência da rede. As redes treinadas foram todas do tipo MLP, mais apropriadas para um problema de regressão.

Doze litologias diferentes estavam presentes nos dados dos seis poços aquisitados (arenito, folhelho, anidrita, taquidrita, marga, carbonato albiano, coquina, carnalita, halita, silito, calcilutito e calcarenito). Para fins de comparação, treinou-se uma rede neuronal única para todas as litologias (em que a litologia é uma entrada categórica) e doze redes neurais diferentes, sendo uma para cada tipo de litologia. O mesmo foi feito no treinamento das redes inversas: uma rede única (tendo a litologia como uma entrada categórica) e doze redes diferentes, uma para cada litologia. Assim, foram treinadas, no total, vinte e seis configurações de redes, sendo treze diretas e treze inversas. A Figura 3.3 ilustra as arquiteturas da rede neuronal direta e da rede neuronal inversa.

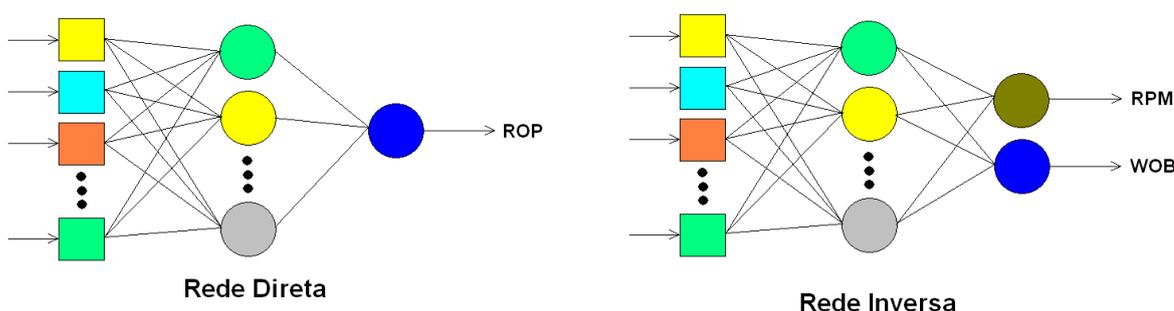


Figura 3.3. Desenhos esquemáticos das arquiteturas das redes neurais direta e inversa

Após a seleção da melhor rede de cada tipo, a mesma foi programada em MATLAB, testada e validada com dados dos quatro poços de validação.

Na obtenção das redes, 70 % dos dados apresentados à rede foram usados para o treinamento, 20% foram usados para seleção e 10% foram usados para teste.

Um ponto importante a ser ressaltado é que tanto os dados coletados para o treinamento das redes quanto os dados de validação são de perfurações realizadas com brocas. Em alguns casos, especialmente em formações mais duras como as Carbonato Albiano, a perfuração é realizada com turbinas. As turbinas são capazes de aumentar sensivelmente a taxa de penetração em formações duras. Entretanto, a maioria das operações de perfuração (tanto *offshore* quanto *onshore*) são realizadas com broca. Além disso, as turbinas geram uma quantidade excessiva de ruídos no fundo do poço o que reduz drasticamente a qualidade dos dados coletados nos sensores de fundo (já que eles são transmitidos à superfície por pulsos de pressão que viajam através do fluido, pelo interior da coluna de perfuração). Isto reduz a confiabilidade dos dados deste tipo de operação e impede que os mesmos sejam usados para o treinamento de redes neurais. Por este motivo, optou-se por não utilizar dados de perfuração empregando turbinas.

3.3.1 Rede direta

As redes diretas têm como saída a ROP (m/h) e como entradas as seguintes variáveis:

- 1) rotação da broca (rpm)
- 2) peso sobre broca (toneladas)
- 3) profundidade vertical (m)
- 4) vazão (gal/min)
- 5) diferencial de pressão poço-formação em termos de densidade equivalente (lb/gal)
- 6) diâmetro do poço (polegada)
- 7) litologia (variável categórica)

Conforme mencionado acima, foram treinadas uma rede direta única que engloba todas as litologias e mais doze redes diretas separadas por litologia, sendo uma para cada tipo de rocha.

Além de uma rede direta tendo as litologias como entradas categóricas, separam-se os dados usados no treinamento em doze grupos, um grupo para cada litologia diferente. As doze litologias presentes nos poços escolhidos para o treinamento das redes são:

- carbonato albiano (ALB)

- anidrita (AND)
- arenito (ARN_MAC)
- calcitulito (CLU)
- coquinas (COQ)
- carlarenito (CRE)
- carnalita (CRN)
- folhelho (FLH)
- halita (HAL)
- marga (MRG)
- siltito (SLT)
- taquidrita (TQD)

Carbonato albiano é um tipo de carbonato formado no período albiano que, no Brasil, é encontrado abaixo da camada de sal. A grande maioria do óleo explorado nos poços do pré-sal estão contidos em carbonatos albianos. Esta é uma litologia de baixíssima perfurabilidade, onde as taxas de penetração raramente ultrapassam 1 m/h (MOHRIAK et al, 2009).

Anidrita é um tipo de sal formado por sulfato de cálcio (CaSO_4). No Brasil, extensas camadas de anidrita são encontradas nas camadas de sal dos poços do pré-sal. Apresenta perfurabilidade média (MOHRIAK et al, 2009).

Arenito é um tipo de litologia formada por grãos de areia (sílica) unidos por um material cimentante (um sal, por exemplo). Arenitos podem apresentar uma grande variação em suas propriedades, dependendo do grau de compactação, do tamanho dos grãos, do grau de consolidação e do material cimentante (MOHRIAK et al, 2009).

Calcilutito é um tipo de litologia formada por grãos pequenos (menor que 1 μm) de calcareo unidos por um material cimentante. Assim como o arenito, apresenta uma grande variação em suas propriedades que dependem do grau de compactação, do grau de consolidação e do material cimentante (MOHRIAK et al, 2009).

Coquina é um tipo de carbonato poroso composto principalmente por conchas e seus fragmentos. No Brasil, coquilhas são muito comuns nas camadas pós-sal (MOHRIAK et al, 2009).

Calcarenito é um tipo de litologia formada por grãos de calcários mais grossos do que os calcilutitos (maiores que 1 μm) unidos por um material cimentante. Assim como o arenito

e o calcilutito, apresenta uma grande variação em suas propriedades que dependem do grau de compactação, do grau de consolidação e do material cimentante (MOHRIAK et al, 2009).

Carnalita é uma litologia salina composta por uma mistura de cloretos de potássio e magnésio hidratados ($\text{KMgCl}_3 \cdot 6(\text{H}_2\text{O})$). No Brasil, é muito encontrada nas camadas salinas dos poços do pré-sal (MOHRIAK et al, 2009).

Folhelho é um tipo de litologia formada por argilas. Geralmente, tem boa perfurabilidade. Entretanto, a maioria dos folhelhos representa uma grande dificuldade, pois quando em contato com água, as argilas que o constituem incham, levando a instabilidade química do poço e seu fechamento. Em casos extremos, o inchamento dos folhelhos podem causar a perda do poço (MOHRIAK et al, 2009).

Halita é uma litologia salina composta por cloreto de sódio (NaCl). No Brasil, é muito encontrada nas camadas salinas dos poços do pré-sal (MOHRIAK et al, 2009).

Marga é um tipo de calcário contendo 35 a 60% de argila. No Brasil, é muito comum nas camadas do pós-sal e tem baixa perfurabilidade (MOHRIAK et al, 2009).

Siltito é uma rocha sedimentar formada pela deposição de sedimentos com grãos de tamanho silte, intermediário entre os tamanhos areia e argila. É composta principalmente por quartzo, feldspato, mica e argila (MOHRIAK et al, 2009).

Taquidrita é uma litologia salina composta por uma mistura de cloretos de cálcio e magnésio hidratados ($\text{CaMgCl}_3 \cdot 3\text{H}_2\text{O}$). No Brasil, é muito encontrada nas camadas salinas dos poços do pré-sal (MOHRIAK et al, 2009).

3.3.2 Rede inversa

Além das redes diretas, foram treinadas também redes inversas, em que a ROP é considerada uma entrada e as saídas são as duas variáveis que se deseja manipular: peso sobre broca e rotação da broca.

As redes inversas têm como saída a WOB (ton) e RPM e como entradas as seguintes variáveis:

- 1) profundidade vertical (m)
- 2) vazão (gal/min)
- 3) diferencial de pressão poço-formação em termos de densidade equivalente (lb/gal)
- 4) diâmetro do poço (polegada)
- 5) litologia

6) ROP (m/h)

A exemplo do que foi feito com as deres diretas, uma rede inversa única (tendo a litologia como uma variável de entrada categórica) foi treinada e mais doze configurações de redes inversas, uma para cada litologia, também foram treinadas. O objetivo do treinamento das redes inversas é a verificação da possibilidade de determinação direta do peso sobre broca e rotação da broca necessários para uma dada taxa de penetração.

3.3.3 Métodos de treinamento

Os dados de treinamento foram usados para o treinamento de redes neuronais no *software* Statistica[®] versão 8, usando a ferramenta *Statistica Automated Neural Network* (SANN). Para cada tipo de arquitetura (modelo direto único, modelos diretos separados por litologia, modelo inverso único e modelo inverso separado por litologia), foram treinadas cem redes diferentes (com diferentes funções de ativação, pesos, *biases* e número de neurônios). Como comentado antes, das cem redes obtidas para cada arquitetura, o *software* selecionou aquela com o melhor desempenho, baseado no critério de menor razão SD. Apesar de usar este critério para a seleção da melhor rede, este valor não é mostrado ao usuário.

Para o treinamento das redes, o Statistica[®] versão 8 utiliza o método de *backpropagation* nas primeiras épocas, seguido pelo gradiente conjugado nas épocas subsequentes.

3.4 Otimização dos parâmetros operacionais

Uma vez que as redes neuronais diretas e inversas foram treinadas, o próximo passo é usar os modelos obtidos para a determinação do par de rotação e peso sobre broca para manter a ROP em um determinado *setpoint*. Foram testadas três maneiras de se obter o par de RPM e WOB:

- 1) Determinação explícita através das redes inversas. Neste caso, basta alimentar a rede com os parâmetros operacionais da operação (vazão, profundidade vertical atual do poço, diâmetro da broca, litologia perfurada e diferencial de pressão poço-formação) e o valor de taxa de penetração desejado (*setpoint*) e as saídas serão o par de rotação da broca e peso sobre broca necessários para manter a taxa naquele *setpoint*.

2) Uso de um algoritmo de otimização. Neste caso, deve-se programar um algoritmo de otimização que busque, a partir do modelo da rede direta, o par de rotação e peso sobre broca que gere o valor de *setpoint* de ROP desejado. Como citado no Capítulo 2, neste trabalho escolheu-se o algoritmo de *Particle Swarm Optimization* (PSO) para a busca do par de RPM e WOB.

3) Programar um algoritmo de varredura exaustiva, que percorra todos os pares de rotação e peso sobre broca possíveis (respeitando-se os limites operacionais de cada um destes parâmetros) e identificar aquele(s) que gere a taxa de *setpoint* desejada, empregando modelo da rede direta.

Entretanto, como comentado anteriormente, durante a perfuração de um poço de petróleo, a otimização dos parâmetros operacionais não se restringe somente a determinar as condições necessárias para se obter a ROP desejada. Na prática, verifica-se que existem inúmeras combinações de parâmetros operacionais que geram a mesma resposta da ROP. Assim, a otimização consiste em determinar, dentre todas as possíveis combinações de parâmetros operacionais, aquela que gere a ROP desejada de forma mais eficiente, ou seja, com o mínimo gasto de energia. Conforme já comentado também no Capítulo 2, cada rocha tem uma energia mínima necessária para o rompimento. Esta energia depende não somente do tipo de rocha, mas também das condições às quais a mesma está submetida (compactação, pressão, temperatura, etc). Para que a perfuração ocorra, é necessário que a broca seja capaz de transmitir à rocha, no mínimo, esta quantidade de energia. Existem correlações para o cálculo desta energia mínima de rompimento com base nos dados da ferramenta de Sônico. Porém, os dados de tempos de trânsito (fornecidos pelo Sônico e usados para a estimativa da energia mínima de rompimento das rochas) raramente estão disponíveis e ainda mais raramente estão disponíveis em tempo real.

Esolhe-se, então, um parâmetro que reflita a quantidade de energia disponibilizada na broca para o corte das formações geológicas: a Energia Mecânica Específica (EME). A otimização dos parâmetros operacionais obrigatoriamente deve levar em conta este parâmetro.

Caso a energia mecânica específica na broca seja menor do que a energia mínima requerida para o corte da rocha, a perfuração não ocorrerá. Caso contrário, a broca será capaz de cortar a formação e haverá uma taxa de penetração positiva. A princípio, quanto maior for a energia mecânica específica disponibilizada na broca, maior será a velocidade de avanço observada. Mas há um limite para a velocidade de perfuração. A partir de um determinado ponto,

o aumento da energia mecânica específica levará a nenhum ou a um insignificante aumento na taxa (AADNOY, 2009). Isto significa que, a partir de um determinado ponto, parte da energia começa a se perder em vez de ser transmitida à broca. Ou seja, em vez de ser integralmente usada para o corte das rochas de subsuperfície, parte da energia do sistema se perde por vibração, flambagem da coluna de perfuração e desgaste da broca e equipamentos de fundo. A vibração e flambagem da coluna de perfuração, além de acelerarem o desgaste da broca e demais equipamentos de fundo, geram fadiga da coluna, podendo causar seu rompimento, o que representa um problema operacional muito grave.

Evidentemente, a quantidade de energia que se perde depende diretamente da eficiência da coluna de perfuração transmiti-la à broca. Uma coluna de perfuração mal projetada gera níveis muito elevados de flambagem e vibração, o que causa a redução da taxa de penetração e da vida útil dos equipamentos de fundo, encarecendo a perfuração do poço.

Logo, a composição da coluna é um fator fundamental a ser levado em conta em qualquer metodologia de otimização de parâmetros operacionais em tempo real. Porém, para que este fator fosse levado em conta no treinamento das redes obtidas neste trabalho, seria necessário um número muito maior de poços, tanto para o treinamento da rede quanto para a validação. Em vez disso, optou-se por utilizar poços com composições de coluna semelhantes, ou seja, com a mesma proporção de comandos, tubos pesados e tubos de perfuração. Desta forma, eliminam-se respostas diferentes causadas por diferentes composições de coluna. Entende-se que este procedimento não leva a uma perda grande de precisão para o uso dos modelos obtidos em outros poços, pois os projetos realizados na costa brasileira seguem um padrão e a grande maioria deles possui uma composição de coluna muito similar às usadas nos poços de treinamento e validação escolhidos para este trabalho (ROCHA e AZEVEDO, 2007).

A otimização dos parâmetros operacionais para se obter uma determinada ROP consiste, basicamente, em manipular os valores de RPM e WOB de forma a se obter a taxa de penetração desejada com o mínimo gasto de energia possível.

A otimização dos parâmetros operacionais é uma atividade extremamente importante durante a perfuração de poços, mesmo que ainda não exista uma metodologia bem consolidada para isso. A busca pelo par de rotação da broca e peso sobre broca que gere a menor energia mecânica específica para uma determinada taxa de perfuração é algo que pode aumentar muito a vida útil da broca e demais equipamentos de fundo e reduzir substancialmente os custos da perfuração de um poço.

A Equação 3.1 mostra o cálculo da energia mecânica específica na broca. Apesar de ser chamada de “energia”, a EME é expressa em termos de pressão. Ela representa a pressão que a broca deve exercer sobre a formação para perfurá-la (RASHIDI et al, 2010).

$$EME = \frac{4WOB}{\pi(D_b)^2} + \frac{\pi.RPM.T}{A_b.ROP} \quad (3.1)$$

onde: EME é a energia mecânica específica, em Pa;

WOB é o peso sobre broca, em N;

RPM é a rotação da broca, em revoluções/s;

T é o torque da coluna, em N.m;

ROP é a taxa de penetração, em m/s;

D_b é o diâmetro da broca, em m.

Existem outros critérios para o cálculo da EME, mas neste trabalho, adotou-se o apresentado na Equação 3.1.

Nota-se, então, que a otimização dos parâmetros operacionais em tempo real pode ser posta como a minimização de duas funções: a função da energia mecânica específica na broca (Equação 3.1) e a função erro, definida como o valor absoluto da diferença do *setpoint* desejado e a taxa prevista pelo modelo, conforme mostrado na Equação 3.2.

$$erro = abs(ROP_{set} - ROP_{prev}) \quad (3.2)$$

Ou seja, o par encontrado de WOB e RPM deve obedecer à restrição da Equação 3.3 (minimizar a EME), sujeito à restrição da Equação 3.4 (deve gerar a ROP desejada).

$$\min_{WOB, RPM} [EME(WOB, RPM)] \quad (3.3)$$

$$ROP_{prev}(WOB, RPM) = ROP_{set} \quad (3.4)$$

A formulação acima foi empregada nos métodos baseados em PSO e varredura exaustiva.

A seguir são comentadas as vantagens e desvantagens de cada um dos métodos de otimização listados anteriormente. Os resultados obtidos serão comentados mais adiante.

3.4.1 Determinação explícita através das redes inversas

A vantagem deste tipo de métodos é que, uma vez que não é feito uso de nenhum algoritmo auxiliar, a determinação é feita de forma muito mais rápida. Basta alimentar a ROP desejada e demais parâmetros e a rede fornece instantaneamente os valores de RPM e WOB necessários.

Entretanto, observa-se, na prática, que existem múltiplas combinações de RPM e WOB possíveis para se atingir uma mesma ROP (mantendo-se constantes os demais parâmetros). Por exemplo, se, por algum motivo, for necessário reduzir a rotação da broca, é possível aumentar o peso sobre broca para compensar a perda da rotação e manter a taxa de penetração no mesmo nível.

A desvantagem deste tipo de método é que a rede fornece apenas um par sub-ótimo, pois tem-se a garantia de que o erro da Equação 3.3 foi minimizado, mas não se tem nenhuma garantia de que este par gera a menor energia mecânica específica possível.

3.4.2 Uso de algoritmo de otimização PSO

Neste trabalho, testou-se uma abordagem empregando o algoritmo PSO (*Particle Swarm Optimization*) para, através da rede direta única ou das redes diretas separadas por litologia, fornecer um par de RPM e WOB que gere o *setpoint* de ROP desejado. Entretanto, assim como a determinação direta pela rede inversa, a abordagem testada fornece apenas um único par de RPM e WOB e não se tem nenhuma garantia de que seja o par ótimo. Desta forma, assim como no caso anterior, o método fornece um par sub-ótimo. Na verdade, a abordagem proposta usando o PSO otimiza o par de RPM e WOB minimizando apenas uma função objetivo que, neste caso, é a função erro da Equação 3.3. Poder-se-ia tentar uma otimização multi-objetivo, mas, por motivos explicados mais adiante, este tipo de abordagem, em princípio, é inapropriada para este problema.

É possível programar o algoritmo para que ele faça várias buscas, partindo sempre de condições iniciais diferentes. Com isso, espera-se que ele seja capaz de encontrar várias soluções diferentes. Pode-se, então, comparar a energia específica de cada um destes pontos e identificar o par ótimo. Mesmo assim, não se tem garantia nenhuma de que todas as múltiplas soluções foram

identificados pelo método e nem de que o ponto ótimo identificado seja de fato aquele que gera a menor energia mecânica específica.

O uso de um algoritmo de otimização como o PSO certamente leva a um resultado mais confiável que o uso da rede inversa, mas ainda é falho. Além disso, a busca de vários pontos pode levar a um custo computacional elevado. Evidentemente, em uma aplicação de tempo real, o aumento do custo computacional (e consequente aumento do tempo de processamento) é sempre indesejável. Mas o cálculo dos parâmetros ótimos não precisa ser feito a cada 10 ou 20 segundos (ou sempre que novos dados forem recebidos), uma vez que as condições operacionais não sofrem variações bruscas com alta frequência. Pode-se efetuar este cálculo com uma periodicidade relativamente elevada (a cada dez metros, por exemplo) ou sempre que houver uma mudança significativa nos parâmetros operacionais, tais como mudança de vazão, mudança de formação, mudança na pressão, etc. Sendo assim, apesar de terem custo computacional maior, o uso de um algoritmo de otimização como o PSO ainda é muito mais vantajoso que a determinação explícita pelas redes inversas.

O código de MATLAB para otimização via algoritmo PSO usado neste trabalho, com as restrições para peso sobre broca e rotação da broca encontram-se no Apêndice A da dissertação.

As equações que determinam a velocidade e a posição das partículas ao longo podem ser escritas como as Equações 3.4 e 3.5.

$$v_{i,d}^{k+1} = wv_{i,d}^k + c_1r_1(p_{i,d}^k - \alpha_{i,d}^k) + c_2r_2(p_{global,d}^k - \alpha_{i,d}^k) \quad (3.4)$$

$$\alpha_{i,d}^{k+1} = \alpha_{i,d}^k + v_{i,d}^{k+1} \quad (3.5)$$

Os índices k , i e d denotam, respectivamente, a iteração, a partícula e a direção de busca. v é a velocidade e α é a posição no espaço de busca. w é um peso de inércia e c_1 e c_2 são duas constantes positivas chamadas respectivamente de parâmetro cognitivo e social. r_1 e r_2 são dois números aleatórios com distribuição uniforme no intervalo $[1,0]$. p_i é o melhor ponto encontrado pela partícula e p_{global} é o melhor valor encontrado por todo o enxame (SCHWAAB e PINTO, 2007).

O parâmetro w , chamado de “peso de inércia” tem o papel de balancear o caráter global e local da busca. Quanto maior o valor de w , maior é o número de iterações para que as partículas converjam. Porém, quando w é maior que a unidade, as partículas divergem. Um

valor de w próximo ao unitário corresponde a uma alta inércia do movimento das partículas e mantém as partículas em movimento por um número maior de iterações, aumentando a exploração da região de busca. Um valor de w próximo a zero diminui rapidamente a velocidade das partículas, levando a uma rápida convergência e diminuindo a exploração na região de busca.

Para tirar proveito desta mudança de comportamento do enxame com o valor do peso de inércia, uma forma interessante de realizar a busca consiste em iniciá-la com um valor de w próximo à unidade (possibilitando uma boa exploração na região de busca) e diminuir seu valor ao longo das iterações, forçando a convergência das partículas e aumentando a precisão do melhor ponto obtido pelo enxame. Existem inúmeras formas de diminuir o valor de w ao longo das iterações. Segundo Schwaab e Pinto (SCHWAAB e PINTO, 2007), a forma mais usual é a apresentada na Equação 3.6.

$$w = w_i + \frac{k}{Niter} (w_f - w_i) \quad (3.6)$$

onde $Niter$ é o número de iterações;

w_i é o valor inicial do peso de inércia;

w_f é o valor final do peso de inércia.

Os parâmetros c_1 e c_2 ponderam, respectivamente, a contribuição individual e a contribuição do grupo na velocidade de cada partícula. A contribuição individual corresponde a um passo na direção do melhor ponto encontrado pela partícula em questão. Já a contribuição global consiste em um passo na direção do melhor ponto encontrado por todo o grupo ou por parte dele. A definição destes parâmetros permite controlar o caráter social da busca, que pode variar de uma busca altamente individual até uma busca completamente social. Quanto maior o caráter individual da busca, maior é a exploração da região de busca, já que um maior número de iterações é necessária para que ocorra a convergência. Valores muito altos de c_1 e c_2 levam a valores altos nas velocidades das partículas, o que pode fazer com que elas divirjam. Assim, deve-se tomar cuidado na definição dos valores destes parâmetros. Torna-se, então, interessante limitar a velocidade e/ou posição de cada partícula.

Note que os parâmetros w , c_1 e c_2 são os pesos dos três vetores descritos no Capítulo 2. Eles influenciam o comportamento do enxame aumentando ou diminuindo a velocidade com que as partículas convergem. Não existe nenhum conjunto de parâmetros que seja ótimo

para qualquer problema. Além disso, o caráter aleatório da busca exige que o problema seja resolvido diversas vezes para garantir que um valor adequado seja definido como o mínimo da função objetivo em questão (SCHWAAB e PINTO, 2007).

3.4.3 Busca exaustiva de todos os pares de RPM e WOB

A desvantagem deste método é evidente: o custo computacional. Entretanto, diferente dos outros dois métodos citados, este tem uma maior possibilidade de identificação de todos os pares de RPM e WOB que geram a ROP desejada. Uma vez identificados todos os pares possíveis, calculam-se suas energias mecânicas específicas e seleciona-se o par ótimo.

Apesar de ter um custo computacional maior, este método possui uma maior probabilidade (em função do grid de varredura escolhido) de localizar o par ótimo de RPM e WOB. Além disso, conforme discutido anteriormente, o cálculo do par ótimo de RPM e WOB só precisa ser feito com uma certa periodicidade (elevada) ou quando houver mudanças significativas nos demais parâmetros operacionais. Arbitrando que a determinação do par ótimo só deve ser feita a cada dez metros e considerando uma taxa de 10 m/h, o cálculo só precisará ser feito a cada hora.

Tendo por base estas considerações, este é o método mais vantajoso dentre os três citados.

Foi desenvolvido um código em MATLAB para a varredura de todos os pares possíveis e escolha daquele que gere a menor energia mecânica específica na broca. O código (chamado de “otimizador de varredura exaustiva”) se encontra no Apêndice A. O modelo para determinação da ROP usado no método de varredura exaustiva foi o das redes diretas separados por litologia. Dependendo da litologia em questão, o “otimizador” escolhe a rede adequada. Esta escolha foi feita, pois as redes diretas separadas por litologia apresentaram uma performance muito superior ao da rede única.

Conforme se observa no código constante do Apêndice A, o algoritmo gerado neste trabalho parte de um valor inicial de RPM nulo. O valor inicial de WOB é um valor baixo, mas não nulo, já que, fisicamente, é impossível haver uma taxa de penetração não nula para valores nulos de peso sobre broca. Assim, escolheu-se 0,1 ton para o valor inicial de WOB. Ou seja, o primeiro par a ser testado é aquele com peso sobre broca de 0,1 toneladas e rotação de broca nula. Estes valores são enviados para as redes neuronais, que retornam um valor de ROP. O valor de ROP retornado é comparado com a ROP de *setpoint* desejada. Caso o módulo da diferença entre o valor de ROP calculado para o par e o valor desejado seja inferior a uma tolerância pré-estabelecida, o par é armazenado em um vetor e sua energia mecânica

específica é calculada. Caso o módulo da diferença entre o valor de ROP calculado para o par e o valor desejado seja superior a esta tolerância, o par é descartado. Para efeitos didáticos, chama-se esta etapa (cálculo da ROP para cada par, comparação com ROP de *setpoint* e armazenamento ou descarte do par) de “teste de par”.

Após cada “teste de par”, a RPM é adicionada de um incremento e a WOB é mantida constante. Repete-se, então o “teste de par” para o novo par obtido (como o novo valor de RPM). O processo é repetido até que a RPM atinja um valor máximo pré-estabelecido. Neste trabalho, usou-se um valor máximo de 600 rpm. O valor máximo de RPM varia depende de uma série de fatores, tais como limite operacional da broca utilizada, limite operacional do *topdrive* (equipamento responsável por impor rotação à coluna de perfuração em superfície), modelo de motor de fundo usado (equipamento responsável por converter a vazão que passa pela coluna de perfuração em rotação, aumentando a quantidade de revoluções por minuto da broca), etc. Entretanto, neste trabalho escolheu-se um valor de 600 rpm como valor máximo da RPM pois este é um valor máximo típico encontrado em campo. Evidentemente, este valor pode ser mudado, dependendo das condições e limitações de cada operação. O incremento usado para a RPM foi de 1 rpm. A escolha deste valor também é arbitrária. Optou-se por usar um incremento tão pequeno quanto 1 rpm para se ter uma melhor resolução, e conseqüentemente uma melhor análise, dos resultados. É possível, evidentemente, aumentar este incremento para se ganhar performance computacional.

Assim que o valor de RPM atinge seu limite máximo, a RPM é retornada para seu valor inicial (nulo) e o valor de WOB é adicionado de um incremento. Inicia-se, então, um novo “teste de par”, ao fim do qual, a WOB é mantida constante e a RPM é adicionada de seu incremento. Para a WOB, escolheu-se um incremento de 0,1 ton. Assim como na RPM, para a WOB escolheu-se um incremento tão pequeno quanto 0,1 ton para aumentar a resolução dos resultados e melhorar suas análises.

O processo acima é repetido até que se atinjam os valores máximos de WOB e RPM. Neste trabalho, adotou-se 65 ton para o valor máximo de peso sobre broca. Ao fim disso, todos os pares que gerem a ROP desejada (a menos de uma pequena tolerância) foram armazenados em uma matriz. A última etapa é a identificação daquele par com a menor energia mecânica específica. Este é o par ótimo.

Com os valores de incrementos e valores máximos e mínimos de RPM e WOB adotados neste trabalho, um total de 195.000 pontos foram testados em cada iteração, ou seja, para cada instante de tempo dos dados reais. Mesmo com o elevado número de pares a serem testados em cada instante de tempo, não se percebeu um custo computacional impeditivo. O

programa foi capaz de gerar resultados em um tempo adequado para aplicações de tempo real. Cabe ressaltar que, como já foi mencionado, os valores de incrementos podem ser aumentados a fim de reduzir o número de pontos e aumentar a performance do algoritmo.

A Figura 3.4 mostra um fluxograma com os passos do algoritmo de varredura exaustiva desenvolvido para este trabalho.

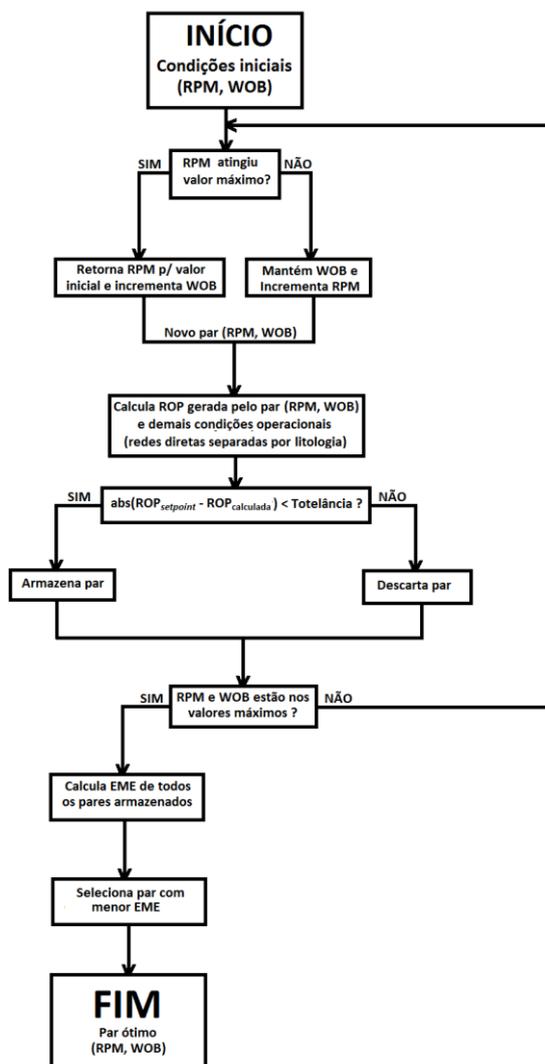


Figura 3.4. Fluxograma do método da varredura exaustiva para determinação do par ótimo de RPM e WOB

CAPÍTULO 4

Resultados e Discussões

4.1 Apresentação

Este capítulo apresenta os resultados e discussões sobre o desempenho das melhores redes neuronais obtidas, tanto as redes diretas (única e separadas por litologia) quanto as redes inversas (única e separadas por litologia). Em seguida, é realizada uma comparação do desempenho das redes neuronais com três dos modelos mais conhecidos e empregados para a previsão de taxa de penetração. Após a comparação, é feita uma análise com três diferentes metodologias para obtenção do par ótimo de RPM e WOB em tempo real durante a perfuração de um poço.

4.2 Melhores Redes Neurais obtidas

Conforme citado anteriormente, para cada tipo de rede investigada, foram treinadas cem redes. Para tanto, usou-se o *software* Statística© versão 8, que possui a funcionalidade *Statistica Automated Neural Network*, para o treinamento de redes neurais. O próprio *software* indica a melhor rede obtida, baseado no critério de mínimo *razão SD*. Entretanto, apesar de calcular este parâmetro e usá-lo para a escolha do melhor modelo obtido, o *software* não mostra o valor ao usuário.

Para o treinamento da rede, o *software* escolhe, de forma aleatória, diferentes números de neurônios na camada escondida, diferentes funções de ativação e diferentes estimativas iniciais para os valores de pesos e *biases*. Usando o método de treinamento de *backpropagation* nas primeiras iterações e *backpropagation* com gradiente conjugado nas demais, os pesos e *biases* são ajustados de acordo com os padrões apresentados à rede. O método de *backpropagation* é aplicado para a atualização dos pesos e *biases* e, em paralelo, o erro de validação é monitorado. O treinamento da rede prossegue enquanto o erro de seleção decrescer. Se, a partir de determinado momento, esse erro iniciar uma tendência de subida, o treinamento é interrompido.

O *software* permite o treinamento de redes do tipo RBF (*Radial Basis Function*) e do tipo MLP. Para este trabalho, as redes do tipo RBF, mais adequadas para problemas de classificação, não foram avaliadas.

A seguir, são mostradas as melhores redes obtidas para cada uma das arquiteturas testadas.

4.2.1 Rede direta única

A melhor rede direta única (cujas litologias são entradas categóricas) fornecida pelo Statística© versão 8 foi uma MLP 18-10-1 (18 neurônios na camada de entrada, 10 neurônios na camada escondida e 1 neurônio na camada de saída). A função de ativação da camada escondida é tangente hiperbólica e da camada de saída é identidade, conforme mostrado na Tabela 4.1.

Tabela 4.1 – Melhor rede obtida no Statistica© versão 8 para previsão de ROP tendo a litologia como uma variável de entrada categórica.

Tipo	Número de neurônios			Função ativ. camada escondida	Função ativ. camada saída
	Camada de entrada	Camada escondida	Camada de saída		
MLP	18	10	1	Tangente Hiperbólica	Identidade

Dos dezoito neurônios da camada de entrada os seis primeiros recebem as variáveis contínuas (RPM, WOB, profundidade vertical do poço, vazão, *overbalance* e diâmetro da broca, nesta ordem). Os outros doze neurônios recebem as variáveis categóricas (litologias).

O código, programado em MATLAB, para esta rede se encontra no Apêndice A desta dissertação.

4.2.2 Redes diretas separadas por litologia

Para cada uma das doze redes diretas separadas por litologias, foram treinadas cem redes no Statistica© versão 8 e a melhor delas foi selecionada pelo *software*. As doze melhores redes (uma para cada litologia) foram implementadas no MATLAB. No Apêndice A, é apresentado um exemplo de código de uma rede direta separada por litologia. A Tabela 4.2 mostra o tamanho de cada uma das redes (números de neurônios), bem como as funções de ativação dos neurônios da camada escondida e da camada de saída. Vale ressaltar que as doze redes diretas separadas por litologias não possuem entradas categóricas, já que cada uma delas foi desenvolvida especificamente para um único tipo de litologia.

Assim, as seis entradas da rede são respectivamente: rotação da broca, peso sobre broca, profundidade vertical do poço, vazão, *overbalance* (em termos de densidade equivalente) e diâmetro da broca.

Tabela 4.2. Melhores redes obtidas no Statistica© versão 8 para previsão de ROP

Tipo	Número de neurônios			Função ativ. camada escondida	Função ativ. camada saída
	Camada de entrada	Camada escondida	Camada de saída		
ALB	6	10	1	Exponencial	Tangente Hiperbólica
AND	6	10	1	Tangente Hiperbólica	Logística
ARN_MAC	6	11	1	Tangente Hiperbólica	Identidade
CLU	6	8	1	Tangente Hiperbólica	Tangente Hiperbólica
COQ	6	3	1	Logística	Tangente Hiperbólica
CRE	6	11	1	Exponencial	Identidade
CRN	6	4	1	Exponencial	Tangente Hiperbólica
FLH	6	10	1	Tangente Hiperbólica	Identidade
HAL	6	6	1	Tangente Hiperbólica	Tangente Hiperbólica
MRG	6	7	1	Exponencial	Tangente Hiperbólica
SLT	6	10	1	Tangente Hiperbólica	Tangente Hiperbólica
TQD	6	8	1	Exponencial	Tangente Hiperbólica

4.2.3 Rede inversa única

No *software* Statistica© versão 8, foram treinadas cem redes inversas e a melhor delas foi escolhida pelo programa e implementada em MATLAB. O código encontra-se em Apêndice A. Novamente, optou-se por treinar apenas redes MLP, descartando-se a arquitetura RBF, que não é adequada para problemas de regressão. Conforme mostrado na Tabela 4.3, a melhor rede inversa única foi uma MLP 17-9-2 (com dezessete neurônios na camada de entrada, nove neurônios na camada escondida e dois neurônios na camada de saída). A função de ativação da camada escondida é a logística e da camada de saída é a identidade. Dos dezessete neurônios da camada de entrada, os cinco primeiros são as entradas contínuas (profundidade vertical do poço, vazão, taxa de penetração, diferencial de pressão poço-formação e diâmetro da broca, nesta ordem). Os últimos doze neurônios são as entradas categóricas (tipo de litologia).

Tabela 4.3. Melhor rede inversa obtida no Statistica© versão 8, para previsão de RPM e WOB tendo a ROP como entrada a litologia como uma variável de entrada categórica

Tipo	Número de neurônios			Função ativ. camada escondida	Função ativ. camada saída
	Camada de entrada	Camada escondida	Camada de saída		
MLP	17	9	2	Logística	Identidade

4.2.4 Redes inversas separadas por litologia

Além de uma rede inversa tendo as litologias como entradas categóricas, treinou-se uma rede inversa para cada tipo de litologia. Para cada tipo de litologia foram treinadas cem redes diferentes e a melhor delas (indicada pelo Statistica© versão 8) foi implementada em

MATLAB. No Apêndice A, encontra-se um exemplo de código de uma rede inversa separada por litologia. Todas as redes são MLP, mais adequadas para problemas de regressão.

A Tabela 4.4 mostra o tamanho de cada uma das redes, bem como as funções de ativação dos neurônios da camada escondida e da camada de saída. Vale ressaltar que as doze redes diretas separadas por litologias não possuem entradas categóricas.

Tabela 4.4. Melhores redes inversas obtidas no Statistica© versão 8 para previsão de RPM e WOB tendo a ROP como entrada

Tipo	Número de neurônios			Função ativ. camada escondida	Função ativ. camada saída
	Camada de entrada	Camada escondida	Camada de saída		
ALB	5	7	2	Logística	Tangente Hiperbólica
AND	5	5	2	Tangente Hiperbólica	Logística
ARN_MAC	5	11	2	Tangente Hiperbólica	Logística
CLU	5	10	2	Tangente Hiperbólica	Tangente Hiperbólica
COQ	5	7	2	Logística	Logística
CRE	5	8	2	Identidade	Identidade
CRN	5	5	2	Tangente Hiperbólica	Exponencial
FLH	5	11	2	Logística	Exponencial
HAL	5	8	2	Logística	Logística
MRG	5	10	2	Exponencial	Identidade
SLT	5	9	2	Exponencial	Identidade
TQD	5	10	2	Tangente Hiperbólica	Identidade

A seguir, é apresentada a avaliação do desempenho das redes neuronais obtidas.

4.3 Avaliação das redes obtidas

Para avaliar os resultados obtidos com as redes e demais modelos, analisaram-se quatro parâmetros: coeficiente de correlação (R), erro quadrático médio e os coeficientes linear e angular obtidos do gráfico de dados reais versus dados previstos (ROP, WOB ou RPM).

O coeficiente de correlação é um bom parâmetro para indicar a eficiência das redes, mas, quando analisado isoladamente, não é capaz de dar uma visão adequada do quão boas ou ruins estão as previsões do modelo. Por exemplo: caso um determinado modelo gere um gráfico de dados reais *versus* previstos com a forma de uma reta perfeita, mas bastante afastada da bissetriz, o R terá um valor unitário, mas as previsões do modelo terão um grande *offset* em relação aos dados reais.

O erro quadrático médio ajuda a minimizar este problema. Um simulação que apresente um alto R e um baixo erro quadrático médio mostra uma boa performance do modelo.

Para melhorar a avaliação dos modelos obtidos, analisaram-se também os coeficientes angulares e lineares obtidos dos gráficos de dados reais *versus* previstos. Um modelo que prevê com exatidão os dados reais de um sistema geraria um gráfico cujos pontos se alinhariam perfeitamente sobre a bissetriz, gerando uma reta com coeficiente angular igual à unidade e com coeficiente linear nulo. Ou seja, quanto mais próximo da unidade for o coeficiente angular e quanto mais próximo de zero for o coeficiente linear, melhores serão as previsões no modelo.

Assim, o modelo em análise será tanto melhor quanto:

- 1) O coeficiente de correlação (R) for mais próximo da unidade;
- 2) O erro quadrático médio for mais próximo de zero;
- 3) O coeficiente angular for mais próximo da unidade e
- 4) O coeficiente linear for mais próximo de zero.

Adicionalmente, é mostrado o valor de razão SD da rede. Este é o parâmetro utilizado pelo Statistica[®] Versão 8.0 para determinar, dentre todas as redes treinadas, aquela que tem o melhor desempenho. Este parâmetro dá uma boa ideia da dispersão dos resultados gerados pela rede. Quanto mais próximo de zero, melhor é o desempenho da rede.

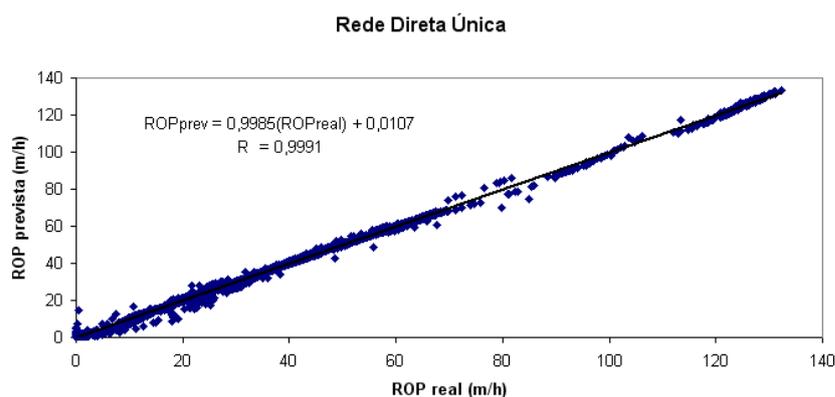
4.3.1 Rede direta única

A rede direta única apresentou um excelente coeficiente de correlação (R), um baixíssimo erro quadrático médio, um coeficiente angular muito próximo da unidade e um baixíssimo coeficiente linear ao reproduzir a taxa de penetração dos 43.524 dados usados em seu treinamento, conforme mostrado na Tabela 4.5.

Tabela 4.5. Parâmetros de análise da rede direta

Coefficiente de correlação (R)	0,9991
Erro Quadrático Médio	0,0671
Coefficiente Angular	0,9985
Coefficiente Linear	0,0107
Razão SD	0,0397

Confirmando os dados da Tabela 4.5, a Figura 4.1 mostra o gráfico das taxas de penetração estimadas pelo modelo *versus* as taxas de penetração reais. Note que os pontos se alinham muito próximos à bissetriz. Estas observações mostram que a rede foi capaz de prever muito bem as taxas de penetração reais. Vale ressaltar que estes dados são os mesmos 43.524 pontos apresentados à rede em seu treinamento. Faz-se ainda necessário uma etapa de validação posterior com dados totalmente novos à rede.

Figura 4.1. ROP prevista *versus* ROP real – rede direta única

4.3.2 Redes diretas separadas por litologias

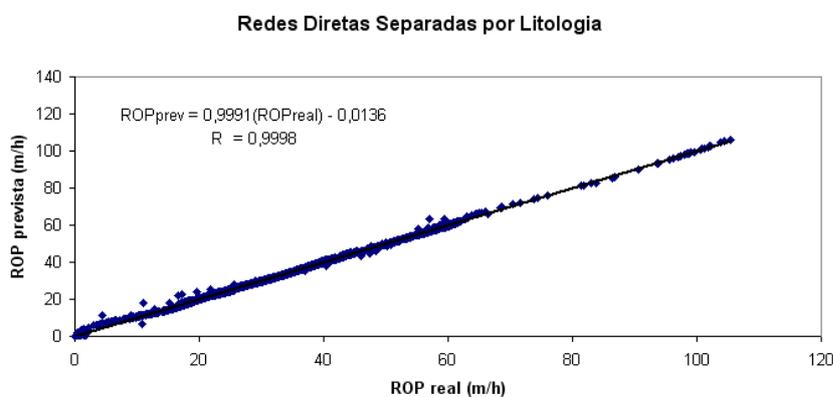
4.3.2.1. Redes diretas separadas por litologia analisadas em conjunto

Reproduziram-se os mesmos dados mostrados na Figura 3.2 (43.524 pontos coletados para o treinamento das redes) com as redes separadas por litologia. Para isso, fez-se um programa auxiliar no MATLAB, chamado de “gerenciador”. Este programa lê os dados, identifica o tipo de litologia e chama a rede adequada para fazer a previsão.

As redes separadas por litologia apresentaram um coeficiente de correlação elevado, como se observa na Tabela 4.6 e na Figura 4.2. Ainda na Tabela 4.6, observa-se que o erro quadrático médio ao reproduzir a taxa de penetração dos 43.524 dados usados para o treinamento das redes (incluindo os dados usados para validação e teste) também foi extremamente baixo, assim como o coeficiente linear. O coeficiente angular também foi bastante próximo da unidade. Na Figura 4.2, observa-se os dados reais *versus* dados previstos pelo modelo. Note que, assim como no caso da rede direta, os pontos estão bastante próximos à bissetriz, o que mostra que a rede previu muito bem as taxas de penetração reais. Mais uma vez ressalta-se a necessidade de uma validação posterior com dados totalmente novos às redes.

Tabela 4.6. Parâmetros de análise da rede direta

Coeficiente de correlação (R)	0,9998
Erro Quadrático Médio	0,0022
Coeficiente Angular	0,9991
Coeficiente Linear	0,0136
Razão SD	0,0246

Figura 4.2. ROP prevista *versus* ROP real – redes diretas separadas por litologias

De modo geral, os dados apresentados nas Tabelas 4.6 e 4.5 mostram resultados melhores para as redes separadas por litologias do que para a rede direta única. Mas, mais uma vez, vale lembrar que esta análise foi feita com os próprios dados usados no treinamento das redes, o que impossibilita qualquer conclusão. Mais adiante, serão mostradas análises dos modelos obtidos com dados totalmente inéditos.

4.3.2.2. Redes diretas separadas por litologia analisadas separadamente

Os dados acima (Tabela 4.6 e Figura 4.2) mostram o resultado das redes diretas trabalhando em conjunto e prevendo dados onde todas as litologias estão presentes. A fim de avaliar o desempenho individual de cada uma das redes, os dados foram separados por litologias e apresentados às suas respectivas redes para que as taxas fossem previstas pelas mesmas e comparadas com os valores reais.

As Figuras B.1 a B.12, que se encontram no Apêndice B, mostram os gráficos de taxas de penetração previstas *versus* taxas de penetração reais de cada uma das litologias testadas. A Tabela 4.7 mostra os coeficientes de correlação (R), erros quadráticos médios, coeficientes angulares e coeficientes lineares obtidos com as redes.

Tabela 4.7. Parâmetros para verificação do desempenho das redes diretas separadas por litologia

Redes separadas por litologia	R	Erro quadrático médio	Coefficiente angular	Coefficiente linear	Razão SD
ALB	0,9821	0,0031	0,9533	0,0143	0,1368
AND	0,9996	0,0008	0,9928	0,0017	0,0210
ARN_MAC	0,9993	0,0011	0,9994	0,0126	0,3638
CLU	0,9984	0,0026	0,9972	0,0023	0,0401
COQ	0,9974	0,0035	0,9971	0,0005	0,0507
CRE	1,0000	0,0061	0,9985	0,0008	0,0062
CRN	0,9986	0,0020	0,9929	0,0095	0,0385
FLH	0,9989	0,0027	0,9989	0,0192	0,0327
HAL	0,9980	0,0093	0,9972	0,0003	0,0451
MRG	0,9943	0,0049	0,9946	0,0015	0,0757
SLT	0,9953	0,0023	0,9940	0,0053	0,0685
TQD	0,9924	0,0020	0,9998	0,0025	0,0885

Os resultados mostrados na Tabela 4.7 e nas Figuras B.1 a B.12 mostram um excelente desempenho das redes separadas por litologia quando trabalhando em separado, ou seja, prevendo dados apenas para suas respectivas litologias. Evidentemente, uma análise com dados inéditos é necessária antes de qualquer conclusão, mas estes resultados preliminares são bastante positivos. Todas as redes apresentaram elevados coeficientes de correlação e baixíssimos erros quadráticos médios. Todos os coeficientes angulares estão muito próximos da unidade e todos os coeficientes lineares são próximos de zero.

4.3.3 Rede inversa única

A rede inversa não teve êxito na previsão de rotação e peso sobre broca para uma determinada taxa de penetração. Apesar de a Tabela 4.8 mostrar valores razoavelmente elevados de coeficiente de correlação (R) e valores razoavelmente baixos de erro quadrático médio, os coeficientes angulares e lineares mostram uma má capacidade de previsão dos parâmetros, especialmente da rotação da broca.

A Figura 4.3 mostra o gráfico de RPM prevista pela rede inversa única *versus* RPM real. Percebe-se que os dados formam uma nuvem dispersa em vez de se alinharem sobre (ou próximo à) bissetriz, o que corrobora a informação contida nos valores de coeficientes angular e linear de que o modelo direto único não consegue prever bem este parâmetro.

Tabela 4.8. Parâmetros de análise da rede inversa

Parâmetro	RPM	WOB
Coefficiente de correlação (R)	0,9290	0,9577
Erro quadrático médio	0,100	0,003
Coefficiente Angular	0,9217	0,9522
Coefficiente Linear	9,4832	0,5202
Razão SD	0,2729	0,2017

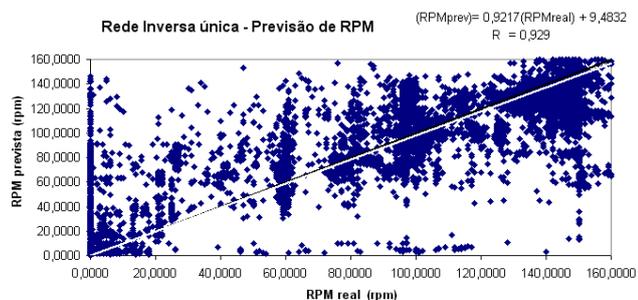


Figura 4.3. RPM real *versus* RPM prevista – rede inversa única

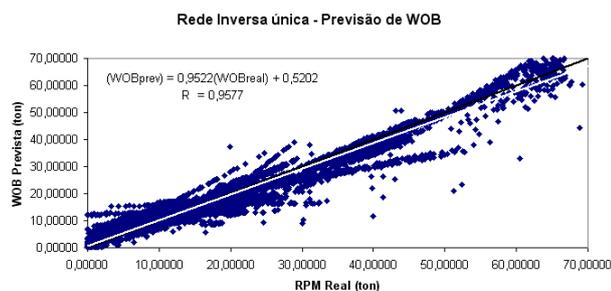


Figura 4.4. WOB real *versus* WOB prevista – rede inversa única

4.3.4 Redes inversas separadas por litologia

Como citado anteriormente, foram treinadas redes específicas para cada um dos doze tipos de litologias. A exemplo do que foi feito para as redes diretas separadas por litologia, aqui também foi feito um “gerenciador”, que identifica o tipo de litologia e aciona a rede mais apropriada para fazer a previsão. A seguir, o desempenho de cada uma destas redes é analisada em separado. Será analisada também a performance de todas as redes quando prevendo a taxa de penetração de uma série de dados reais em conjunto.

4.3.4.1. Redes inversas separadas por litologia analisadas em conjunto

Através do “gerenciador”, usaram-se as redes inversas para prever a rotação e o peso sobre broca dos 43.524 dados coletados. O resultado foi muito semelhante ao obtido com a rede inversa única. As redes inversas separadas também não foram capazes de prever bem os dados de RPM, como mostram os dados da Tabela 4.9 e a Figura 4.5. O coeficiente de correlação obtido (de 0,9163), apesar de mais baixo do que os obtidos com as outras redes, ainda apresenta um valor elevado. O coeficiente angular também é bem próximo da unidade. Entretanto, o erro quadrático médio apresenta um valor bastante elevado. O coeficiente linear também é bastante alto. Além disso, o gráfico de RPM prevista *versus* RPM real (Figura 4.5) mostra que os pontos formam uma nuvem dispersa, o que confirma o desempenho ruim da rede para a previsão da rotação.

Houve, entretanto, uma pequena melhora na previsão do peso sobre broca, quando comparada à previsão feita pela rede inversa única. Os dados da Tabela 4.9 mostram um bom coeficiente de correlação e um erro quadrático médio baixo. O valor do coeficiente angular também é muito próximo da unidade e o coeficiente linear é praticamente nulo. A Figura 4.6 mostra o gráfico de WOB prevista *versus* WOB real, em que os pontos se alinham próximos à bissetriz, indicando uma boa previsão do modelo.

Tabela 4.9. Parâmetros de análise do desempenho da rede inversa única

Parâmetro (R)	RPM	WOB
Coefficiente de correlação	0,9163	0,9433
Erro quadrático médio	0,280	0,020
Coefficiente Angular	1,0079	1,0057
Coefficiente Linear	-1,3266	0,0007
Razão SD	0,2010	0,0632

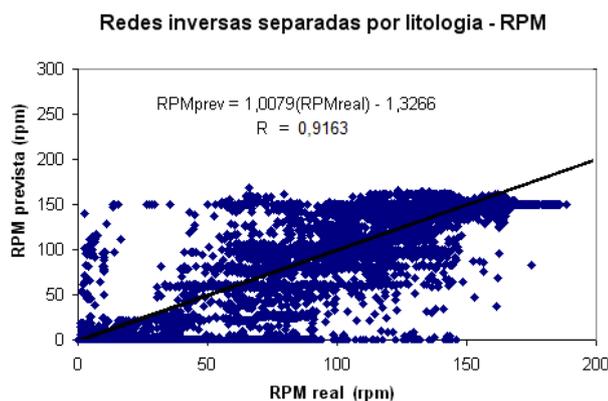


Figura 4.5. RPM real versus RPM prevista – redes inversas separadas por litologia

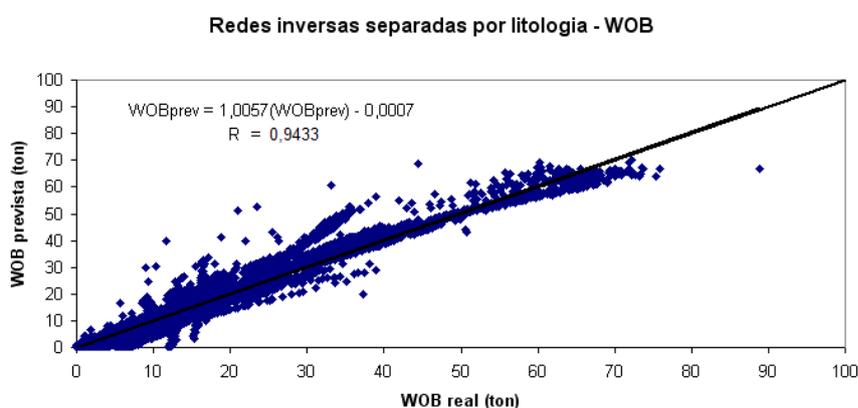


Figura 4.6. WOB real versus WOB prevista – redes inversas separadas por litologia

4.3.4.2. Redes inversas separadas por litologia analisadas separadamente

Os dados acima (Tabela 4.9 e Figuras 4.5 e 4.6) mostram os resultados das redes inversas trabalhando em conjunto e prevendo dados onde todas as litologias estão presentes. A fim de avaliar o desempenho individual de cada uma das redes, os dados foram separados por litologias e apresentados às suas respectivas redes para que as rotações e pesos sobre broca fossem previstos pelas mesmas e comparadas com os valores reais.

A Tabela 4.10 e as Figuras B.13 a B.36 (contidas no Apêndice B da dissertação) mostram os resultados obtidos.

Note, na Tabela 4.10, que os parâmetros para a previsão do peso sobre broca mostram-se bem melhores do que os para a previsão da rotação da broca. Os coeficientes de correlação e os erros quadráticos médios apresentam valores, respectivamente, muito mais próximos da unidade e de zero do que no caso da previsão da rotação da broca. Os coeficientes angulares são ligeiramente mais próximos da unidade para o caso do WOB. Porém, os coeficientes lineares obtidos para a RPM são muito elevados, contrastando com os baixos valores dos coeficientes do WOB.

Além disso, a análise das Figuras B.13 a B.36 mostra que, em geral, os dados de WOB formam uma reta bem comportada sobre a bissetriz, enquanto os dados de RPM formam uma nuvem dispersa, indicando a falta de capacidade da rede de prever a rotação.

Os maus resultados da rede inversa se devem ao fato de que existem múltiplos pares de RPM e WOB para uma única taxa de penetração de saída. Durante uma perfuração real, é, por exemplo, comum que os engenheiros responsáveis sejam obrigados a reduzir a rotação da broca (seja por questões de segurança de poço ou por problemas operacionais). Em casos como estes, para evitar uma redução da taxa de penetração, aumenta-se o peso sobre broca para compensar a queda da rotação. Se, ao contrário, os engenheiros são obrigados a reduzir o peso sobre broca, aumenta-se a rotação da broca para evitar a queda na taxa de penetração.

Assim, a multiplicidade de pares de RPM e WOB para uma mesma ROP é observada na prática durante a perfuração e foi reproduzida com sucesso pelas redes diretas. Isto impossibilita o uso de modelos inversos para a previsão de RPM e WOB. As redes inversas não funcionam, pois este tipo de arquitetura não permite a obtenção de múltiplas saídas para uma única entrada, mesmo a recíproca não sendo verdadeira.

Uma vez que as redes inversas mostraram-se inadequadas para a previsão de RPM e WOB (pelos motivos expostos acima), não será realizada validação com dados inéditos de poços.

Tabela 4.10. Parâmetros de análise do desempenho das redes separadas por litologia

R P M					
Litologia	R	Erro quadrático médio	Coefficiente angular	Coefficiente Linear	Razão SD
ALB	0,9301	0,6131	0,9561	2,3264	0,2657
AND	0,9643	0,3750	0,9403	8,0043	0,1906
ARN_MAC	0,9431	1,0010	0,9382	2,4097	0,2385
CLU	0,9983	0,9317	0,9971	0,4780	0,0418
COQ	0,8819	1,3040	0,8681	13,3510	0,3440
CRE	0,8965	0,5518	0,9229	7,7917	0,3230
CRN	0,9615	0,1248	0,9550	2,5291	0,1964
FLH	0,9537	2,1110	0,9507	7,0126	0,2153
HAL	0,8894	2,7374	0,9054	10,4000	0,3331
MRG	0,9438	1,1101	0,9455	5,5996	0,2372
SLT	0,9526	0,9913	0,9513	5,8097	0,2177
TQD	0,8480	0,9777	0,8485	15,1300	0,0785
W O B					
Litologia	R	Erro quadrático médio	Coefficiente angular	Coefficiente Linear	Razão SD
ALB	0,9592	0,0170	0,9113	3,9521	0,2079
AND	0,9971	0,0083	0,9752	0,1747	0,0578
ARN_MAC	0,9980	0,0094	0,9924	0,1276	0,0451
CLU	0,9994	0,0004	0,9979	0,0204	0,0238
COQ	0,9958	0,0013	0,9937	0,0957	0,0652
CRE	0,9924	0,0008	0,9874	0,2289	0,0871
CRN	0,9981	0,0009	0,9915	0,0949	0,0440
FLH	0,9953	0,0021	0,9940	0,0818	0,0686
HAL	0,9867	0,0082	0,9699	0,2949	0,1167
MRG	0,9984	0,0007	0,9997	0,0125	0,0402
SLT	0,9995	0,0006	0,9989	0,0045	0,0220
TQD	0,9988	0,0004	0,9971	0,0009	0,0214

4.4 Validação das redes diretas com dados inéditos

As análises mostradas acima foram feitas, em grande parte, com os mesmos dados usados para o treinamento da rede (excetuam-se apenas os dados usados para seleção), o que permite apenas uma conclusão preliminar sobre a real capacidade de previsão dos modelos obtidos, sejam os modelos diretos únicos (que têm a litologia como entrada categórica), os modelos diretos separados por litologia, os modelos inversos únicos (litologia como entrada categórica) ou os inversos separados por litologia. Apesar disso, as análises anteriores mostram uma tendência de que os modelos prevejam bem os dados reais.

Para a validação das redes neuronais obtidas, coletaram-se dados totalmente inéditos de quatro poços (chamados aqui de Poços A, B, C e D) da mesma região dos poços de treinamento. Tomou-se o cuidado de garantir que em nenhum dos poços escolhidos houve problema de broca desgastada, o que reduziria a taxa de penetração e levaria dúvidas sobre a eficácia da rede em prever estes dados. Outro cuidado que se tomou foi o de garantir que não

havia nesses poços nenhuma litologia diferente das doze presentes nos dados usados para o treinamento das redes.

Os poços escolhidos para a validação continham as seguintes litologias cada (note que todas as doze litologias foram contempladas na validação):

- Poço A (4.835 pontos): anidrita, folhelho, halita, taquidrita, arenito e carbonato albiano.

- Poço B (3.551 pontos): arenito, folhelho, siltito, coquina, calcarenito, carnalita e carbonato albiano.

- Poço C (11.672 pontos): arenito, folhelho, coquina, marga, siltito, halita, taquidrita, carnalita, anidrita e Calcilutito.

- Poço D (3.893 pontos): arenito, folhelho, siltito, calcarenito.

Selecionaram-se ainda, apenas poços perfurados com brocas, descartando-se aqueles perfurados com turbinas.

4.4.1 Validação da rede direta única

Dados totalmente inéditos de quatro poços, A, B, C e D, foram apresentados à rede neuronal direta única para que as taxas de penetração previstas por ela fossem comparadas com as taxas reais. Os dados dos poços foram alimentados à rede e, para cada instante de tempo, foi prevista uma taxa de penetração com base nas entradas disponíveis.

A seguir, os resultados obtidos são apresentados.

4.4.1.1. Validação da rede direta única com dados do poço A

A Figura 4.7 mostra um gráfico de ROP prevista *versus* ROP real para o poço A. O coeficiente de correlação foi extremamente baixo (0,1903). O erro quadrático médio da previsão foi de 0,1021, o que também é um valor bastante elevado. Os coeficientes angulares e lineares são, respectivamente, 0,7372 (valor muito baixo) e 4,1711 (valor muito alto), o que corrobora uma má predição dos dados do poço A pela rede direta única.

Note que, na Figura 4.7 e nas próximas, a reta que se vê é a bissetriz, sob a qual deveriam se alinhar os pontos no caso de uma boa previsão. A equação da reta e o coeficiente de correlação que aparecem se referem não à bissetriz, mas à reta que melhor se ajusta aos pontos do gráfico. Esta reta, não aparece na figura.

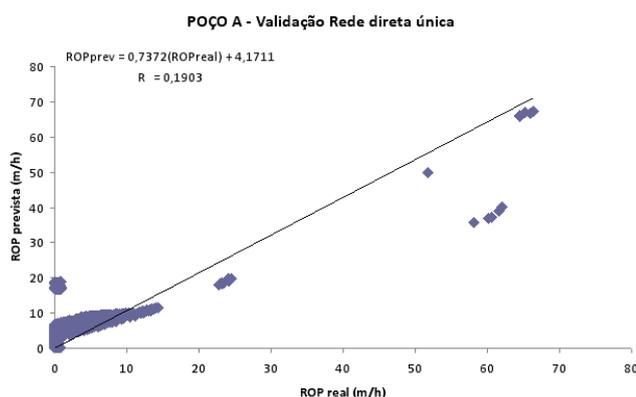


Figura 4.7. ROP prevista *versus* ROP real para o poço A - Rede direta única

A Figura 4.8 mostra um histograma de frequência dos erros absolutos na previsão das taxas de penetração reais do poço A. Nota-se uma grande frequência de erros na faixa de -15,88 a -17,80 m/h. Estes valores de erro são extremamente elevados. Há também uma frequência grande de erros na faixa de -6,29 a 9,06 m/h, o que também representa erros elevados.

Os gráficos das Figuras 4.7 e 4.8 mostram resultados ruins da previsão da taxa real pela rede direta única para o poço A.

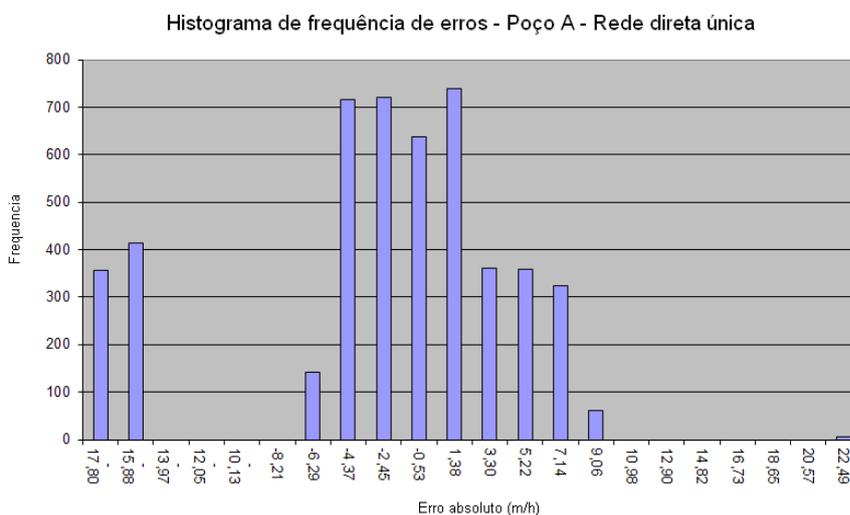


Figura 4.8. Histograma de frequência de erros absolutos para o poço A – rede direta única

4.4.1.2. Validação da rede direta única com dados do poço B

Para o poço B, obtém-se resultados ainda piores. A Figura 4.9 mostra um gráfico de ROP prevista *versus* ROP real para o poço. Apesar de os dados para este poço apresentarem um coeficiente de correlação maior que o poço anterior (0,4731), nota-se claramente que as

previsões foram piores. O erro quadrático médio das previsões para este poço foi de 0,3694, o coeficiente angular foi de 1,8612 (bem distante da unidade) e o coeficiente linear foi de 8,0049 (também, muito distante de zero).

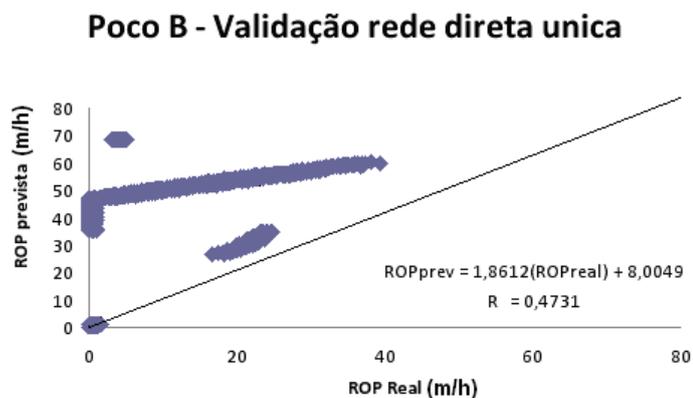


Figura 4.9. ROP prevista versus ROP real para o poço B – Rede direta única

A Figura 4.10 mostra o histograma de frequência dos erros absolutos na previsão das taxas de penetração reais do poço B. Apesar de a maior frequência de erros se dar para valores próximos de zero, há ainda uma grande quantidade de erros na faixa de -44,65 a -28,49 m/h, o que representa valores extremamente elevados.

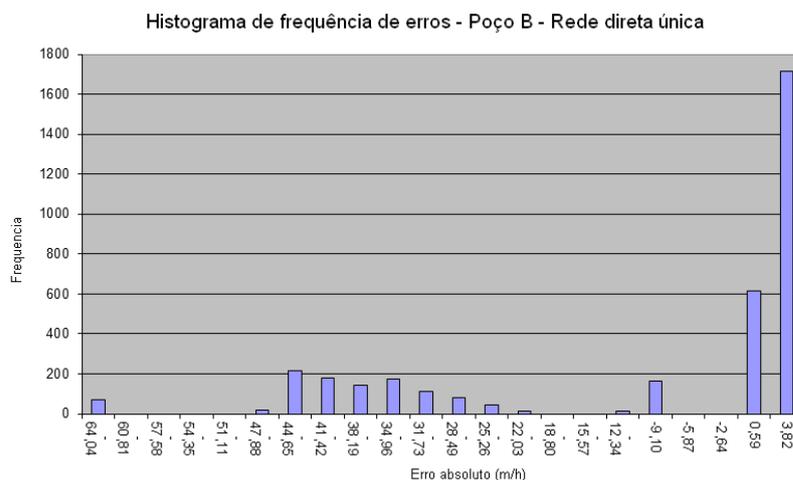


Figura 4.10. Histograma de frequência de erros absolutos para o poço B – rede direta única

4.4.1.3. Validação da rede direta única com dados do poço C

Os resultados obtidos com a validação da rede direta única para o poço C também não foram bons. A Figura 4.11 mostra um gráfico de ROP prevista pela rede versus ROP real. Note que os pontos estão muito afastados da bissetriz, indicando que a rede não foi capaz de

prever adequadamente as taxas reais. Além disso, a rede apresentou um erro quadrático médio de 2,42 m/h e um coeficiente de correlação de 0,4129. Os coeficientes angular e linear, obtidos do gráfico mostrado na Figura 4.12, são respectivamente -13,296 e 479,52, o que confirma a péssima previsão da rede.

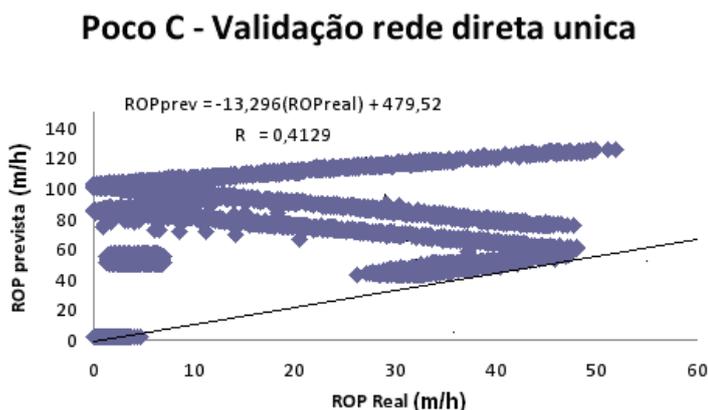


Figura 4.11. ROP prevista versus ROP real para o poço C – Rede direta única

A Figura 4.12 mostra o diagrama de frequência de erros absolutos obtidos com a rede direta para o poço C e corrobora as conclusões tiradas com a Figura 4.11. Observa-se que os erros são extremamente elevados (cerca de -630 m/h). As maiores frequências estão na faixa de -632 a -484 m/h e -100 a -12 m/h. São erros extremamente elevados e inaceitáveis para qualquer modelo de previsão.

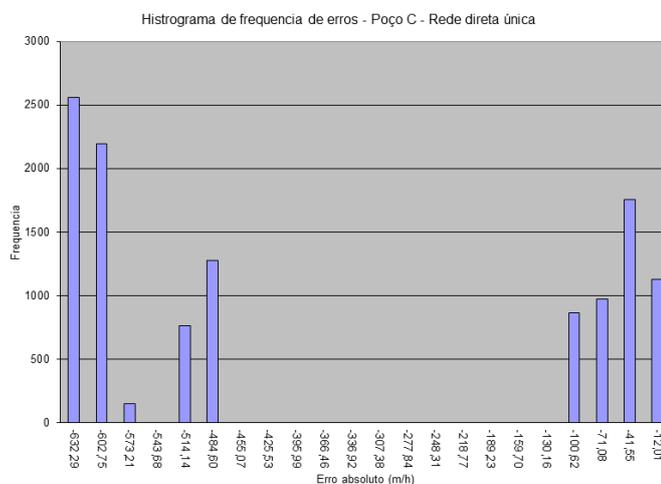


Figura 4.12. Histograma de frequência de erros absolutos para o poço C – rede direta única

4.4.1.4. Validação da rede direta única com dados do poço D

Assim como nos três poços anteriores, os resultados obtidos com a validação da rede direta única para o poço D também não foram bons. A Figura 4.13 mostra um gráfico de ROP prevista pela rede *versus* ROP real. Note que os pontos formam duas nuvens em duas regiões distintas, ambas bem afastadas da bissetriz, indicando que a rede não foi capaz de prever adequadamente as taxas reais. Além disso, a rede apresentou um erro quadrático médio de 0,4371 m/h e um coeficiente de correlação de 0,0635, valor extremamente baixo. Os coeficientes angular e linear são respectivamente $-0,4159$ e $22,316$, o que confirma a péssima previsão da rede.

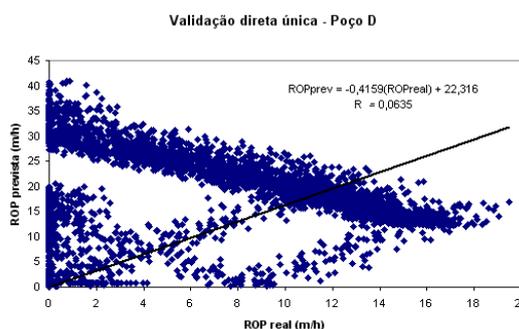


Figura 4.13. ROP prevista *versus* ROP real para o poço D – Rede direta única

A Figura 4.14 mostra o diagrama de frequência de erros absolutos obtidos com a rede direta para o poço D e corrobora as conclusões tiradas com a Figura 4.13. Observa-se que os erros são extremamente elevados, tanto os negativos quanto os positivos, e a maior frequência é observada entre 26,47 e 35,02 m/h, valores inaceitáveis na previsão de qualquer taxa de penetração.

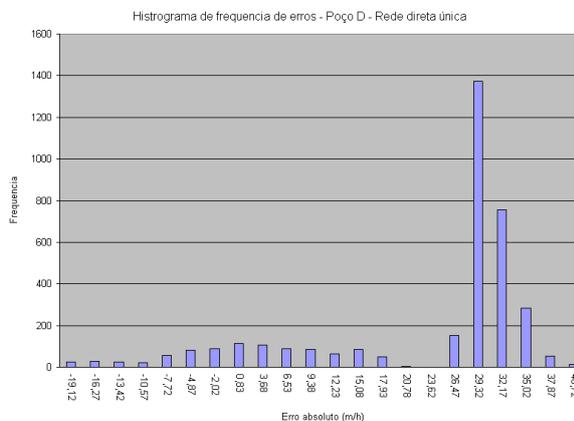


Figura 4.14. Histograma de frequência de erros absolutos para o poço D – rede direta única

A Tabela 4.11 mostra um resumo dos parâmetros de análise do desempenho da rede direta única para a previsão da taxa de penetração. Observe que, para todos os quatro poços testados, os valores de coeficientes de correlação são extremamente baixos. Além disso, os valores dos coeficientes angulares e lineares evidenciam a má previsão das taxas de penetração pela rede direta única.

Apesar de ter apresentado um bom desempenho quando usada para prever os dados dos seis poços usados em seu treinamento, o modelo mostrou-se incapaz de prever bem o comportamento de dados totalmente inéditos. Uma vez que nenhum dos quatro poços usados na validação apresentou problemas de desgaste de broca, composição de coluna ou histórico geológico muito diferente daqueles dos seis poços de treinamento, conclui-se que a rede direta única não é adequada para a previsão da taxa de penetração em poços na costa brasileira.

Tabela 4.11. Parâmetros de análise do desempenho da rede direta única para a previsão da taxa de penetração

Poço	R	Erro Quadrático Médio	Coefficiente Angular	Coefficiente Linear
A	0,1903	0,1021	0,7372	4,1711
B	0,4731	0,3694	1,8612	8,0049
C	0,4129	2,4200	-13,2960	479,5200
D	0,0635	0,4371	-0,4159	22,3160

4.4.2 Validação das redes diretas separadas por litologia

Os mesmos dados dos poços A, B, C e D foram apresentados ao “gerenciador” das redes diretas separadas por litologias (programa feito em MATLAB para escolher a melhor rede para fazer a previsão, dependendo da litologia corrente) para que as redes separadas, trabalhando em conjunto, previssem as taxas de penetração e as mesmas fossem comparadas com as taxas reais. Diferentemente dos resultados da validação obtidos para a rede direta, as redes separadas apresentaram uma resposta boa.

4.4.2.1. Validação das redes diretas separadas por litologia com dados do poço A

A Figura 4.15 mostra um gráfico de ROP prevista (pelas redes separadas por litologia) *versus* ROP real para o poço A. Note que, além de um elevado coeficiente de correlação (0,9964), os pontos se encontram praticamente em cima da bissetriz, o que mostra que as redes previram com bastante sucesso as taxas de penetração reais. O erro quadrático médio nas previsões para o poço A foi de 0,0035. O coeficiente angular de 1,0012 (extremamente

próximo à unidade) e o coeficiente linear de 0,0699 (também muito próximo de zero) mostram uma excelente capacidade de previsão das redes.

A Figura 4.16 mostra o histograma de frequência dos erros absolutos do poço A e confirma os bons resultados apresentados acima. Note que os erros na predição da taxa de penetração real pelas redes são extremamente baixos. A maior incidência de erros está na faixa de 0,02 m/h, o que é um resultado muito bom.

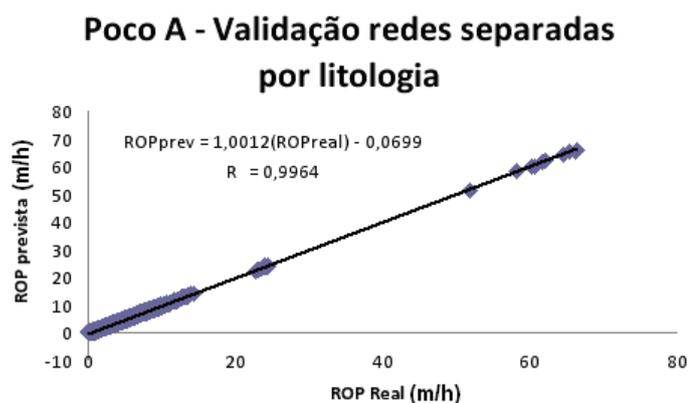


Figura 4.15. ROP prevista versus ROP real para o poço A – Redes diretas separadas

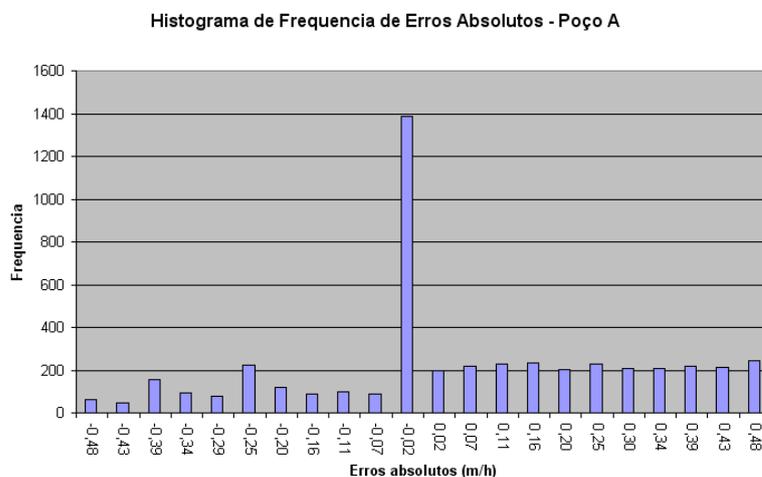


Figura 4.16. Histograma de frequência de erros absolutos para o poço A – redes diretas separadas por litologias

4.4.2.2. Validação das redes diretas separadas por litologia com dados do poço B

Para o poço B, os resultados foram bastante semelhantes. A Figura 4.17 mostra um gráfico de ROP prevista versus ROP real para o poço. Assim como no poço anterior, o

coeficiente de correlação foi bastante elevado (0,9961) e os pontos se encontram praticamente em cima da bissetriz, o que mostra que as redes previram com bastante sucesso as taxas de penetração reais. O erro quadrático médio nas previsões para o poço B foi de 0,0039. O coeficiente angular obtido é extremamente próximo da unidade (0,9991) e o coeficiente linear também é extremamente baixo (0,0362), o que reflete excelentes previsões feitas pelas redes diretas separadas por litologia.

A Figura 4.18 mostra o diagrama de frequência dos erros absolutos para o poço B. Apesar de apresentar erros superiores aos do poço A, a frequência dos erros mais elevados é extremamente baixa. A maior quantidade de erros ocorre na faixa de 0,01 m/h, o que é bastante baixo e aceitável.

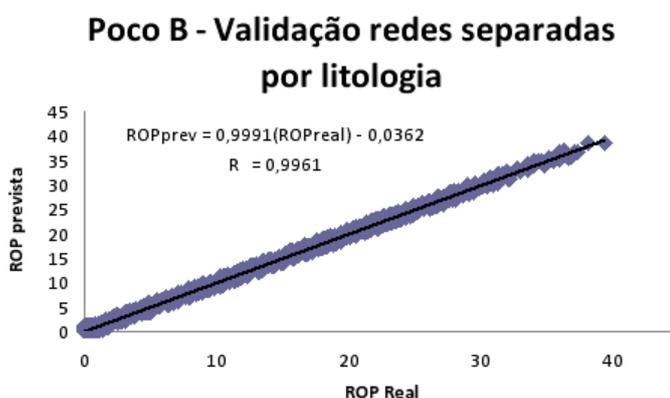


Figura 4.17. ROP prevista *versus* ROP real para o poço B – Redes diretas separadas

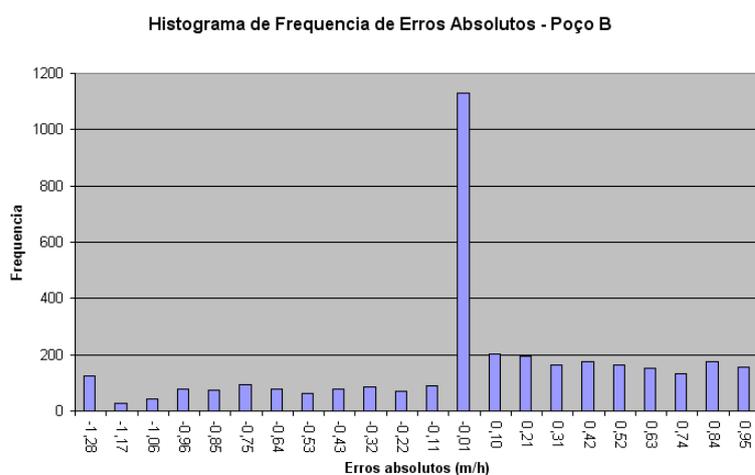


Figura 4.18. Histograma de frequência de erros absolutos para o poço B – redes diretas separadas por litologias

4.4.2.3. Validação das redes diretas separadas por litologia com dados do poço C

Os resultados obtidos com a validação das redes diretas separadas por litologia com os dados do poço C foram tão bons quanto os dos outros dois poços. A Figura 4.19 mostra o gráfico de ROP prevista *versus* ROP real. Os pontos se alinham muito bem sobre a bissetriz, apesar de apresentar uma dispersão um pouco maior do que a dos outros casos. O coeficiente de correlação (0,9923) é bastante elevado e o erro quadrático médio foi de 0,0106 m/h, valor extremamente baixo. O coeficiente angular obtido foi de 1,0045, muito próximo da unidade. O coeficiente linear também apresenta um valor baixo (-0,3397), apesar de ligeiramente superior aos demais poços testados. O valor mais elevado do coeficiente de correlação para o poço C é causado pela maior dispersão observada nos pontos do gráfico. Mesmo assim, os resultados obtidos para este poço também foram muito positivos, confirmando a boa capacidade de previsão das redes diretas separadas por litologia.

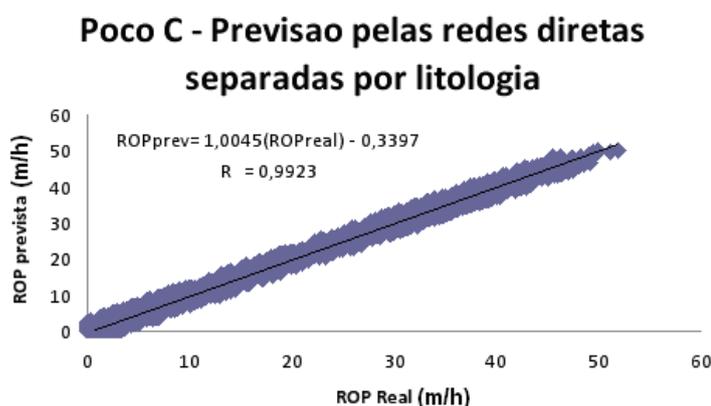


Figura 4.19. ROP prevista *versus* ROP real para o poço C – Redes diretas separadas

A Figura 4.20 mostra o diagrama de frequência dos erros absolutos para o poço C. Note que as maiores frequências ocorrem para valores muito próximos de zero, o que evidencia a boa capacidade de previsão das redes.

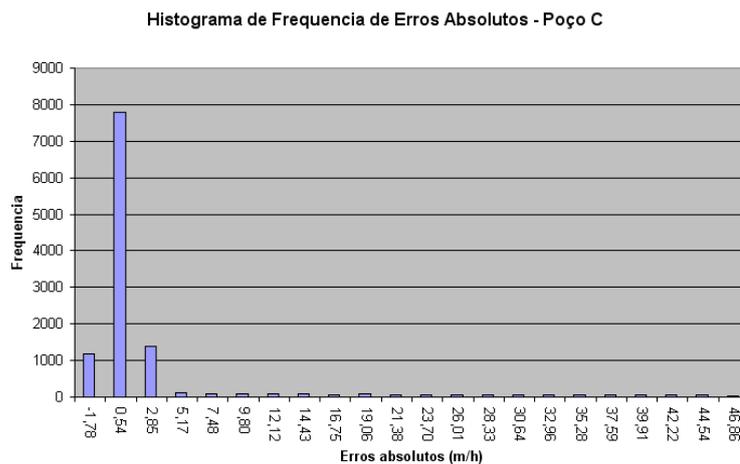


Figura 4.20. Histograma de frequência de erros absolutos para o poço C – redes diretas separadas por litologias

4.4.2.4. Validação das redes diretas separadas por litologia com dados do poço D

Por fim, os resultados obtidos com a validação das redes diretas separadas por litologia com os dados do poço D foram, também, muito bons. A Figura 4.21 mostra o gráfico de ROP prevista *versus* ROP real. Os pontos se alinham sobre a bissetriz, apesar de apresentar uma dispersão um pouco maior do que a dos outros três poços. O coeficiente de correlação foi de 0,9682, valor bastante elevado que reflete o bom desempenho das redes. O erro quadrático médio foi de 0,0153 m/h, valor extremamente baixo. O coeficiente angular obtido foi de 0,9857, muito próximo da unidade. O coeficiente linear também apresenta um valor bastante baixo, de 0,0057. Estes valores indicam claramente que, também para este poço, as redes separadas por litologia apresentam um bom desempenho na previsão das taxas de penetração.

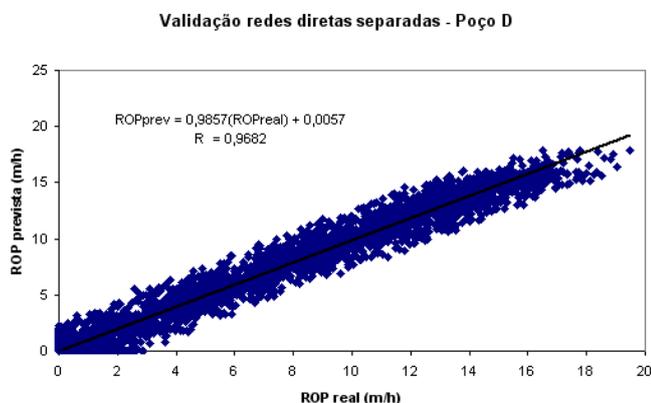


Figura 4.21. ROP prevista *versus* ROP real para o poço D – Redes diretas separadas

A Figura 4.22 mostra o diagrama de frequência dos erros absolutos para o poço D. Note que a distribuição dos erros absolutos segue claramente uma distribuição normal, sendo as maiores frequências observadas para erros em torno do zero. Além disso, a frequência para erros maiores decai rapidamente e não são observados, em valores absolutos, erros superiores a 3 m/h. Este é um excelente resultado e confirma a boa capacidade das redes diretas separadas por litologia.

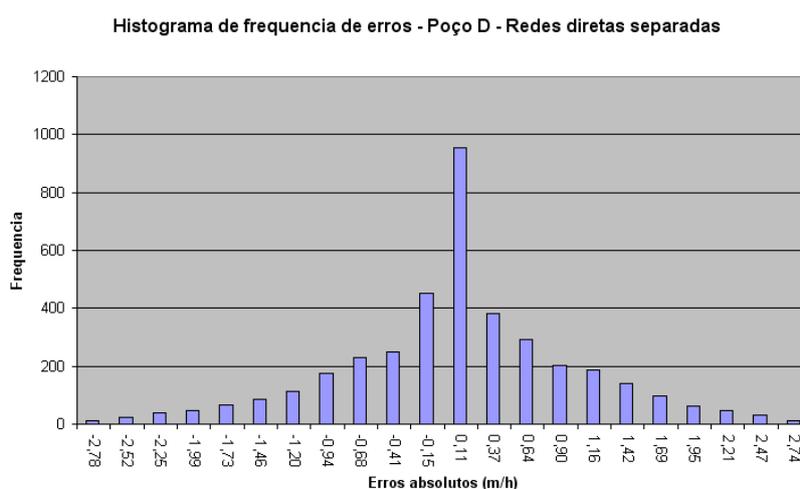


Figura 4.22. Histograma de frequência de erros absolutos para o poço D – redes diretas separadas por litologias

A Tabela 4.12 mostra um resumo dos parâmetros de análise do desempenho das redes diretas separadas por litologia. Observa-se que todos os poços apresentaram um elevado coeficiente de correlação, bem como valores bastante reduzidos para os erros quadráticos médios, coeficientes angulares bem próximos da unidade e coeficientes lineares também muito próximos de zero. Em contraste com a rede direta única, estes resultados permitem concluir que as redes diretas separadas por litologias são capazes de prever a taxa de penetração para poços na costa brasileira.

Tabela 4.12. Parâmetros de análise do desempenho das redes diretas separadas por litologia para a previsão da taxa de penetração

Poço	R	Erro Quadrático Médio	Coefficiente Angular	Coefficiente Linear
A	0,9964	0,0035	1,0012	-0,0699
B	0,9961	0,0039	0,9991	-0,0362
C	0,9923	0,0106	1,0045	-0,3397
D	0,9682	0,0153	0,9857	0,0057

Outra confirmação de que as redes diretas únicas são, de fato, um modelo adequado para previsão de taxas de penetração é o fato de que os resíduos (erros) gerados pelas redes (mostrados nas Figuras 4.16, 4.18, 4.20 e 4.22), nos quatro poços de validação, podem ser modelados por uma distribuição normal. Os valores de χ^2 , JB (teste de Jarques-Barre) e LL (teste de Lilliefors) indicam que os resíduos podem, em grande parte, ser modelados por uma distribuição normal. Os parâmetros de χ^2 , JB e LL são usados para “testes de normalidade”, que indicam se uma determinada amostra segue ou não uma distribuição normal. Para uma determinada amostra, quanto mais próximos de zero estes parâmetros estiverem, mais normal é sua distribuição. Para os quatro poços de validação, os valores de χ^2 , JB e LL são muito próximos de zero. Para o poço A, $\chi^2 = 0,0039$, JB = 0,0132 e LL = 0,0095. Para o poço B, $\chi^2 = 0,0172$, JB = 0,048 e LL = 0,0194. Para o poço C, $\chi^2 = 0,0090$, JB = 0,0124 e LL = 0,0113. Para o poço D, $\chi^2 = 0,0001$, JB = 0,0000 e LL = 0,0000.

O fato de que as redes diretas separadas por litologia terem gerado, para os poços de validação, bons resultados de coeficientes de correlação (R), erros quadráticos médios, coeficientes angulares e coeficientes lineares, aliado ao fato de que os resíduos seguem uma distribuição normal, é um indício muito forte de que este tipo de modelo é adequado para a predição de taxas de penetração.

A diferença notória nos desempenhos das redes diretas separadas por litologia e da rede direta única é devido, provavelmente, à diferença entre as litologias. Cada tipo de rocha apresenta um comportamento bastante distinto quando submetido às diferentes condições operacionais. Esta diferença de comportamento entre os tipos de rocha fica evidente na Tabela 4.2. Percebe-se que cada uma das melhores redes obtidas para cada tipo de litologia possui funções de ativação na camada escondida e de saída distintas uma das outras. A rede direta separada para a Anidrita, por exemplo, tem a função tangente hiperbólica na camada escondida e a função logística na camada de saída. Já a rede direta para a Taquidrita apresenta a função exponencial na camada escondida e a função tangente hiperbólica na camada de saída. Isso reflete a diferença de comportamento de cada tipo litologia. Diferentemente do que ocorre com as redes diretas separadas, a rede direta única apresenta apenas uma única função na camada escondida e na camada de saída, minando a capacidade do modelo de prever estas diferenças de comportamento de cada tipo de rocha. A única forma que a rede direta única tem para diferenciar o comportamento das diferentes formações geológicas é a escolha de diferentes pesos e *biases* nos neurônios associados a cada entrada categórica. Nas redes diretas separadas por litologia, além de todos os pesos e *biases* da rede, pode-se também

escolher as funções de ativação mais adequadas àquele tipo de rocha. Por este motivo, as redes separadas por litologia são muito mais adequadas.

4.5 Comparação entre redes neuronais e demais modelos usados na indústria

As redes neuronais são uma tentativa de obtenção de um modelo confiável para a previsão da taxa de penetração, uma vez que os modelos existentes e usados na indústria do petróleo apresentam uma série de sérias limitações. Os resultados mostrados no item 4.4 mostram que o uso de redes neuronais pode, realmente, ter sucesso na previsão de taxas de penetração com base nas condições operacionais. Os resultados mostram ainda um desempenho significativamente melhor da rede quando são usados diferentes modelos para cada tipo específico de rocha.

Entretanto, para concluir que esta é, de fato, a melhor solução, é necessário fazer uma comparação com os modelos mais usados para este fim. Os três modelos mais usados para a previsão da taxa de penetração são os modelos de Young, Maurer e Bourgoyne.

Para a determinação das taxas de penetração com os modelos da literatura, faz-se necessária a determinação dos parâmetros de cada modelo com base em dados de poços reais. Para esta determinação, empregaram-se os dados dos mesmos seis poços usados no treinamento das redes neuronais. Já para a validação dos modelos, usaram-se os dados dos mesmos quatro poços usados para a validação das redes.

Para os modelos de Maurer e Young, não faz sentido determinar constantes gerais (que valessem em qualquer situação). Uma vez que, como já ficou claro, as diferentes litologias respondem de forma bastante distinta, os dados de treinamento foram divididos por litologia e os parâmetros do modelo foram determinados para cada uma destas litologias. É algo semelhante ao que foi feito para o treinamento das redes diretas separadas por litologia. Assim, na validação, desenvolveu-se um código em MATLAB que identifica o tipo de litologia e faz a previsão usando os valores dos parâmetros correspondentes àquela litologia.

Dentre as redes testadas, as redes diretas separadas por litologia mostraram-se como a opção mais adequada para a previsão de taxas. Sendo assim, as redes diretas separadas por litologia serão comparadas aos três modelos citados acima, conforme mostrado a seguir.

4.5.1 Comparação com modelo de Bourgoyne

Dentre os três modelos citados acima, o de Bourgoyne, como comentado anteriormente, é o mais completo e, portanto, aquele que fornece os resultados mais confiáveis. Entretanto, o modelo apresenta a grande desvantagem de exigir uma quantidade de informações extremamente difíceis de medir e que, na grande maioria dos casos, sequer estão disponíveis. É o caso, por exemplo, do desgaste de broca e do tempo de trânsito. O desgaste dos dentes da broca é uma informação fundamental para o modelo de Bourgoyne, mas é impossível de se medir durante uma perfuração real. A única forma de se obter esta informação seria a retirada da broca para a medida direta em superfície. Mas isso acarretaria na retirada e desmontagem da coluna de perfuração inteira do poço, medida do tamanho dos dentes da broca para determinar o desgaste e posterior remontagem e reinserção da coluna de perfuração no poço. Esta operação (conhecida como “manobra”) levaria cerca de 50 horas para ser concluída, o que inviabiliza a sua execução. Já o tempo de trânsito (que é relacionado com a dureza e perfurabilidade da rocha) é obtido pela ferramenta de sônico, que não está disponível na grande maioria das perfurações. Mesmo naqueles poços em que se dispõe de uma ferramenta de sônico, apenas em uma pequena fração, os dados de tempo de trânsito são disponibilizados em tempo real. Na maioria das vezes, estes dados só podem ser visualizados após o término da perfuração.

Evidentemente, o desgaste de broca afeta a resposta esperada de redes neuronais. No entanto, esta é uma situação extremamente difícil de contornar e afeta não só às redes, mas a todos os modelos para previsão da taxa. Neste trabalho, tomou-se o cuidado de garantir que em nenhum dos dez poços usados (tanto os seis de treinamento quanto os quatro de validação) apresentassem este tipo de problema, de forma que a análise feita aqui não fosse prejudicada.

É evidente, também, que o tempo de trânsito é uma variável importante e que afeta sobremaneira a resposta das rochas de subsuperfície às condições operacionais. Porém, a informação contida neste dado (a perfurabilidade) é, de certa forma, levada em conta nas redes neuronais em outros dados, tais como a litologia e a profundidade. Além disso, nada impede que, uma vez que este dado esteja disponível, uma rede neuronal seja treinada tendo esta informação como variável de entrada.

Uma vez que nem os dados de sônico e nem os dados de desgaste de broca puderam ser medidos em nenhum dos dez poços usados neste trabalho, não foi possível usar o modelo de Bourgoyne para uma comparação direta com as redes neuronais.

Entretanto, o fato de a rede neuronal ter gerado resultados plenamente satisfatórios sem a necessidade de usar o tempo de trânsito mostra que esta solução pode ser utilizada com sucesso mesmo em situações em que este dado não esteja disponível. Isso representa uma grande vantagem das redes sobre o modelo de Bourgoyne.

Assim, apesar de não ter sido apresentada uma comparação entre os resultados de previsão de taxas de penetração das redes neuronais e do modelo de Bourgoyne, fica evidente a vantagem da primeira opção.

4.5.2 Comparação com modelo de Maurer

O modelo de Maurer (Equação 2.1) é um dos modelos mais simples disponíveis e, talvez por isso, um dos mais usados. Porém, apesar de largamente utilizado na indústria do petróleo, os resultados gerados são, na grande maioria dos casos, muito diferentes dos resultados reais observados. Um dos principais problemas do modelo é, exatamente, a grande simplicidade com que um fenômeno de alta complexidade é tratado. Outro problema é que o modelo não prevê o comportamento não linear da taxa de penetração com a rotação da broca. Note que o uso do modelo de Maurer na equação da Energia Mecânica Específica (Equação 3.1) levaria a uma energia específica independente da rotação da broca, ou seja, a EME não variaria com o aumento ou diminuição da RPM, o que é inconsistente.

Os parâmetros a e b do modelo de Maurer foram determinados para cada uma das 12 litologias diferentes. Os valores obtidos são apresentados na Tabela 4.13. A determinação dos parâmetros foi feita no *software* Statistica © Versão 8.0, com a ferramenta *Nonlinear Estimation* que, com base em uma regressão não linear dos dados apresentados, determina os parâmetros de qualquer equação alimentada pelo usuário.

Tabela 4.13. Parâmetros do modelo de Maurer para as litologias testadas

Modelo de Maurer					
Litologia	a	erro padrao a	b	erro padrao b	R2
ALB	0,00171	0,000349	4,030433	0,140937	0,8563
AND	0,00056	0,000031	-0,795975	0,024741	0,7956
ARN_MAC	0,01342	0,000359	-4,44845	0,081667	0,7145
CLU	0,00018	0	-3,40427	0,070663	0,8336
COQ	0,00005	0	-4,89968	0,03548	0,9489
CRE	0,00001	0	-3,87544	0,06874	0,4708
CRN	0,00483	0,000727	-2,07358	0,208285	0,9593
FLH	0,00015	0,000013	-5,36549	0,367898	0,6478
HAL	0,00031	0	-1,27757	0,015886	0,8912
MRG	0,0001	0	-3,41554	0,068149	0,8748
SLT	0,00624	0,000263	-1,14856	0,020933	0,4783
TQD	0,00012	0	-4,92506	0,014396	0,6762

4.5.2.1. Validação do modelo de Maurer com dados do poço A

A Figura 4.23 mostra o gráfico de ROP prevista *versus* ROP real para o poço A. Note que a previsão não é satisfatória. Foi obtido um baixíssimo coeficiente de correlação (0,0743) e os pontos estão bem distantes da bissetriz. Além disso, obteve-se um coeficiente angular afastado da unidade (0,7517) e um coeficiente linear bastante elevado (16,292). O erro quadrático médio foi de 0,2735 m/h.

Note que, para uma faixa de ROP, duas taxas diferentes são obtidas para uma única taxa real. Por exemplo, para uma taxa de penetração real de 9,43 m/h, o modelo de Maurer previu, em um determinado momento, uma taxa de 22,25 m/h e, em outro momento, outra taxa de 43,1 m/h. Isto ocorre porque o modelo não é capaz de prever a influência de outras variáveis (tais como vazão, profundidade do poço, *overbalance*, etc) no comportamento da taxa. Durante a perfuração do poço A, em um determinado momento, as condições operacionais levaram a uma taxa de 9,43 m/h. Em outro momento, peso sobre broca, rotação e litologia mudaram, mas a conjunção com as demais condições operacionais levaram a uma taxa muito próxima. Como o modelo de Maurer leva em conta apenas a rotação e o peso sobre broca (desprezando os demais parâmetros que a rede utiliza como entrada), mudanças nestes valores fatalmente vão levar a diferenças na taxa de penetração, o que pode não ser real. É o que se observa na Figura 4.23.

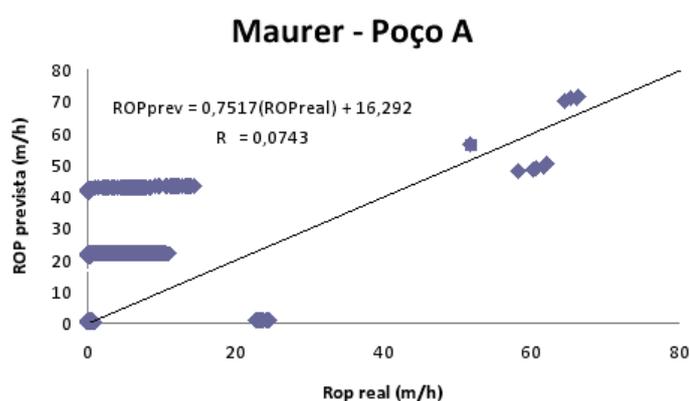


Figura 4.23. ROP prevista *versus* ROP real para o poço A – Modelo de Maurer

A Figura 4.24 mostra o histograma de frequência de erros absolutos na previsão das taxas do poço A com o modelo de Maurer. Note que a distribuição de frequências não segue uma distribuição normal e as maiores frequências estão afastadas do zero, o que mostra uma má previsão pelo modelo de Maurer.

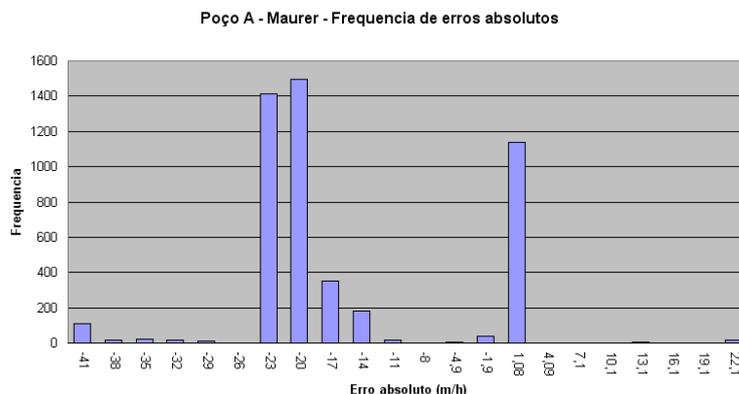


Figura 4.24. Histograma de frequência de erros absolutos para o poço A – Modelo de Maurer

4.5.2.2. Validação do modelo de Maurer com dados do poço B

A Figura 4.25 mostra o gráfico de ROP prevista *versus* ROP real para o poço B e o modelo de Maurer. Assim como no poço A, o modelo de Maurer também não conseguiu prever adequadamente as taxas de penetração do poço B. O coeficiente de correlação foi muito baixo (0,2791) e o erro quadrático médio foi de 0,167 m/h. O coeficiente angular é distante da unidade (0,6412) e o coeficiente linear também é bem distante de zero (4,9315). Estes valores, somados à análise do gráfico que mostra os pontos bem distantes da bissetriz, confirmam a má capacidade do modelo de Maurer em prever bem o comportamento observado no poço B.

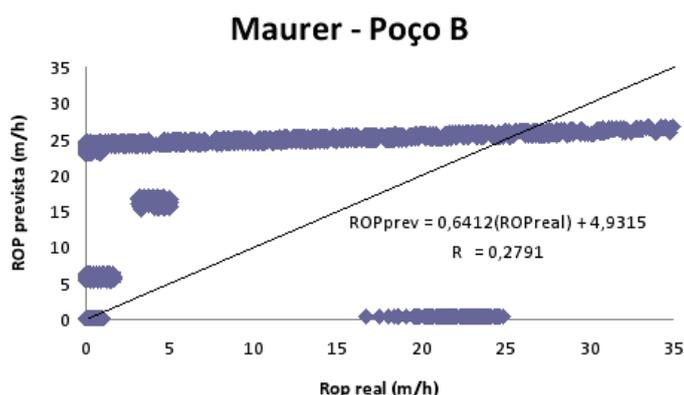


Figura 4.25. ROP prevista *versus* ROP real para o poço B – Modelo de Maurer

A Figura 4.26 mostra o diagrama de frequência de erros absolutos para o poço B e as previsões do modelo de Maurer. Apesar de a frequência maior ocorrer para valores de erros absolutos próximos a zero e de a distribuição seguir uma distribuição normal, há ainda uma frequência elevada de erros com valores altos, o que já se observava na Figura 4.25.

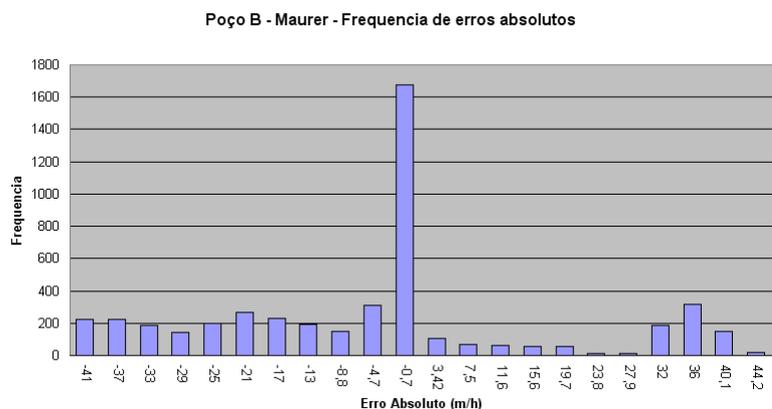


Figura 4.26. Histograma de frequência de erros absolutos para o poço B – Modelo de Maurer

4.5.2.3. Validação do modelo de Maurer com dados do poço C

A Figura 4.27 mostra o gráfico de ROP prevista *versus* ROP real para o poço C e o modelo de Maurer. Mais uma vez, a análise da figura deixa muito clara a falta de capacidade do modelo de Maurer em prever o comportamento das taxas de penetração reais de um poço de petróleo. Mais uma vez, também, observa-se que o modelo previu diferentes taxas para uma mesma taxa real. Este comportamento já havia sido observado no poço A e se dá porque o modelo deixa de levar em conta uma série de parâmetros que influenciam a taxa de penetração e que, em conjunção com RPM e WOB, levariam a taxa para valores diferentes.

Como se vê na figura, os pontos estão bem distantes da bissetriz evidenciando a má previsão do modelo. Além disso, o coeficiente de correlação obtido é muito baixo (0,0462), o coeficiente angular está bem distante da unidade (0,2577) e o coeficiente linear está bem distante de zero (15,396). O erro quadrático médio da previsão foi de 0,3154 m/h.

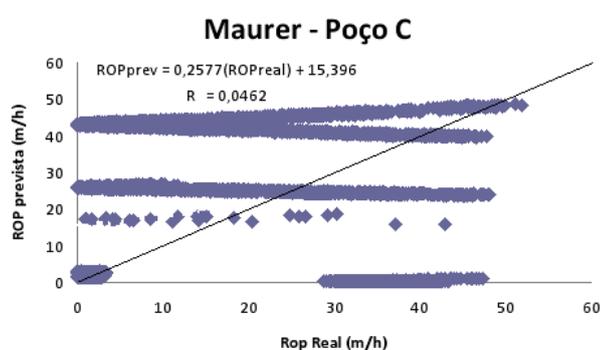


Figura 4.27. ROP prevista *versus* ROP real para o poço C – Modelo de Maurer

A Figura 4.28 mostra o diagrama de frequência dos erros absolutos na previsão das taxas do poço C pelo modelo de Maurer. As maiores frequências ocorrem para valores entre 0 e -5,7 m/h, o que é uma faixa bem abrangente. Observa-se ainda uma frequência elevada de erros em -23 m/h. Os erros absolutos confirmam a má previsão do modelo para as taxas do poço C.

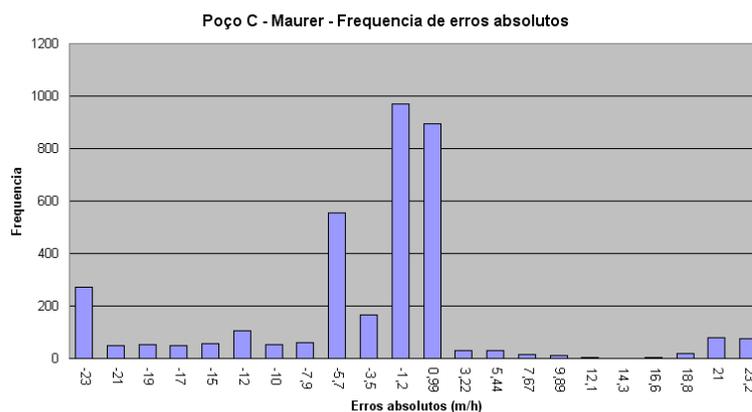


Figura 4.28. Histograma de frequência de erros absolutos para o poço C – Modelo de Maurer

4.5.2.4. Validação do modelo de Maurer com dados do poço D

A Figura 4.29 mostra o gráfico de ROP prevista pelo modelo de Maurer *versus* ROP real para o poço D. Como nos demais poços, o modelo de Maurer não foi capaz de prever bem as taxas de penetração reais do poço. A Figura 4.29 mostra os pontos bem distantes da bissetriz. Nota-se que, a exemplo do que aconteceu nos poços A e C, o modelo previu diferentes taxas para uma mesma taxa real. Isto ocorre, como já explicado, porque o modelo deixa de levar em conta uma série de parâmetros que influenciam a taxa de penetração.

O baixo coeficiente de correlação (0,1142), o coeficiente angular distante da unidade (-0,8188) e o coeficiente linear também distante de zero (12,612) confirmam os maus resultados obtidos com o modelo. O erro quadrático médio da previsão foi de 0,2474 m/h.

A Figura 4.30 mostra o diagrama de frequência dos erros absolutos na previsão das taxas do poço D pelo modelo de Maurer. Nota-se que os erros observados são elevados e a maior frequência se concentra nos erros positivos variando de 0,32 a 16,8 m/h, valores muito elevados e considerados inaceitáveis.

A Tabela 4.14 mostra os parâmetros de análise do desempenho do modelo de Maurer com os dados dos poços de validação. Note que, para todos os casos analisados, o desempenho do modelo para a previsão das taxas de penetração de poços de petróleo foi

muito fraco. Isso mostra claramente que o modelo de Maurer não é adequado para a previsão de taxas de penetração de poços de petróleo.

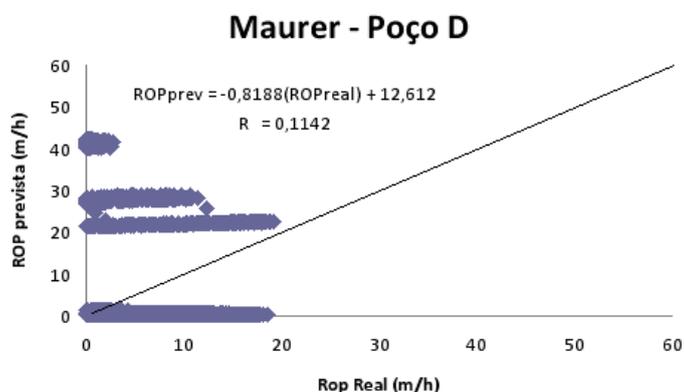


Figura 4.29. ROP prevista *versus* ROP real para o poço D – Modelo de Maurer

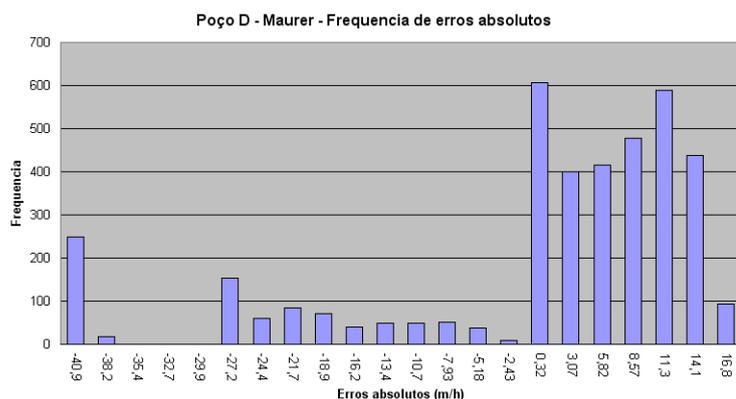


Figura 4.30. Histograma de frequência de erros absolutos para o poço D – Modelo de Maurer

Tabela 4.14. Parâmetros de análise do desempenho do modelo de Maurer com dados dos poços de validação

MAURER				
Poço	R	Erro Quadrático Médio	Coefficiente Angular	Coefficiente Linear
A	0,0743	0,2735	0,7517	16,2920
B	0,2791	0,1670	0,6412	4,9315
C	0,0462	0,3154	0,2577	15,3960
D	0,1142	0,2474	0,8188	12,6120

4.5.3 Comparação com modelo de Young

O modelo de Young (Equação 2.2) é similar ao modelo de Maurer, mas consegue descrever o comportamento não linear da taxa de penetração com a rotação da broca, graças à

inserção de um expoente neste parâmetro. Isto lhe confere uma grande vantagem sobre o modelo de Maurer. Este modelo também é largamente utilizado na indústria de petróleo, provavelmente por sua simplicidade. Mas assim como Maurer, o modelo de Young trata um fenômeno de alta complexidade de forma extremamente simples, deixando de levar em conta diversos parâmetros que evidentemente influenciam fortemente a taxa de penetração. Isto gera resultados distantes dos observados na prática e com baixa confiabilidade.

Os parâmetros k , c e d do modelo de Young foram determinados para cada uma das doze litologias diferentes. Os valores obtidos são apresentados na Tabela 4.15. A determinação dos parâmetros foi feita no *software* Statistica © Versão 8.0, com a ferramenta *Nonlinear Estimation* que, com base em uma regressão não linear dos dados apresentados, determina os parâmetros de qualquer equação alimentada pelo usuário.

Tabela 4.15. Parâmetros de do modelo de Young para as litologias testadas

Modelo de Young							
Litologia	k	erro padrao k	c	erro padrao c	d	erro padrao d	R2
ALB	0,008754	0,000864	0,27852	0,003654	0,221482	0,002682	0,8413
AND	0,069911	0,001296	0,353381	0,001769	0,303321	0,003798	0,9994
ARN_MAC	0,04628	0,001785	0,42589	0,004001	0,387412	0,003129	0,64587
CLU	0,02193	0,000228	0,415711	0,001449	0,69778	0,001947	0,9965
COQ	0,028249	0,001613	0,452106	0,001475	0,380285	0,012349	0,9856
CRE	0,025892	0,001239	0,424204	0,005215	0,583887	0,010381	0,9784
CRN	0,01697	0,003332	0,74302	0,008165	0,34872	0,023961	0,6192
FLH	5,075582	0,079395	0,342638	0,001712	0,340386	0,003092	0,9578
HAL	0,091069	0,002211	0,474889	0,002415	0,201091	0,004917	0,9892
MRG	0,001238	0,000091	0,374248	0,004974	1,130771	0,015411	0,9752
SLT	0,357431	0,029788	0,248357	0,005733	0,264238	0,016727	0,9522
TQD	0,045743	0,008306	0,35826	0,016506	0,376555	0,040688	0,9815

4.5.3.1. Validação do modelo de Young com dados do poço A

A Figura 4.31 mostra o gráfico de ROP prevista *versus* ROP real para o poço A. As previsões das taxas com o modelo de Young também não foram satisfatórias. O coeficiente de correlação obtido é extremamente baixo (0,1061), bem como o coeficiente angular (0,1038, valor muito distante da unidade). O coeficiente linear está bem próximo de zero, porém, isso só significaria uma boa previsão caso o coeficiente linear estivesse próximo da unidade, o que não é o caso. O erro quadrático médio na previsão da taxa de penetração foi de 0,5555 m/h.

A Figura 4.32 mostra o diagrama de frequência de erros absolutos na previsão das taxas do poço A pelo modelo de Young. A maior frequência de erros ocorre para um valor baixo (apenas 1,16 m/h), mas, mesmo com uma frequência inferior, há ainda um número grande de erros com valores superiores, como 7,20 m/h.

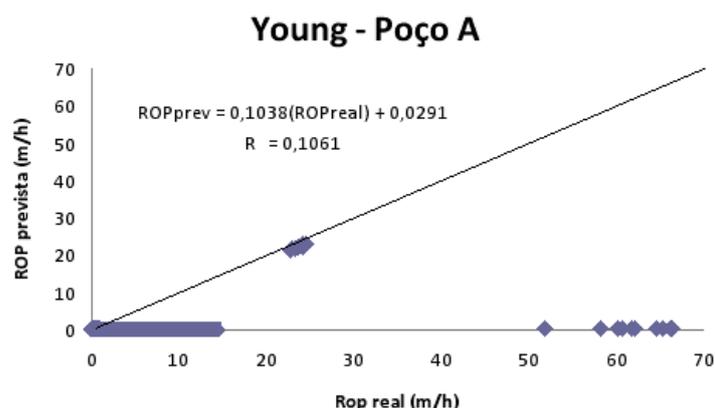


Figura 4.31. ROP prevista *versus* ROP real para o poço A – Modelo de Young

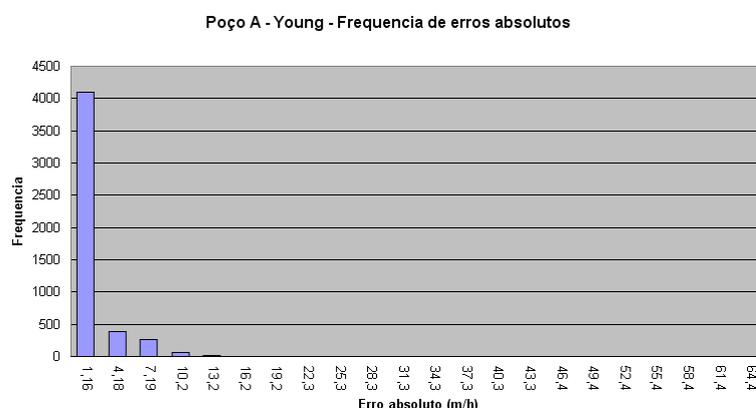


Figura 4.32. Histograma de frequência de erros absolutos para o poço A – Modelo de Young

4.5.3.2. Validação do modelo de Young com dados do poço B

A Figura 4.33 mostra o gráfico de ROP prevista *versus* ROP real para o poço B. A figura mostra claramente uma péssima previsão das taxas de penetração pelo modelo de Young. Os pontos estão bem distantes da bissetriz e o coeficiente de correlação apresenta um valor extremamente baixo (0,1872). O erro quadrático médio foi de 0,1435 m/h. O coeficiente angular foi de 0,1522 (bem longe da unidade) e o linear foi de 0,4018 (também bem longe de zero).

A Figura 4.34 mostra o diagrama de frequência dos erros absolutos na previsão das taxas do poço B pelo modelo de Young. Novamente, a maior frequência se dá para valores muito baixos de erros absolutos. Mas, como nos casos anteriores, há ainda uma frequência muito elevada de erros maiores, o que evidencia a má capacidade do modelo de Young para prever as taxas de penetração reais do poço B.

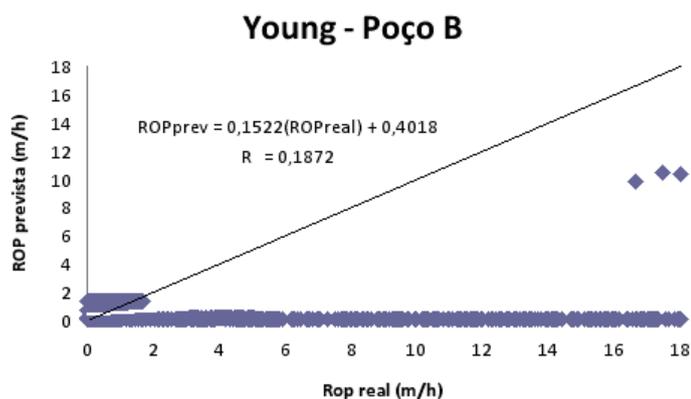


Figura 4.33. ROP prevista *versus* ROP real para o poço B – Modelo de Young

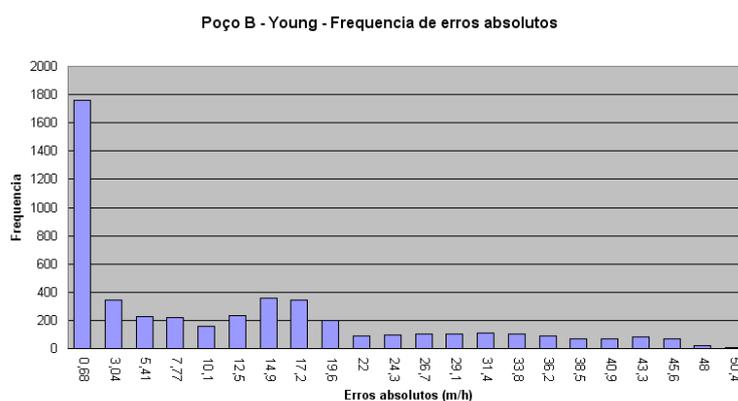


Figura 4.34. Histograma de frequência de erros absolutos para o poço B – Modelo de Young

4.5.3.3. Validação do modelo de Young com dados do poço C

A Figura 4.35 mostra o gráfico de ROP prevista *versus* ROP real para o poço C e o modelo de Young. Os resultados obtidos aqui foram muito semelhantes aos obtidos nos casos anteriores. Mais uma vez percebe-se claramente que o modelo não foi capaz de prever as taxas de penetração reais do poço. Os pontos estão longe da bissetriz e o coeficiente de correlação é extremamente baixo (0,3026). Os valores dos coeficientes angulares e lineares também evidenciam o mau desempenho do modelo. O erro quadrático médio na previsão foi de 0,2534 m/h.

A Figura 4.36 mostra o diagrama de frequência de erros absolutos na previsão das taxas do poço C com o modelo de Young. A maior frequência ocorre para valores bastante baixos, mas ainda assim, a quantidade de erros com valores elevados é considerável.

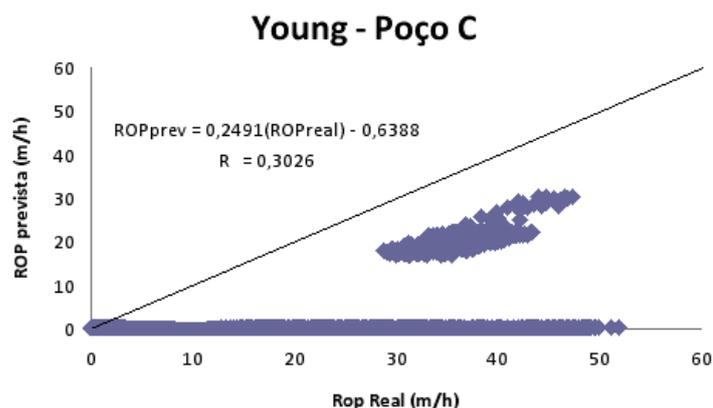


Figura 4.35. ROP prevista *versus* ROP real para o poço C – Modelo de Young

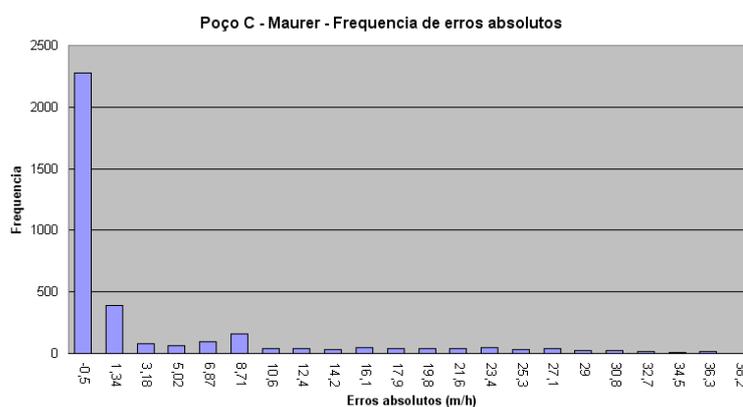


Figura 4.36. Histograma de frequência de erros absolutos para o poço C – Modelo de Young

4.5.3.4. Validação do modelo de Young com dados do poço D

A Figura 4.37 mostra o gráfico de ROP prevista pelo modelo de Young *versus* ROP real para o poço D. Os resultados para este poço não são diferentes dos resultados dos outros três poços, ou seja, evidenciam a falta de capacidade do modelo de Young para previsão das taxas de penetração reais. Os pontos estão longe da bissetriz e o coeficiente de correlação é extremamente baixo (0,2290). Os valores dos coeficientes angulares e lineares também evidenciam o mau desempenho do modelo. O erro quadrático médio na previsão foi de 0,0787 m/h.

A Figura 4.38 mostra o diagrama de frequência de erros absolutos na previsão das taxas de penetração do poço D com o modelo de Young. Apesar de a maior frequência ocorrer para valores próximos da zero, há ainda frequências muito elevadas para erros também elevados, tanto positivos quanto negativos. Este resultado confirma o mau desempenho do modelo de Young em prever as taxas de penetração do poço D também.

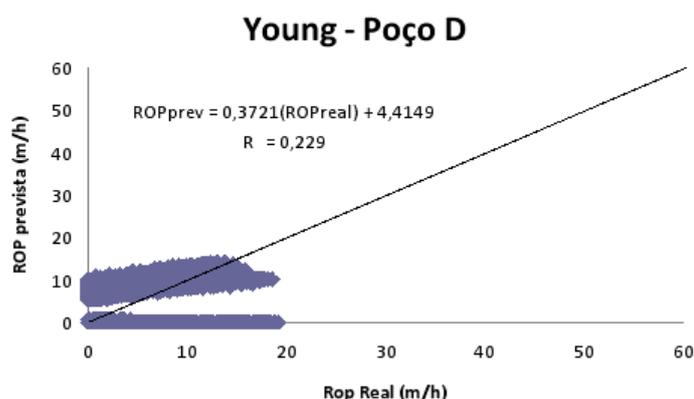


Figura 4.37. ROP prevista versus ROP real para o poço D – Modelo de Young

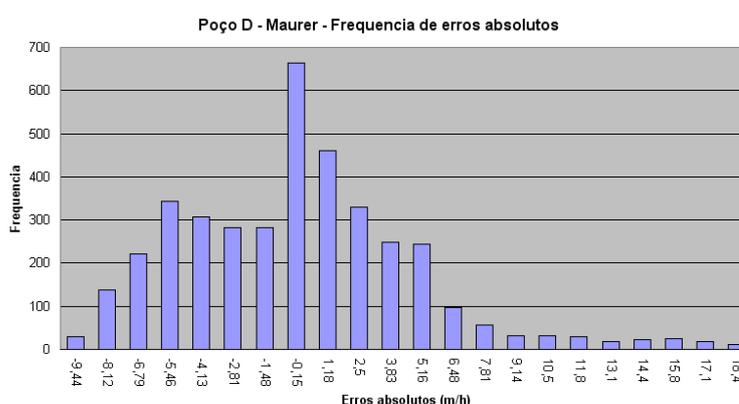


Figura 4.38. Histograma de frequência de erros absolutos para o poço D – Modelo de Young

A Tabela 4.16 mostra os parâmetros de análise do desempenho do modelo de Young na previsão das taxas de penetração dos poços de validação. Assim como ocorreu no modelo de Maurer, os parâmetros da tabela revelam a falta de capacidade do modelo em prever o comportamento de poços de petróleo reais. Isto confirma a constatação prática de que ambos os modelos (Maurer e Young) não são adequados para previsão de taxas de penetração.

Tabela 4.16. Parâmetros de análise do desempenho do modelo de Young com dados dos poços de validação

YOUNG				
Poço	R	Erro Quadrático Médio	Coefficiente Angular	Coefficiente Linear
Á	0,1061	0,5555	0,1038	0,0291
B	0,1872	0,1435	0,1522	0,4018
C	0,3026	0,2534	0,2491	0,6388
D	0,2290	0,0787	0,3721	4,4149

A comparação dos dados das Tabelas 4.11 (rede direta única), 4.12 (redes diretas separadas por litologia) e 4.16 (modelo de Maurer) e 4.18 (modelo de Young) mostram que de

todas as opções testadas para a previsão da taxa de penetração, aquele que gera os melhores resultados é o modelo empregando redes diretas separadas por litologia. Esta opção apresentou resultados extremamente superiores a todas as outras testadas. Por este motivo, a etapa de otimização dos parâmetros, apresentada a seguir, será realizada apenas com as redes diretas separadas por litologia.

4.6 Otimização dos parâmetros operacionais

Neste trabalho, foram testados e comparados 3 métodos para otimização do par rotação e peso sobre broca:

- 1) Utilização das redes inversas para determinação do par rotação da broca e peso sobre broca, a partir de uma entrada de taxa de penetração de *setpoint*.
- 2) Utilização de Algoritmo PSO (*Particle Swarm Optimization*) para determinação do par rotação e peso sobre broca, a partir de uma especificação de taxa de penetração de *setpoint*.
- 3) Utilização de um método de varredura exaustiva.

A seguir, são mostrados os resultados obtidos com os três métodos de otimização mencionados acima.

4.6.1 Otimização através da rede inversa

Apesar de os resultados gerados pela rede inversa deixarem clara a incapacidade de previsão de valores de RPM e WOB para uma determinada taxa de penetração, a otimização do par de WOB e RPM foi feita também com este tipo de arquitetura para efeito de comparação com os outros dois métodos. Os resultados são mostrados no Apêndice C.

Para esta análise, por simplicidade, escolheu-se usar o modelo da rede inversa única. Uma vez que a rede inversa única e as redes inversas separadas por litologia apresentaram desempenhos muito semelhantes, entende-se que não há nenhuma perda em se escolher o modelo inverso único em detrimento dos separados por litologia para esta análise.

Os dados dos poços A, B, C e D colhidos em tempo real foram alimentados na rede inversa e um gráfico de WOB e RPM ao longo do tempo foi gerado para um *setpoint* de ROP de 45 m/h. Cada linha do arquivo com os dados reais (semelhante ao arquivo mostrado na

Figura 3.2) contém os dados colhidos em um determinado instante de tempo. Para cada linha do arquivo, foram gerados valores de RPM e WOB.

4.6.2 Otimização através do algoritmo PSO

O PSO (*Particle Swarm Optimization*) é um algoritmo de otimização que determina os parâmetros de uma equação para minimizar uma função objetivo. No caso do presente trabalho, a função objetivo é o valor absoluto da diferença entre a ROP de *setpoint* e a ROP prevista pela rede neuronal e o valor mínimo desejado para esta função é zero. O algoritmo buscará os valores de RPM e WOB que, junto aos demais parâmetros operacionais, minimizarão a função objetivo, ou seja, levarão a uma ROP o mais próxima possível do *setpoint* desejado.

O processo será repetido para cada instante de tempo, com as condições daquele momento. Os dados dos poços A, B, C e D foram usados para ilustrar o funcionamento do método e comparar com os demais métodos testados no trabalho. Considerando uma ROP de *setpoint* de 45 m/h, os valores de RPM e WOB foram otimizados para cada instante de tempo. Cada linha do arquivo de dados dos poços (semelhante ao mostrado na Figura 3.2) se refere a um instante de tempo. As condições operacionais para aquele instante de tempo (vazão, *overbalance*, profundidade, etc), exceto a rotação e o peso sobre broca, são entradas para o método, que variará RPM e WOB de forma a obter a ROP mais próxima possível do *setpoint*. O processo é repetido para cada instante de tempo, de forma a se obter curvas de RPM e WOB ótimas ao longo do tempo. O modelo escolhido para a determinação da taxa de penetração dentro do algoritmo PSO foi o das redes diretas separadas por litologia, pois foi o que apresentou os melhores resultados.

Entretanto, o método PSO pode determinar valores de WOB e RPM, muitas vezes acima dos limites operacionais. Para evitar esse tipo de resposta, incluiu-se, no código do algoritmo, uma condição que força um valor extremamente elevado para a função objetivo quando RPM ou WOB assumem valores fora dos limites operacionais. Quando isso acontece, o algoritmo é obrigado a buscar novos valores de RPM e WOB que atendam os limites operacionais dos equipamentos. Tipicamente, o valor máximo de rotação da broca é de 400 rev/min e de peso sobre broca é de 90 toneladas.

O tamanho do enxame usado aqui foi mantido fixo em 49 partículas. A posição inicial das partículas, bem como as velocidades iniciais de cada uma delas foram determinadas de forma aleatória. A partir da primeira iteração, as velocidades e direções de cada uma delas

passaram a ser determinadas de acordo com as informações que cada uma obteve de suas próprias explorações e das explorações de suas informantes.

4.6.2.1. Otimização dos dados do poço A através do algoritmo

PSO

A Figura 4.39 mostra os resultados obtidos para o poço A. Note que há uma enorme variação nos valores WOB e RPM determinados pelo método PSO. Isso ocorre porque, como mostrado anteriormente, existe uma grande multiplicidade de pares de peso e rotação que geram uma mesma resposta na taxa de penetração. O método PSO é capaz de determinar apenas um único par de peso e rotação e a determinação deste par depende das condições aleatórias em que a busca pelos valores se iniciou. Assim, o resultado obtido garante a taxa de penetração desejada, mas a enorme variação instantânea dos valores de RPM e WOB dificulta a aplicação dos resultados na prática.

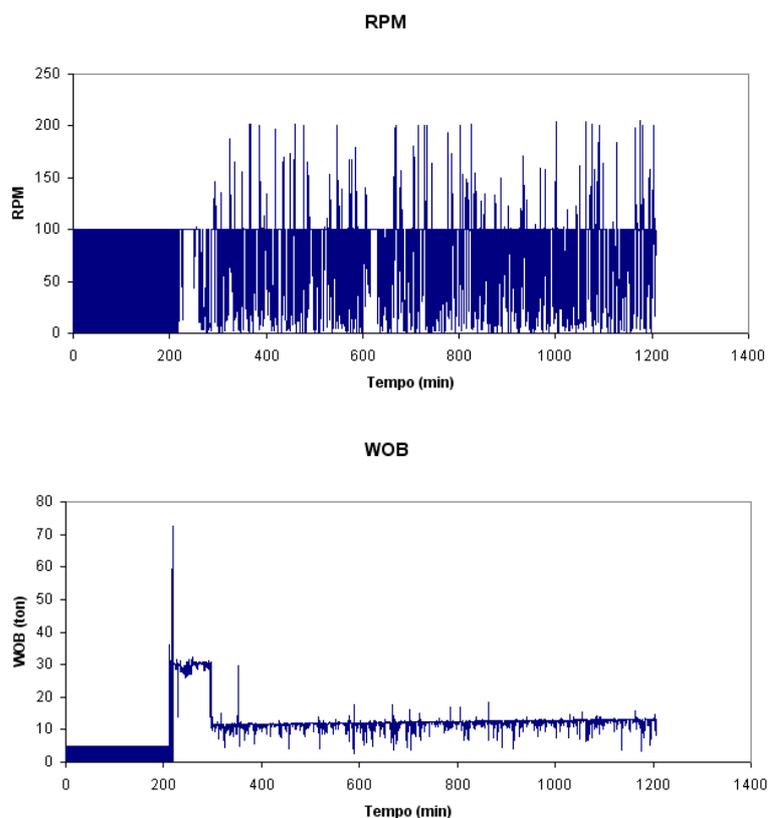


Figura 4.39. RPM e WOB ao longo do tempo gerados pelo método PSO para manter a taxa de penetração em 45 m/h – Poço A

A Figura 4.40 mostra o gráfico de energia mecânica específica na broca, calculada a partir das condições operacionais e dos valores de RPM e WOB determinados pelo PSO, ao longo do tempo. Note que a grande variação nos parâmetros operacionais causa também uma enorme variação instantânea na Energia Específica.

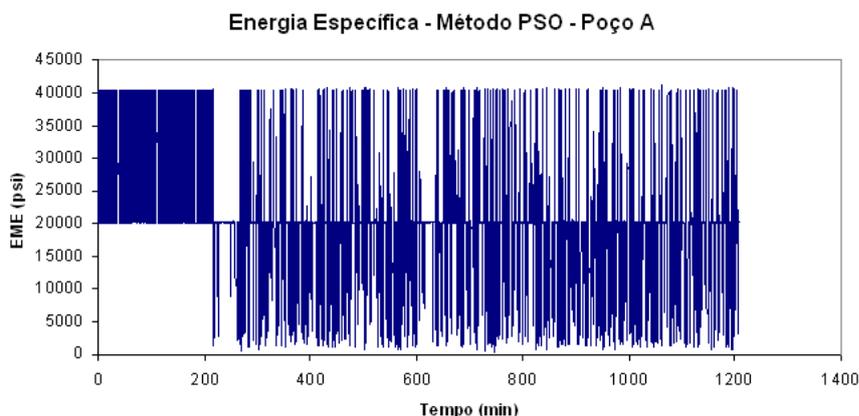


Figura 4.40. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela algoritmo PSO – Poço A

4.6.2.2. Otimização dos dados do poço B através do algoritmo PSO

O mesmo procedimento acima foi feito para o poço B. As Figuras 4.41 e 4.42 mostram os mesmos resultados obtidos. O mesmo comportamento observado para o poço A se repete no poço B, embora o algoritmo tenha convergido para valores menos aleatórios nas condições deste poço. O algoritmo obtém pares aleatórios de RPM e WOB, o que gera enormes variações instantâneas, tanto nos valores dos parâmetros obtidos quanto nos valores da energia mecânica específica.

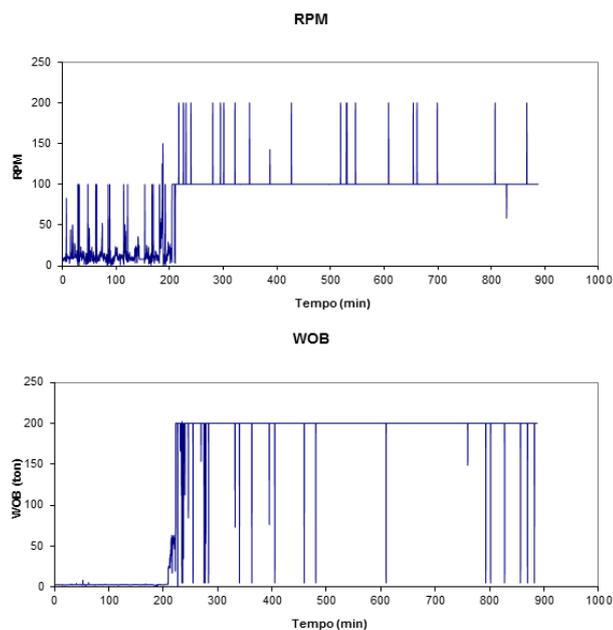


Figura 4.41. RPM e WOB ao longo do tempo gerados pelo método PSO para manter a taxa de penetração em 45 m/h – Poço B

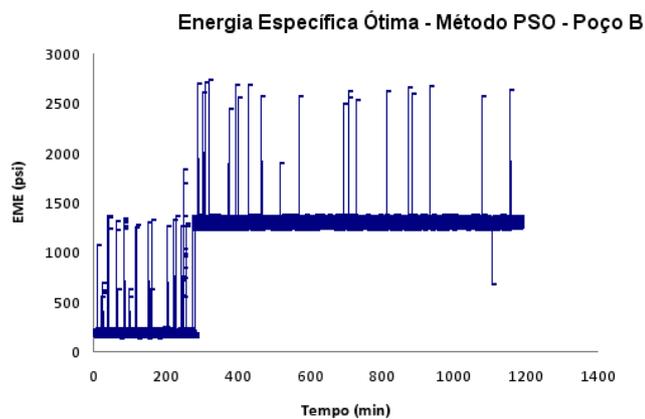


Figura 4.42. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela algoritmo PSO – Poço B

4.6.2.3. Otimização dos dados do poço C através do algoritmo PSO

O mesmo procedimento acima foi feito para o poço C. As Figuras 4.43 e 4.44 mostram os resultados obtidos. Assim como nos outros poços, a Figura 4.43 mostra os valores de RPM e WOB necessários, ao longo do tempo, para manter a ROP no *setpoint* desejado. A Figura 4.44 mostra o gráfico de energia mecânica específica na broca para os valores calculados pelo método.

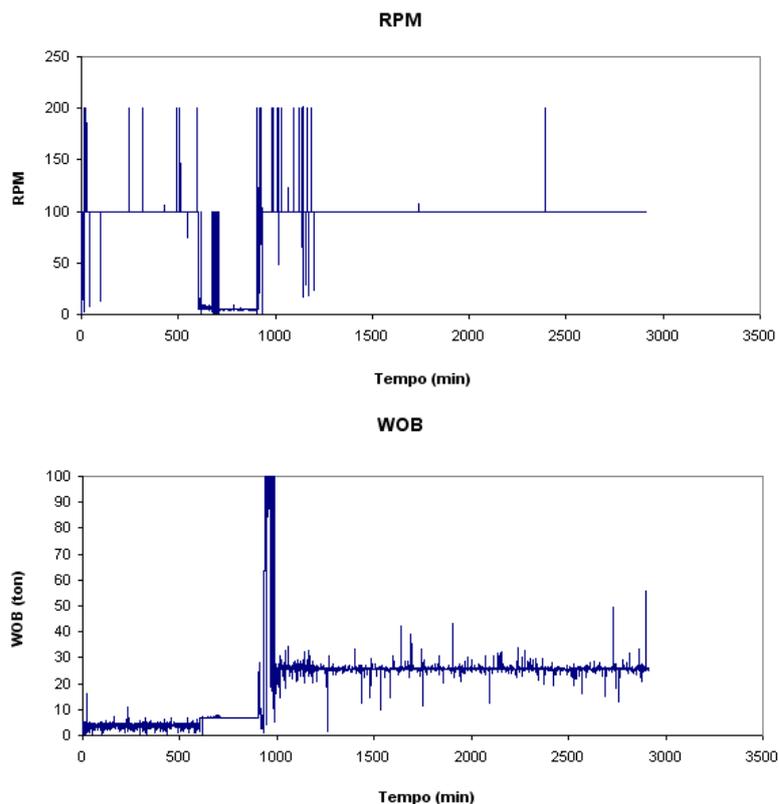


Figura 4.43. RPM e WOB ao longo do tempo gerados pelo método PSO para manter a taxa de penetração em 45 m/h – Poço C

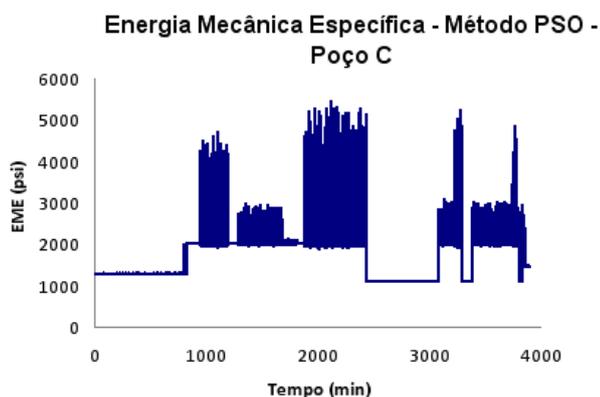


Figura 4.44. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela algoritmo PSO – Poço C

4.6.2.4. Otimização dos dados do poço D através do algoritmo PSO

Por fim, a otimização através do algoritmo PSO foi testada com os dados do poço D. A Figura 4.45 mostra os gráficos dos valores de RPM e WOB determinados pelo algoritmo ao

longo do tempo a fim de manter a taxa de penetração do *setpoint* de 45 m/h. Note que os valores determinados pelo algoritmo apresentam um comportamento errático.

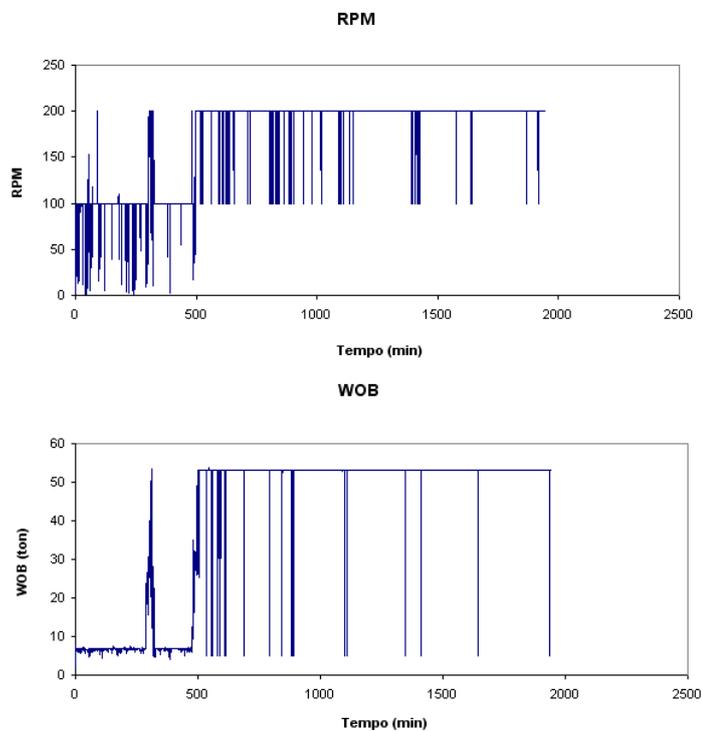


Figura 4.45. RPM e WOB ao longo do tempo gerados pelo método PSO para manter a taxa de penetração em 45 m/h – Poço D

A Figura 4.46 mostra o gráfico de energia mecânica específica na broca calculada com base nos parâmetros (RPM e WOB) determinados pelo algoritmo PSO. A energia mecânica específica segue o comportamento de RPM e WOB e também apresenta muitas variações.

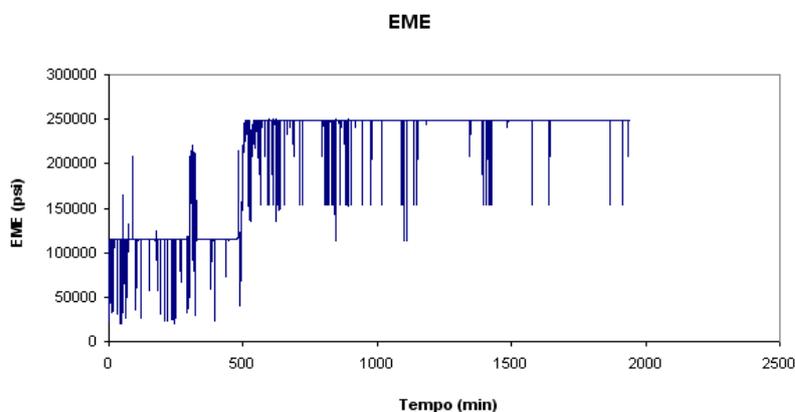


Figura 4.46. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pelo algoritmo PSO – Poço D

Note que, os valores de RPM e WOB determinados neste item (mostrados nas Figuras 4.39, 4.41, 4.43 e 4.45) são ótimos no sentido de que eles são capazes de gerar a ROP desejada. Mas não são ótimos no sentido de que esses são os valores que minimizam a energia mecânica específica na broca.

Os métodos de otimização através do algoritmo PSO e das redes inversas não são capazes de garantir que o par achado é aquele que gere a menor energia mecânica específica. O problema de otimização dos parâmetros operacionais exige a minimização simultânea de duas funções: a função erro (Equação 3.3) e função da energia mecânica específica na broca (Equação 3.1). A dificuldade neste tipo de otimização é que, se por um lado o valor alvo da função objetivo é conhecido (valor nulo), por outro lado, não se conhece o valor alvo da Energia Mecânica Específica. Ou seja, sabe-se que o valor da energia mecânica específica deve ser minimizado, mas não se sabe sequer a ordem de grandeza do valor mínimo procurado.

A princípio, é possível incluir a minimização de uma segunda função no algoritmo PSO. Ou seja, com o PSO é possível minimizar simultaneamente tanto a diferença entre ROP de *setpoint* e prevista pela rede quanto a função da energia específica. Mas o desconhecimento do valor mínimo da EME (alvo) dificulta este procedimento.

Desta forma, na maneira como foi empregado neste trabalho, o algoritmo PSO garante a determinação de valores de WOB e RPM que gerem a taxa de penetração desejada, mas não se tem garantia nenhuma de que o par encontrado seja o ótimo, ou seja, aquele que gera a menor EME possível para aquelas condições. O mesmo problema ocorre com a determinação de RPM e WOB através das redes inversas.

4.6.3 Otimização através de varredura exaustiva

O método de varredura exaustiva de todos os pares possíveis de rotação da broca e peso sobre broca tinha como objetivo, a princípio, estudar o comportamento do sistema e determinar se a rede era capaz de reproduzir a multiplicidade de entradas (múltiplos pares de ROP e WOB) para uma única saída de ROP.

Os resultados mostram que, de fato, a rede teve sucesso em reproduzir este comportamento. Usando as redes diretas separadas por litologia, por exemplo, foram encontrados cento e oitenta e nove pares de RPM e WOB para um *setpoint* de taxa de

penetração de 25,3 m/h, sendo a vazão 800 gal/min, o *overbalance* (em termos de densidade equivalente) igual a 0,36 lb/gal, o diâmetro do poço igual a 8,5 pol e a litologia arenito.

Este resultado deixou evidente a deficiência dos métodos anteriores em determinar o ponto ótimo, uma vez que ambos são capazes de determinar apenas um único par.

Fica também clara a necessidade de a adoção de um critério para escolha, dentre as cento e oitenta e nove opções encontradas para este caso, do par ótimo a ser usado na perfuração real. Conforme citado na seção 3.4, o critério adotado neste trabalho é o da mínima energia mecânica específica na broca.

Assim, o passo seguinte ao da determinação dos pares que gerem a ROP desejada é o cálculo da energia específica de cada um deles e a seleção daquele que gere o menor valor deste parâmetro.

Os dados dos poços A, B, C e D foram usados para testar a aplicação deste método de otimização. Os dados recolhidos em tempo real foram alimentados no algoritmo desenvolvido e um gráfico de WOB e RPM ótimos ao longo do tempo foi gerado. Cada linha do arquivo com os dados reais (semelhante ao arquivo mostrado na Figura 3.2) contém os dados colhidos em um determinado instante de tempo. Valores ótimos de RPM e WOB foram gerados para cada linha do arquivo com base nos demais parâmetros operacionais daquele instante de tempo e do *setpoint* de ROP. À medida que o tempo passa, as condições do poço mudam (a profundidade aumenta, a vazão pode variar, a pressão do poço e a pressão de poros podem sofrer alterações, o torque pode mudar, etc), o que leva a mudanças nos valores ótimos de RPM e WOB. Além disso, o *setpoint* da ROP também pode ser mudado pelos usuários e o programa será obrigado a buscar outros patamares de RPM e WOB a partir do momento da mudança. Neste método, está-se na verdade minimizando a energia, ao mesmo tempo em que se atende ao critério de *setpoint*.

4.6.3.1. Otimização dos dados do poço A através de varredura exaustiva

A Figura 4.47 mostra os gráficos de RPM e WOB ótimos ao longo do tempo para o poço A e um *setpoint* de taxa de penetração de 45 m/h. Note que há variações dos parâmetros ótimos ao longo do tempo devido às mudanças nas condições de perfuração. A Figura 4.48 mostra o gráfico de energia específica para os parâmetros mostrados na Figura 4.47.

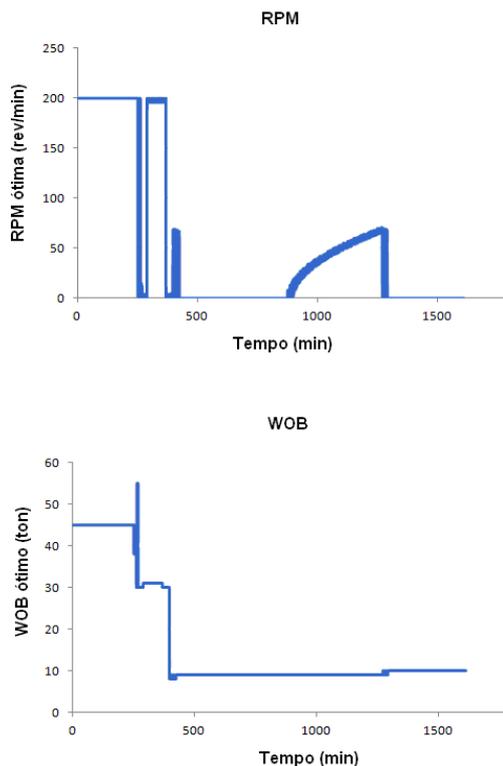


Figura 4.47. RPM e WOB ótimas de acordo com as condições operacionais do poço A

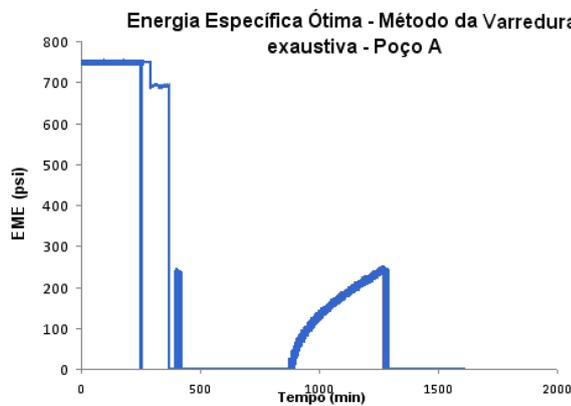


Figura 4.48. Energia mecânica específica mínima ao longo do tempo para uma taxa de 45 m/h do poço A

Diferente dos demais métodos (rede inversa e algoritmo PSO), o método da varredura exaustiva garante que a curva mostrada na Figura 4.48 é, de fato, a curva que contém os valores mínimos da energia mecânica específica.

4.6.3.2. Otimização dos dados do poço B através de varredura exaustiva

A Figura 4.49 mostra os gráficos de RPM e WOB ótimos ao longo do tempo para o poço B e um *setpoint* de taxa de penetração de 45 m/h. A Figura 4.50 mostra o gráfico de energia mecânica específica ao longo do tempo, calculada com base nos parâmetros operacionais calculados pelo método da varredura exaustiva e mostrados na Figura 4.49.

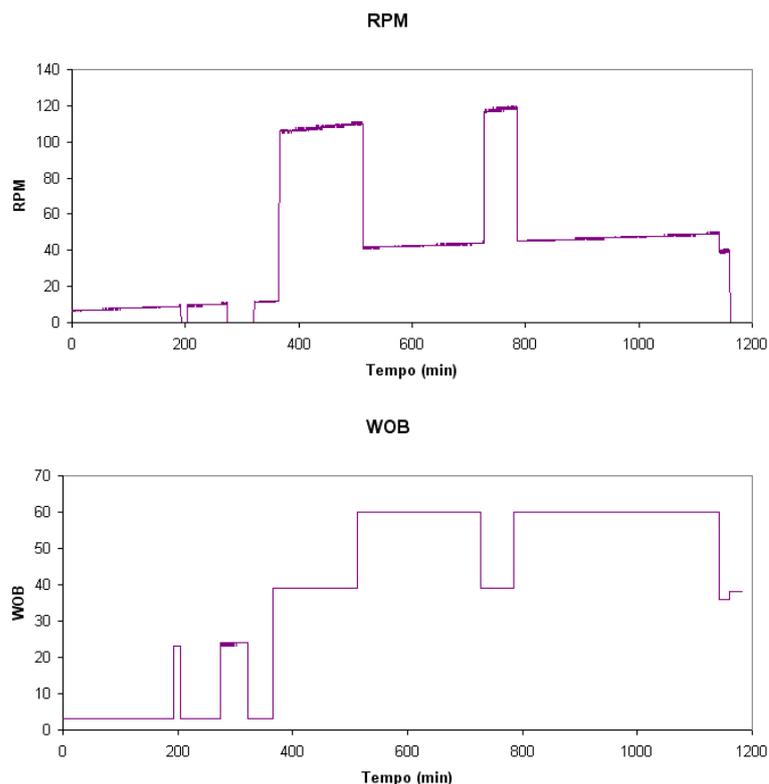


Figura 4.49. RPM e WOB ótimas de acordo com as condições operacionais do poço B

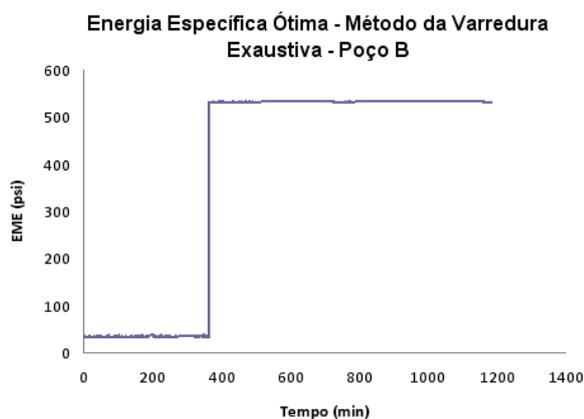


Figura 4.50. Energia mecânica específica mínima ao longo do tempo para uma taxa de 45 m/h do poço B

As variações mais bruscas estão associadas a mudanças de litologia. Quando há a transição de uma litologia mais dura para uma mais mole, o peso sobre broca ótimo tende a diminuir.

A título de exemplo, para ilustrar melhor o efeito da mudança de litologia nos parâmetros ótimos de perfuração, a Figura 4.51 mostra o mesmo gráfico da Figura 4.44 com as litologias encontradas em cada faixa de tempo. Note que, de fato, as mudanças mais bruscas nos valores ótimos determinados pela metodologia estão associadas a mudanças de litologia. Mudanças mais lentas (como o aumento paulatino da rotação da broca) estão associadas a mudanças nas condições operacionais, tais como o aumento da profundidade do poço.

Os resultados indicam que, para este poço, a melhor opção é manter um peso sobre broca constante e compensar a dificuldade crescente de perfuração aumentando-se a rotação.

Nota-se também que rochas mais duras (como a Coquina) exigem pesos sobre broca e rotações maiores do que rochas mais friáveis (como Arenito).

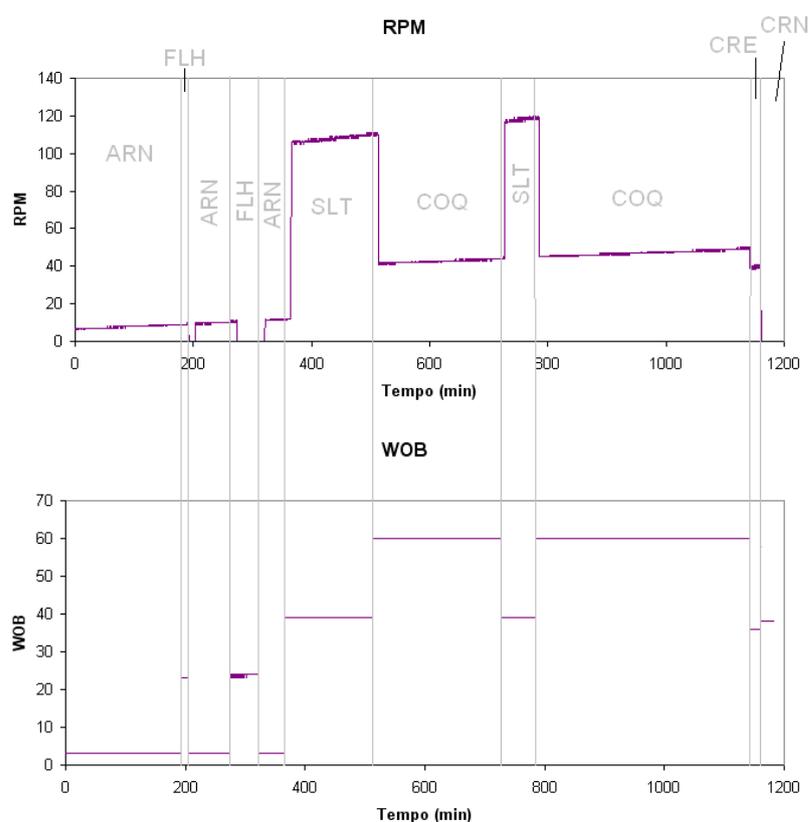


Figura 4.51. RPM e WOB ótimas de acordo com as condições operacionais do poço B – litologias marcadas (resultado obtido com redes diretas separadas por litologia)

Ainda a título de exemplo, a Figura 4.52 mostra os gráficos de rotação e peso sobre broca ótimos ao longo do tempo para o poço B e vários *setpoints* diferentes de taxa de penetração. De maneira geral, quanto maior a ROP desejada, maiores são os pesos sobre broca e rotações requeridos. Há, porém, situações em que é preferível reduzir o peso sobre broca e aumentar a rotação para se obter uma ROP maior.

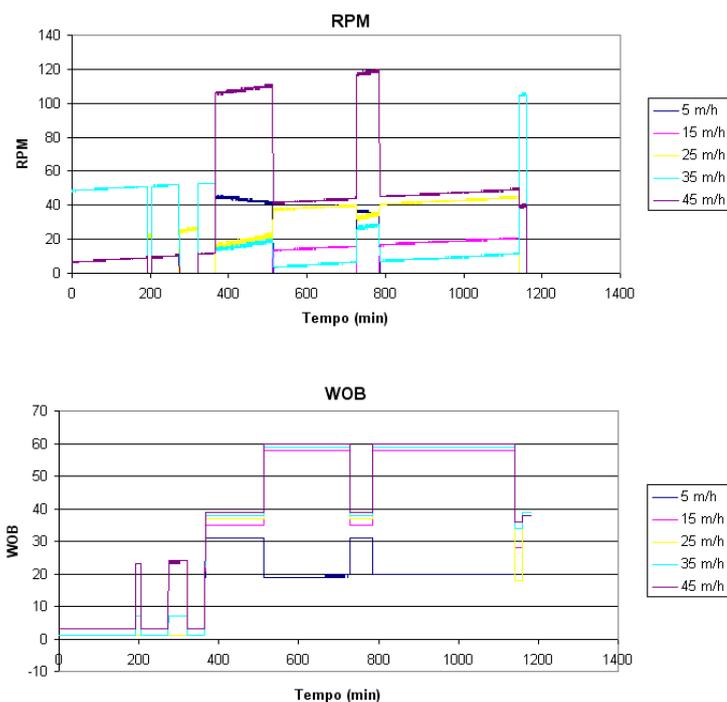


Figura 4.52. Rotação e peso sobre broca ótimos ao longo do tempo para o poço B e vários *setpoints* diferentes de taxa de penetração (resultado obtido com redes diretas separadas por litologia)

4.6.3.3. Otimização dos dados do poço C através de varredura exaustiva

A Figura 4.53 mostra os gráficos de RPM e WOB ótimos ao longo do tempo para o poço C e um *setpoint* de taxa de penetração de 45 m/h. A Figura 4.54 mostra o gráfico de energia específica mínima na broca ao longo do tempo para manter a taxa de penetração no *setpoint* desejado.

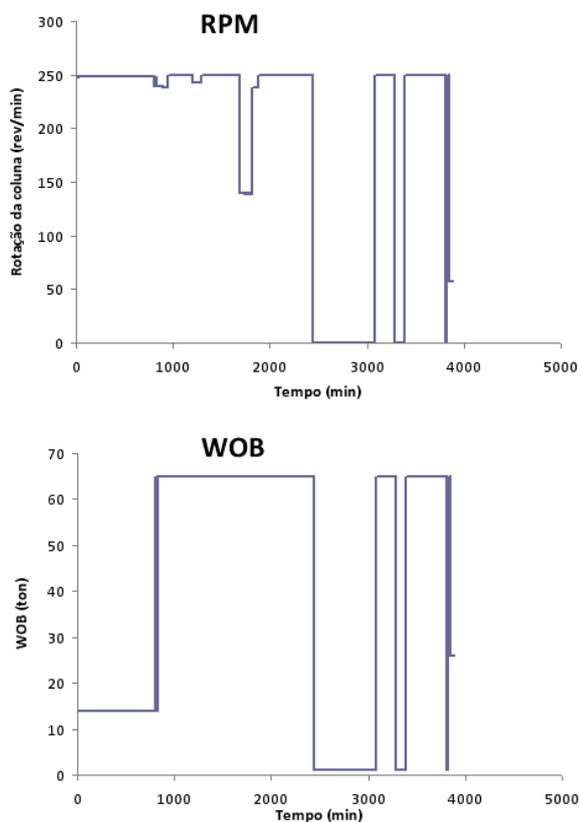


Figura 4.53. RPM e WOB ótimas de acordo com as condições operacionais do poço C

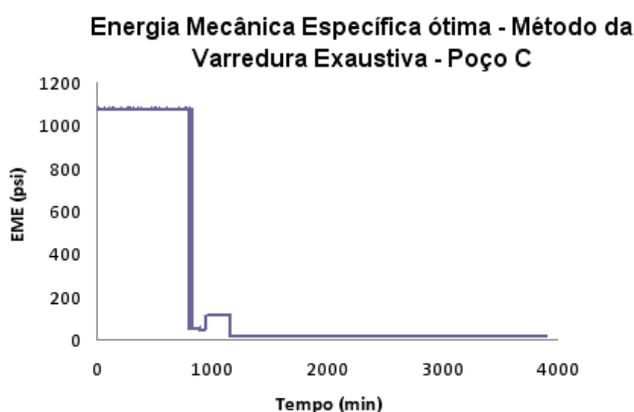


Figura 4.54. Energia mecânica específica mínima ao longo do tempo para uma taxa de 45 m/h do poço C

4.6.3.4. Otimização dos dados do poço D através de varredura exaustiva

A Figura 4.55 mostra os gráficos de RPM e WOB ótimos ao longo do tempo para o poço D e um *setpoint* de taxa de penetração de 45 m/h. Estes valores não só garantem a taxa de penetração desejada, como também garantem os valores mínimos de energia mecânica específica.

A Figura 4.56 mostra o gráfico de energia específica mínima na broca ao longo do tempo para manter a taxa de penetração no *setpoint* desejado.

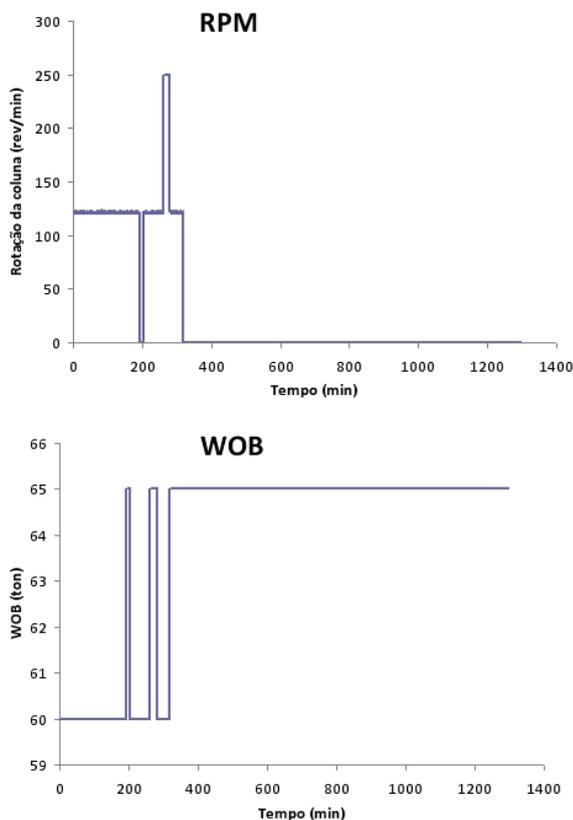


Figura 4.55. RPM e WOB ótimas de acordo com as condições operacionais do poço D

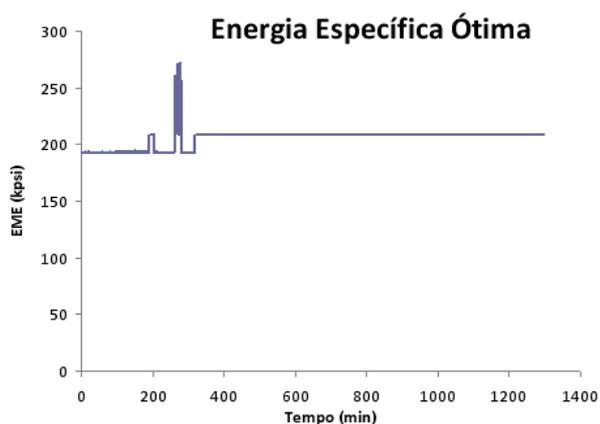


Figura 4.56. Energia mecânica específica mínima ao longo do tempo para uma taxa de 45 m/h do poço D

As Figuras 4.47, 4.49, 4.53 e 4.55 mostram os gráficos de energia mecânica específica na broca para manter a taxa no *setpoint* de 45 m/h para os poços A, B, C e D respectivamente. Uma vez que as curvas de EME foram geradas pelo método de varredura exaustiva, tem-se a garantia de que estes valores são, de fato, os mínimos possíveis.

4.7 Comparação dos métodos de otimização

Acima, foram mostradas três tentativas de se chegar a valores ótimos de rotação da broca e peso sobre broca. Valores ótimos são, não só aqueles que gerem a taxa de penetração desejada (nos exemplos mostrados, 45 m/h), mas também aqueles que garantam o mínimo gasto de energia possível, minimizando perdas de energia por vibração, flambagem e desgaste de broca e equipamentos de fundo. Dos três métodos propostos, o método da varredura exaustiva é o único que garante o mínimo gasto de energia.

O método de determinação do par de RPM e WOB pela rede inversa, de todos os testados, é o que gera resultados com o menor custo computacional. Entretanto, a incapacidade de as redes inversas (tanto a única quanto as separadas por litologia) o torna o mais inapropriado dos métodos. Uma vez que fornece apenas um par de rotação e peso sobre broca para uma determinada taxa de penetração, o método não dá nenhuma garantia de que este par seja aquele que gera o menor gasto de energia. Além disso, devido ao mau desempenho das redes inversas, sequer se tem a garantia de que, ao utilizar o par de RPM e WOB obtido, a taxa de penetração desejada será atingida.

Assim, o método da obtenção de RPM e WOB com as redes inversas não gera os resultados esperados e não é uma opção a ser considerada.

Já o método introduzido com algoritmo PSO utiliza as redes diretas separadas por litologia como modelo para previsão da taxa de penetração e, portanto, garante que o par de RPM e WOB determinado gera a taxa desejada. Mas, assim como as redes inversas, o método converge assim que encontra um par que leva à ROP desejada, fornecendo um único par de rotação e peso sobre broca. Existem, entretanto, múltiplas combinações possíveis. Logo, o método também não é capaz de garantir que o par determinado gere a mínima quantidade de energia. Ou seja, apesar de garantir a ROP desejada, não há garantias de que o par de RPM e WOB seja o par ótimo. Quanto ao custo computacional, o algoritmo PSO é o método que levou o maior tempo para a determinação do par de RPM e WOB para cada instante de tempo do poço (cerca de 10 segundos). Este tempo, no entanto, não é impeditivo para uma aplicação de tempo real.

Por fim, o método proposto com varredura exaustiva, que também utiliza as redes diretas separadas por litologia, garante não só a taxa de penetração desejada, como também a menor energia específica possível. Por varrer todos os pares de RPM e WOB que geram a taxa desejada, o método garante a obtenção daquele par que gere a menor energia mecânica específica, ou seja, garante a obtenção, de fato, do par ótimo. A boa eficiência das redes

diretas separadas por litologia nas previsões das taxas de penetração garantem a eficiência do método. Quanto ao custo computacional o método da varredura exaustiva foi o que apresentou um tempo intermediário (mas muito próximo do algoritmo PSO) para a determinação do par ótimo a cada instante de tempo: cerca de 8 segundos. Este tempo não é impeditivo para uma aplicação de tempo real. Mesmo assim, não há necessidade de rodar o método a cada instante de tempo que chegam novos dados em tempo real. Caso as condições operacionais do poço não mudem, os valores de RPM e WOB ótimos também não devem sofrer alterações significativas. Assim, o método poderia ser acionado periodicamente (a cada intervalo de tempo ou de profundidade pré-determinado) ou sempre que houvesse mudanças nas condições operacionais (mudança de litologia, mudança de vazão, de pressões, etc).

As Figuras 4.57 a 4.60 mostram a comparação das energias mecânicas específicas obtidas com os três diferentes métodos para os poços A, B, C e D, respectivamente. Em todos os casos, a energia mecânica específica gerada pelo método da varredura exaustiva levou aos menores valores de energia específica. Note que, na Figura 4.60, a energia específica calculada por este método é tão inferior às demais que torna-se difícil visualizá-la na escala do gráfico.

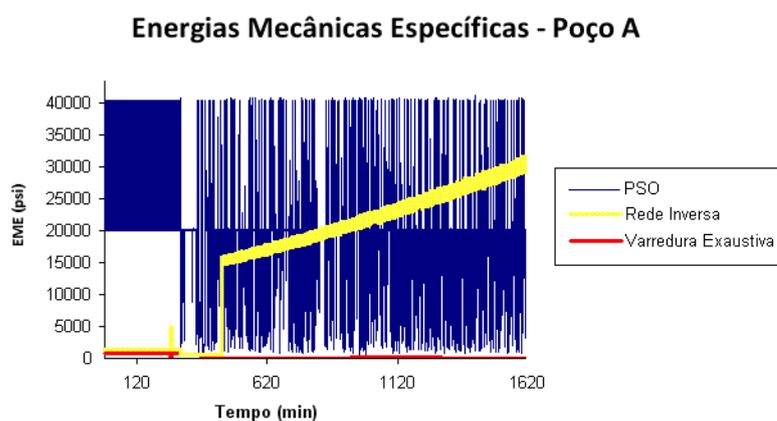


Figura 4.57. Comparação das energias mecânicas específicas previstas pelos diferentes métodos – Poço A

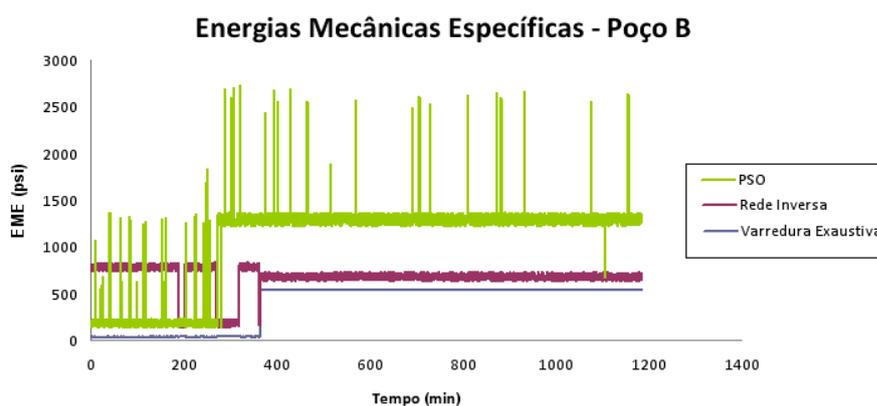


Figura 4.58. Comparação das energias mecânicas específicas previstas pelos diferentes métodos – Poço B

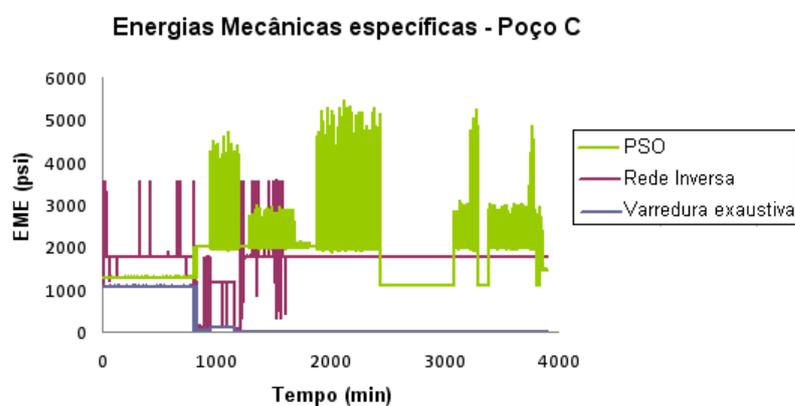


Figura 4.59. Comparação das energias mecânicas específicas previstas pelos diferentes métodos – Poço C

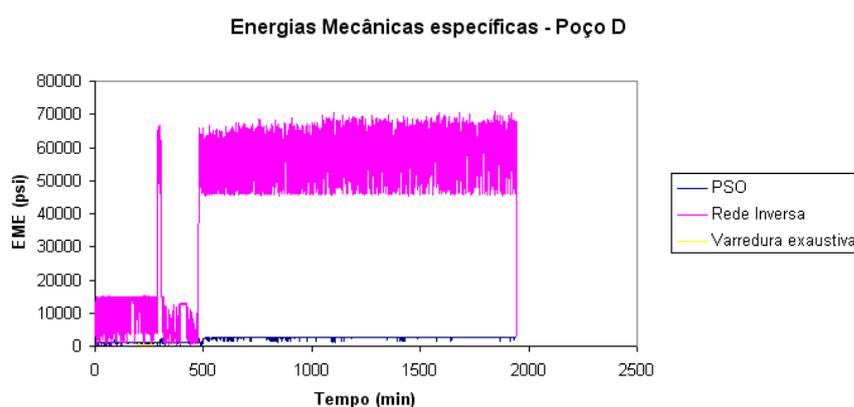


Figura 4.60. Comparação das energias mecânicas específicas previstas pelos diferentes métodos – Poço D

A otimização dos parâmetros operacionais para a obtenção de uma determinada taxa de penetração exige a minimização simultânea da energia mecânica específica na broca (Equação 3.1) e da função erro (Equação 3.3).

Como mencionado anteriormente, a dificuldade encontrada na otimização de rotação e peso sobre broca é que não se conhece o valor alvo de uma das funções a serem minimizadas. Não se conhece o valor mínimo (alvo) da energia mecânica específica na broca. Este valor pode apresentar uma enorme variação em um intervalo de tempo bastante curto, bastando que ocorram modificações nas condições operacionais. Se, por exemplo, o torque medido em superfície aumentar rapidamente em 25 % (situação comum em poços direcionais), o valor da energia mecânica mínima também aumentará rapidamente. Mudanças na vazão do poço também causam mudanças na energia específica. Mudanças de litologia podem causar gigantescas variações na energia mecânica específica.

Isto dificulta o uso de métodos de otimização convencionais, tais como Métodos de Superfície de Resposta com função “*desirability*” (MONTGOMERY, 2005), que requerem o conhecimento do valor alvo a ser buscado.

O Método de Monte Carlo poderia ser uma boa opção para o problema de otimização deste trabalho. Porém, uma vez que ambos os métodos (Monte Carlo e varredura da exaustiva) possuem custos computacionais semelhantes e que o segundo pode garantir a determinação do ponto ótimo pelo uso de um grid mais fino, o método determinístico da varredura exaustiva foi escolhido. Soma-se a isso, o fato de que, apesar do alto custo computacional do método da varredura exaustiva, o tempo de execução do código gerado não se mostrou impeditivo para a aplicação em tempo real.

CAPÍTULO 5

Conclusões e sugestões para trabalhos futuros

5.1 Apresentação

Após a análise do desempenho das redes neuronais, dos modelos mais comuns para a previsão da taxa e dos métodos utilizados neste trabalho para a determinação do par ótimo de RPM e WOB para se obter uma determinada ROP, esta capítulo faz uma discussão sobre as conclusões tiradas do trabalho. Primeiro, são apresentadas as conclusões acerca do desempenho das redes neuronais diretas na previsão de taxas de penetração e da comparação com os três modelos mais conhecidos e usados na indústria do petróleo para este fim. Em seguida, é feita uma discussão sobre o desempenho da arquitetura dos modelos inversos, para a previsão de RPM e WOB dada uma ROP desejada. Após isso, é feita uma discussão a respeito das conclusões sobre os três métodos para obtenção do par de RPM e WOB ótimos. Os métodos são discutidos e comparados entre si. Por fim, são feitas considerações finais e sugestões para trabalhos futuros.

5.2 Uso de redes neuronais para previsão da taxa de penetração durante a perfuração de poços de petróleo

O uso de redes neuronais mostrou-se uma boa solução para a falta de modelos confiáveis para a previsão da taxa de penetração. A arquitetura desenvolvida para as redes diretas separadas por litologias apresentou uma excelente capacidade de previsão para os quatro poços de validação escolhidos. A arquitetura da rede direta única apresentou um resultado inferior quando comparada às redes diretas separadas. Cada tipo de rocha possui um comportamento muito distinto das demais e a arquitetura da rede única não permite uma diferenciação adequada das respostas extremamente diferentes de cada tipo de litologia.

A comparação dos resultados das redes diretas separadas por litologias (que apresentaram o melhor desempenho) com os obtidos para os modelos de Maurer e Young também deixa clara a superioridade das redes neuronais. Apesar de muito usados na indústria do petróleo, tais modelos tem diversas limitações e não geram resultados realistas. Diferentemente das redes desenvolvidas neste trabalho, os modelos de Maurer e Young levam em conta apenas a rotação da broca e o peso sobre broca, além de características das rochas, embutidas em suas constantes. Entretanto, uma mesma rocha pode apresentar diferentes características, dependendo das condições (temperatura, compactação, etc) a que está submetida. Diferente das redes neuronais, os modelos de Maurer e Young não são capazes de levar este tipo de comportamento em conta.

O modelo de Bourgoyne não pôde ser testado e comparado com as redes neuronais. Este modelo requer informações que certamente influenciam a taxa de penetração, mas que são extremamente difíceis ou mesmo impossíveis de se medir diretamente durante a perfuração. Por exemplo, não estavam disponíveis, para os poços usados neste trabalho, informações da ferramenta de sônico (tempo de transito) e de desgaste de broca. Entretanto, o fato de as redes neuronais terem apresentado um desempenho tão satisfatório em uma situação em que o modelo de Bourgoyne sequer poderia ter sido usado representa uma grande vantagem da primeira opção.

Assim, conclui-se que as redes neuronais diretas separadas por litologias apresentaram um desempenho muito satisfatório e são a melhor opção, dentre as testadas neste trabalho, para a previsão da taxa de penetração durante a perfuração de poços de petróleo.

Entretanto, deve-se tomar grande cuidado com o cenário de aplicação deste tipo de solução. As redes desenvolvidas nesta dissertação foram treinadas com dados de poços localizados na costa brasileira. Após um trabalho para eliminação de dados ruidosos e

incoerentes, restaram apenas doze litologias diferentes. Para a verificação do desempenho das redes, foram usados poços de validação localizados na mesma região dos poços de treinamento. Ou seja, tanto os poços de validação quanto os de treinamento possuíam uma história geológica muito similar. Assim, é de se esperar que os tipos de rochas encontrados nos poços de treinamento apresentem comportamentos semelhantes aos encontradas nos poços de validação. Outro cuidado que se teve foi o de eliminar dos poços de validação dados que continham qualquer litologia diferente das doze usadas no treinamento. As redes, evidentemente, não seriam capazes de prever o comportamento da taxa em uma litologia para a qual não foram treinadas.

Assim, as redes desenvolvidas aqui apresentarão resultados satisfatórios apenas para poços da região da costa brasileira e que não apresentem litologia diferente das doze citadas. Um poço localizado em regiões *onshore* do Rio Grande do Norte, por exemplo, possui uma história geológica bem diferente dos situados na costa brasileira e, portanto, provavelmente não apresentaria resultados satisfatórios.

Evidentemente, doze litologias é um número muito limitado e, para uma aplicação em perfurações reais, novas redes precisam ser treinadas para a previsão do comportamento da taxa em mais tipos de rocha. Isso, porém, não compromete as conclusões deste trabalho, que visa o desenvolvimento não de um modelo para previsão da taxa de penetração em qualquer situação, mas de uma metodologia de otimização dos parâmetros operacionais em tempo real.

5.3 Redes neuronais inversas

As redes neuronais inversas foram treinadas objetivando-se a determinação rápida e direta dos parâmetros operacionais para um dado *setpoint* de ROP. Entretanto, a observação do comportamento da taxa de penetração frente os demais parâmetros operacionais (tanto prática quanto das respostas fornecidas pelas redes diretas) mostrou que existem múltiplas entradas para uma única saída de ROP. Isto, por si só, inviabilizaria o uso de uma rede inversa para qualquer fim de otimização, pois este tipo de arquitetura é capaz de fornecer apenas um único par de saída. Não se teria nenhuma garantia de que o par encontrado é, de fato, o ótimo.

Além disso, a própria natureza do problema (múltiplas entradas para uma única saída) leva a resultados ruins das redes inversas, que não foram capazes de prever corretamente os dados de RPM e WOB reais.

Mesmo assim, as energias mecânicas específicas dos pares de RPM e WOB obtidos pela rede foram comparados às dos pares obtidos pelo algoritmo de varredura exaustiva. A comparação mostra que as energias mecânicas dos pontos determinados rede inversa são sempre mais elevadas do que aqueles obtidos pelos demais algoritmos.

Desta forma, o uso de redes inversas mostrou-se inadequado tanto para a previsão de parâmetros operacionais quanto para qualquer uso de otimização de perfuração em tempo real.

5.4 Resultados dos métodos de otimização

Foram testadas três diferentes formas para determinação dos parâmetros operacionais ótimos em tempo real: 1) determinação explícita através de rede inversa; 2) Determinação através de algoritmo PSO e 3) Determinação através de método de varredura exaustiva.

A otimização da perfuração passa, necessariamente, por uma etapa de minimização da energia mecânica específica na broca. Em outras palavras, a otimização dos parâmetros operacionais (RPM e WOB) consiste em determinar as condições para se atingir uma determinada taxa de penetração desejada e, ao mesmo tempo, com a menor energia mecânica específica possível.

O método de determinação dos parâmetros operacionais através de uma rede inversa não serve, como já explicado anteriormente, para uma aplicação de otimização de perfuração, uma vez que fornece apenas um único par de RPM e WOB e não há nenhuma garantia de que este seja o par ótimo. Outro agravante é a constatação de que as redes inversas não são capazes de prever RPM e WOB tendo um *setpoint* de taxa de penetração como entrada. Assim, não há sequer a garantia de que o par de RPM e WOB apontado pela rede gera de fato a ROP desejada.

O mesmo ocorre com o método de determinação de RPM e WOB através do algoritmo PSO. O algoritmo gera apenas um par de WOB e RPM. Diferente do que ocorre com os modelos das redes neurais inversas, o PSO utiliza o modelo direto (redes separadas por litologias), o que garante que o par encontrado gera a ROP desejada. Mas não há nenhuma garantia de que este par seja aquele que gera a menor energia mecânica específica. É possível, entretanto, determinar diversos pares de RPM e WOB varrendo regiões diferentes do domínio. As energias específicas dos pontos identificados são, então, comparadas e aquele ponto que gera o menor valor deste parâmetro é eleito como o ponto ótimo. Mesmo assim, não se tem garantia de que todos os pontos possíveis foram identificados e, portanto, não se

pode afirmar que o ponto ótimo eleito é de fato aquele com o menor valor de energia específica. Outra opção seria a inclusão da equação de energia mecânica específica (Equação 3.1) no algoritmo para que tanto a função erro (Equação 3.3), quanto a EME fossem minimizadas simultaneamente. Sob esse ponto de vista, adotou-se o método de varredura exaustiva

O método de varredura exaustiva consiste em varrer todos os pontos possíveis de RPM e WOB (respeitando-se os limites operacionais) e determinar a taxa de penetração para cada um deles. Aqueles pontos que gerem uma taxa igual (ou dentro dos limites de tolerância pré-estabelecidos) ao *setpoint* desejado são armazenados e tem sua energia específica calculada. Dentre estes pontos, aquele que possuir o menor valor de energia específica é eleito o ponto ótimo. Para este trabalho adotou-se uma tolerância de erro na taxa de penetração de 0,1 m/h. Ou seja, qualquer par que gerasse uma ROP igual à ROP de *setpoint* somada ou subtraída de 0,1 m/h era considerado como aceitável.

Apesar de a busca exaustiva elevar o custo computacional da solução, este foi o único método (dentre os três citados) que garante a determinação do ponto ótimo. O custo computacional, por outro lado, não chega a ser um problema, já que não há necessidade de se calcular os parâmetros ótimos a cada intervalo de 10 ou 15 segundos. Conforme comentado anteriormente, o cálculo dos parâmetros ótimos precisa ser feito apenas quando houver mudanças nas condições operacionais (o que não costuma ocorrer com uma frequência elevada) ou com uma periodicidade pré-estabelecida (a cada 10 ou 20 metros perfurados ou a cada 1 ou 2 horas, dependendo do critério do engenheiro de perfuração). Assim, o custo computacional deste método não é um empecilho para seu uso.

A análise das Figuras 4.57 a 4.60 mostra que, de fato, o método da varredura exaustiva leva às menores energias específicas possíveis. Note que, em alguns casos, a energia específica prevista pelo método de varredura exaustiva é várias ordens de grandeza menor do que a prevista pelos outros dois métodos. Este tipo de diferença se observa na prática. Ou seja, verifica-se que ao se manipular (aumentar WOB e reduzir RPM, por exemplo) alguns parâmetros operacionais, mantendo-se a taxa de penetração em um mesmo patamar, a energia específica na broca pode reduzir várias ordens de grandeza. Note que a curva de energia específica obtida com o método da varredura exaustiva apresenta sempre os menores valores. Em alguns casos, inicialmente a rede inversa prevê uma energia específica próxima do método de varredura exaustiva, mas, em seguida, a energia cresce enormemente. Nota-se ainda que alguns pontos obtidos com o algoritmo PSO apresentam valores de energia muito baixos e bem próximos daqueles obtidos com o método da varredura exaustiva. Mas ainda

assim, não foi verificado nenhum valor abaixo daqueles obtidos com o método da varredura exaustiva.

O desenvolvimento de uma metodologia que ajude na escolha dos parâmetros ótimos em tempo real durante a perfuração é extremamente útil e gera uma grande redução de tempo e custos.

Logo, a partir dos resultados mostrados na dissertação, conclui-se que o método de varredura exaustiva é o que fornece os melhores resultados e, portanto, é mais indicado para a otimização da perfuração em tempo real.

5.5 Considerações finais

As redes diretas separadas por litologias funcionaram bem e apresentaram resultados muito bons com a validação de dados inéditos. As redes foram treinadas com dados de poços da costa brasileira. Por este motivo, os modelos desenvolvidos devem prever bem o comportamento da taxa em poços desta região, ou que apresentem uma história geológica similar. Não há nenhuma garantia de bom funcionamento das redes em regiões diferentes, tais como Golfo do México ou campos *onshore* brasileiros.

As redes inversas, por outro lado, não mostraram desempenhos adequados e não foram capazes de prever rotação e peso sobre broca. Não devem, portanto, ser utilizadas para previsão destes parâmetros e nem para otimização de perfuração em tempo real.

Quanto aos métodos de otimização, os melhores resultados foram obtidos com o algoritmo de varredura exaustiva. Este método, apesar de apresentar um custo computacional mais elevado, é o que apresenta maior probabilidade de determinar o ponto ótimo, dependendo do *grid* adotado. Por isso, é bastante adequado para o uso de otimização de perfuração em tempo real.

5.6 Sugestões para trabalhos futuros

Embora, neste trabalho, as litologias de maior incidência na costa brasileira tenham sido contempladas, ainda existe um número muito grande de tipos de rocha que não o foram. Isto impede a aplicação das redes desenvolvidas em aplicações reais. Assim, recomenda-se o treinamento de mais redes neuronais para mais tipos de litologias de forma a aumentar a abrangência do modelo de previsão de taxas de penetração. Isso inclui não só mais litologias

presentes na costa brasileira como também novas redes para poços em outras regiões, tais como o Recôncavo Baiano, Espírito Santo e o Rio Grande do Norte. Outra solução a ser testada é o treinamento de redes *online* durante uma perfuração. Isto garante que a rede seja treinada com dados reais do poço em vez de dados de poços de correlação, o que é sempre preferível.

As redes inversas não mostraram desempenho adequados, devido à própria natureza do processo. Assim, não se recomenda mais testes com este tipo de arquitetura.

Após a implementação de uma rede neuronal direta com treinamento *online* ou de novas redes neuronais diretas para mais tipos de litologias, é imprescindível que seja realizado um teste de campo. Recomenda-se que as redes neuronais sejam implementadas em um *software* de acompanhamento de perfuração em tempo real (tal como o PWDa, de onde foram coletados os dados de perfuração usados neste trabalho), junto com o método de otimização por varredura exaustiva para a avaliação dos resultados em um teste de campo.

Sugere-se ainda investigação da eficiência de outros métodos de otimização, tais como algoritmo genético.

CAPÍTULO 6

Referências bibliográficas

- (1) AADNOY, B.S., COOPER, I., MISKA, S.Z., MITCHELL, R.F., PAYNE, M.L., *Advanced Drilling and Well Technology*, Society of Petroleum Engineers, E.U.A., 2009.
- (2) ARAGAO, A.F.L., TEIXEIRA, G.T., MARTINS, A.L., GANDELMAN, R.A., SILVA, R.A., *PWD Analysis in Deepwater Environments: Campos Basin Case Study*, Deep Offshore Technology, Vitória – Brasil, 8 a 10 de novembro, 2005.
- (3) BAGAJEWICZ, M.J. *Process Plant Instrumentation: design and upgrade*, Technomic Publishing, Pennsylvania, 2001.
- (4) BILGESU, H.I., TETRICK, L.T., ALTMIS, U., MOHAGHEGH, S., AMERI, S., *A New Approach for the Prediction of Rate of Penetration (ROP) Values*, Society of Petroleum Engineers, Eastern Regional Meeting – SPE-39231, Lexington – KY – Estados Unidos, 22 a 24 de outubro, 1997.
- (5) BISHOP, C. *Neural Networks for Pattern Recognition*, University Press, Oxford, 1995.
- (6) BOURGOYNE, A.T., MILLHEIM, K.K., CHENEVERT, M.E., YOUNG, F.S., *Applied Drilling Engineering*, Society of Petroleum Engineers, Richardson - TX, 1991.

- (7) BOURGOYNE, A.T., YOUNG, F.S., *A Multiple Regression Approach to Optimal Drilling and Abnormal Pressure Detection*, Society of Petroleum Engineers, SPE/AIME-4238, Austin – TX, Estados Unidos, 22 a 23 de Janeiro, 1974.
- (8) CLERC, M., *Particle Swarm Optimization*, Iste, Newport Beach - CA, 2006.
- (9) COMBS, G.D., *Prediction of Pore Pressure From Penetration Rate*, II Symposium of Abnormal Surface Pore Pressure, Baton Rouge – LA, Estados Unidos, Janeiro, 1970.
- (10) CUNNINGHAM, A.J., EENINK, J.G., *Laboratory Study of Effect of Overburden, Formation and Mud Column Pressure on Drilling Rates at Depth*, AIME, vol 216, 9-17, 1959.
- (11) DE SOUZA JR, M. B. *Redes Neurais aplicadas a modelagem e controle de processos químicos*, Tese (Doutor em Ciências) – Programa de Engenharia Química/COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 124p.; 1993.
- (12) EDWARDS, J.H., *Engineering Design of Drilling Operations*, Drilling and Production Practices, API, 1964.
- (13) FORTUNA, L.; GRAZIANI, S.; RIZZO, A.; XIBILIA, M.G. *Soft Sensors for Monitoring and Control of Industrial Processes*, Springer, London, 2007.
- (14) GALLE, E.M., WOODS, A.B., *Best Constant Weight and Rotary Speed for Rotary Rock Bit*, Drilling and Production Practices, API, 1963.
- (15) GANDELMAN, R.A., MARTINS, A.L., TEIXEIRA, G.T., WALDMANN, A.T.A., ARAGAO, A.F.L., MARI, A., STRUGATA, V.A., REZENDE, M.S.C., *Real Time Drilling Data Analysis: Building Blocks for the Definition of a Problem Anticipation Problem*, Society of Petroleum Engineers, SPE/IADC - 128871, Nova Orleans – LA – Estados Unidos, 2 a 4 de fevereiro, 2010.
- (16) GANDELMAN, R.A., MARTINS, A.L., TEIXEIRA, G.T., WALDMANN, A.T.A., MARI, A., REZENDE, M.S.C., Aragao, A.F.L., *A Comprehensive Methodology to Avoid and Remediate Drilling Problems by Real Time PWD Data Interpretation*, Society of Petroleum Engineers, SPE/ATCE - 124116, Nova Orleans – LA – Estados Unidos, 4 a 7 de outubro, 2009.
- (17) GARNIER, A.J., LINGEN, N.H., *Phenomena Affecting Drilling Rates at Depth*, AIME, vol 216, 232-239, 1959.
- (18) HEDAYATZADEH, M., HAMIDI, K.S.J.K., *An Artificial Neural Network Model to Predict the Performance of Hard Rock TBM*, ISRM International Symposium 2010 and 6th Asian Rock Mechanics Symposium, Nova Deli – Índia, 23 a 27 de outubro, 2010.

- (19) HAYKIN, S. *Redes Neurais: princípios e prática*, 2^a ed., Bookman, Porto Alegre, 2001.
- (20) HOSKINS, J.C.; HIMMELBLAU, D. *Artificial Neural Network Models of knowledge representation in chemical engineering*, Computer Chemical Engineering, v. 12, n. 9/10, p. 881-890, 1988.
- (21) JAMES, W., CHUKWU, G.A., KHATANIAR, S., PATIL, S., *An Economic Appraisal of Hole Cleaning Using Hydraulic Horse Power and Jet Impact Force*, SPE-83496, West Regional Pacific Section, California, Estados Unidos, 19 a 24 de maio, 2003.
- (22) JOHN, Z., AHSAN, A., REID, I., *Optimized Decision Making Through Real Time Access to Drilling and Geological Data from Remote Wellsites*, SPE 77855, SPE Asia Pacific Oil and Gas Conference and Exhibition, Melbourne, Australia, Outubro, 2002.
- (23) JORDEN, J.R., SHIRLEY, O.J., *Application of Drilling Performance Data to Overpressure Detection*, Journal of Petroleum Technology, 1387-1394, novembro, 1966.
- (24) KADLEC, P.; GABRYS, B.; STRANDT, S. *Data-driven soft sensors in the process industry*, Computer and Chemical Engineering, v. 33, p. 795-814, 2009.
- (25) KENNEDY, J., EBERHART, R. C., *Swarm Intelligence*, Morgan Kaufmann Publishers, Estados Unidos, 2001.
- (26) LEONARD, J.; KRAMER, M.A.. *Improvement of the backpropagation algorithm for training neural networks*, Computers chem. Eng., v. 14, issue 3, p. 337-341, 1990.
- (27) MAURER, W.C., *Bit Tooth Penetration Under Simulated Borehole Conditions*, Journal of Petroleum Technology, 1433-1442, 1965.
- (28) MAURER, W.C., *The Perfect Cleaning Theory of Rotary Drilling*, Journal of Petroleum Technology, 1270-1274, 1962.
- (29) MONTGOMERY, C. D. *Design and Analysis of Experiments*, p448-454, GGS Book Services, Estados Unidos, 2005.
- (30) MOHRIAK, W., SZATMARI, P., ANJOS, S. M. C., Sal: *Geologia e Tectonia*, Beca/BALL Edições LTDA, Brasil, 2009.
- (31) MURRAY, A.S., CUNNINGHAM, R.A., *The Effect of Mud Column Pressure on Drilling Rates*, Trans AIME, vol 204, 196-204, 1955.
- (32) ROMMETVEIT, R., VEFRING, E. H., Comparison of Results from an Advanced Kick Simulator with Surface and Downhole Data from Full Scale Gas Kick

- Experiments in an Inclined Well, SPE-22558, 66° Annual Technical Conference and Exhibition of the Society of Petroleum Engineers, Dallas, TX, 6 a 9 de outubro, 2004.
- (33) OORT, E. V., BRADY, K., *Case-Based Reasoning System Predicts Twist-Off in Luisiana Well Based on Mideast Analog*, Special-Focus – Drilling Technology, Abril, 2011.
- (34) RASHIDI, B., HARELAND, G., FAZAELIZADEH, M., SVIGIR, M., *Comparative Study Using Rock Energy and Drilling Strength Models*, ARMA – American Rock Mechanichs Association, 44th U.S. Rock Mechanichs Symposium and 5th U.S.-Canada Rock Mechanichs Symposium, Salt Lake City - UT – Estados Unidos - 27 a 30 de junho, 2010.
- (35) ROCHA, L.A.S., AZEVEDO, C. T., *Projetos de Poços de Petróleo*, Editora Interciência, Rio de Janeiro, 2007.
- (36) ROMMETVEIT, R., BJORKEVOLL K.S., HALSEY G.W., LARSEN H.F., MERLO A., NOSSAMAN L.N., SWEEP M.N., KNUT M.S., AND INGE S., *Drilltronics: An Integrated System for Real-Time Optimization of the Drilling Process*, IADC/SPE 87124, IADC/SPE Drilling Conference, Dallas, Texas, 2-4 March 2004.
- (37) RUMELHART, D.E.; MCCLELLAND, J.L. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, MIT Press, Cambridge, 1986.
- (38) SCHWAAB, M., PINTO, J. C., *Análise de Dados Experimentais I – Fundamentos de Estatística e Estimação de Parâmetros*, E-papers serviços editoriais LTDS, Rio de Janeiro, 2007.
- (39) SEBORG, D.E., EDGAR, T.F., DUNCAN, A.M., DOYLE, F.J., *Process Dynamics and Control*, John Wiley & Sons Inc, Estados Unidos, 2011.
- (40) SIMMONS, E. L., *A Technique for Accurate Bit Programming and Drilling Performance Optimization*, IADC/SPE – 14784, Drilling Conference, Dallas – TX, Fevereiro, 1986.
- (41) THOMAS, J.E., *Fundamentos de Engenharia de Petróleo*, Editora Interciência, Rio de Janeiro, 2001.
- (42) VALDMAN, A., *Sistema de Automação para Monitoramento Online de Gases Residuais e Diagnóstico de uma Caldeira Operada com Mistura Diesel/Biodiesel*, Dissertação de Mestrado, Programa de Pós-graduação em Tecnologia de Processos Químicos e Bioquímicos, Escola de Química, UFRJ, 2010

- (43) VIDRINE, D.J., BENIT, E.J., *Field Verification of the Effect of Differential Pressure on Drilling Rate*, Journal of Petroleum Technology, 676-682, julho, 1968.
- (44) YOUNG, F.S., *Computadorized Drilling Control*, Journal of Petroleum Technology, 483-496, 1969.
- (45) WALDMANN, A.T.A., *Mecanismos que Governam a Efetividade de Agentes Obturantes no Controle da Invasão de Fluidos de Perfuração na Rocha Reservatório de Petróleo*, Dissertação de Mestrado, Departamento de Engenharia Mecânica, PUC-Rio, 2005.
- (46) WOLF, M.Z., ARIAN, A., *Field Measurements of Downhole Drillstring Vibrations*, SPE-14330, Annual Technical Conference and Exhibition, Las Vegas – NV, 22 a 25 de setembro, 1985.

APÊNDICE A

Códigos em MATLAB desenvolvidos

Rede direta única

```
% Rede Direta Única  
clc, clear all
```

```
W1 = [ -1.55011130815923e-001 1.11550919151877e+001 1.54808274532539e-001 -  
9.28502099712775e-003 3.17637081787007e-001 -1.11460127211524e-001 -  
4.43925881506270e+000 -1.81922710844356e+000 7.83421548842249e+000 -  
3.96213050208072e+000 -3.84577618701074e+000 -7.05691993854821e-001 -  
2.23919042821301e+000 8.23286776434430e+000 -3.16427625256290e+000  
1.09598243171712e+000 -6.85760853996348e-001 5.80608178039201e-001;  
-2.35836587501405e-002 4.32025249786297e+000 3.34151733230056e+000  
6.13707483095500e-003 1.14041680064226e+000 -1.45199281095867e+000  
1.88627773736950e-001 5.10274787707893e+000 3.68303129588634e+000 -  
1.22747681157774e+001 5.55654921267497e+000 -1.71378687297177e+000 -  
1.19570914242303e+000 4.03117229921748e+000 1.82981151669283e-001 -  
2.03014476796170e+000 -3.32004502094094e+000 5.83319060333523e-001;  
-6.51075649300488e-001 -4.30363634175871e-001 8.26852923335713e-001  
-5.73166448195517e-001 9.50296060323730e-001 2.43348356729844e+000 -  
2.13857269637014e+000 -8.13810238511028e-001 -2.79914755705628e+000  
5.37511801140803e+000 -5.37542206892228e-001 -2.43152133827734e+000 -  
1.13735378147538e+000 9.93031551053942e-002 1.12709187973527e+000 -  
6.44548207125818e-001 2.36113034625689e+000 1.40136368197893e+000;  
-9.28068491304193e-002 -2.28875273692629e-001 3.16163281009925e-001  
4.28966872279606e-001 -4.71535021173689e-001 1.23433387083846e-001  
5.13549249461295e+000 9.47128201815924e-001 -1.49960818799610e+000  
4.68597683225035e-001 -6.46833970294593e-001 -1.67793509262877e+000  
1.98600540208785e-001 -4.09406833531684e+000 4.96250461006823e-001  
7.27448923574619e-001 1.19535681815998e+000 6.03644843244838e-002;  
-9.34645559472997e-003 1.45656754883347e+000 -4.66566163308734e-001  
-1.48151027900296e-001 7.96017034723527e-001 4.55513163530032e-001 -  
1.84412050810823e+000 4.44590970681778e+000 2.78905112039761e+000 -  
8.57613210328055e+000 4.64462052558236e+000 1.03125438132885e+000 -  
1.93478661623490e+000 2.64651777009245e+000 3.40708404579162e-001 -  
4.65800513328828e+000 -1.04669400112169e+000 5.52067297465740e-001;  
4.64100045578975e-001 5.49958701816814e-001 -3.70268851235244e-001  
1.69125814797472e-001 -4.64535883403681e-001 -1.05835019824474e+000 -  
2.01420534322857e+000 -8.59017145758261e-001 4.08180942751162e+000 -  
1.99510289778924e+000 1.64806528934131e+000 -1.67000998765809e+000 -  
9.91821004226867e-001 3.70897171883171e+000 6.68963064100976e-001  
4.80482592348033e-001 -2.09872739643415e+000 -1.48747995989441e+000;  
-1.54012484912447e-001 3.75178496342246e+000 -6.75602753413836e-001  
-1.46496684568382e+000 6.26002866786427e-001 -6.41409891104739e-001  
8.40014899858504e+000 2.97500780427005e+000 -3.61830538791262e+000  
8.08558871191229e-001 -2.04257317045867e+000 -4.68207237703244e+000  
3.26622523318585e+000 -2.41949352692772e+000 -2.01380864382946e-001 -  
2.38393128966939e+000 1.82467230143572e+000 -3.56365780071607e-003;  
5.43898798580693e-001 -1.38511014548682e+001 1.58498755201780e-002 -  
8.41420143051829e-001 -2.66629436042070e-001 6.00938930671524e-001  
3.04616707146403e+000 8.95800182683104e-001 -5.55035316240364e+000  
4.48229035889769e+000 8.60133413425435e-001 -6.97140826665591e-001  
1.26391660986612e+000 -5.86333261351557e+000 2.00523350107698e+000 -  
1.29002387964439e+000 1.71351692932767e+000 2.31924391263380e+000;  
-9.68519153723364e-001 3.08460926084090e+000 4.05327313336336e+000 -  
2.64092412007752e+000 1.24124685829926e+000 2.83599609184551e+000 -  
1.68674869358468e+000 -6.95005055460602e+000 6.81483050136503e+000  
4.35885806914398e+000 -7.32268385485493e+000 1.80374977410608e+000 -  
1.57691627155287e+000 -1.91322912119894e-001 -9.70153217261835e-001  
2.65600638249028e+000 4.78614807943989e+000 -9.06135960838042e-001;
```

```

-4.99349415061650e-001 -6.08613791496276e-001 4.73906477154942e-001
-1.78353104848496e-001 4.98094285219232e-001 1.15313969067077e+000
1.14051641190101e+000 4.02218665582690e+000 -1.81664866890457e+000
3.40627870560735e-001 -2.95881273577010e+000 -1.07355796692472e+000 -
3.96202814063079e-001 -4.51804894207235e+000 -1.88471206298715e+000 -
9.96107717264365e-001 5.40618474375348e+000 3.86988032634218e+000 ];

W2 = [ 2.39929460089899e+000 -2.02340363099432e-002 -2.85371910869673e-001
1.64869786237383e+000 1.85655470161184e-001 -2.42450606860055e+000
1.41786735307827e-001 9.50413840305838e-002 1.71337485664628e-001 -
1.68099974103441e+000 ];

B1 = [ -6.74325043481144e+000 -2.51474046021754e+000 -5.73739463613962e-002
2.62296702578186e+000 -3.33252756665993e+000 -1.57350637342014e+000
4.06996502315262e+000 6.05471745715689e+000 1.78652783607134e+000
2.53019041341435e+000 ];

B2 = [ 5.71971560970446e-002 ];

Tamanho1 = size( W1 );
Tamanho2 = size( W2 );
Tamanho3 = size( B1 );
Tamanho4 = size( B2 );

Ne = Tamanho1( 2 );
Nh = Tamanho1( 1 );
Ns = Tamanho2( 1 );

maximos_entradas = [ 2.46000000000000e+002 6.99900000000000e+001
5.80353674404941e+003 1.18049502000000e+003 3.69257949443443e+000
1.75000000000000e+001 1 1 1 1 1 1 1 1 1 1 1 ];
minimos_entradas = [ 0.00000000000000e+000 0.00000000000000e+000
2.78520000000000e+003 0.00000000000000e+000 1.63337348972398e-001
8.50000000000000e+000 0 0 0 0 0 0 0 0 0 0 ];
maximos_saidas = [ 1.31157277708162e+002 ];
minimos_saidas = [ 0.00000000000000e+000 ];

for i = 1 : Ne
    scale_e( i ) = 1 / ( maximos_entradas( i ) - minimos_entradas( i ) );
    shift_e( i ) = minimos_entradas( i ) / ( minimos_entradas( i ) -
maximos_entradas( i ) );
end
for i = 1 : Ns
    scale_s( i ) = 1 / ( maximos_saidas( i ) - minimos_saidas( i ) );
    shift_s( i ) = minimos_saidas( i ) / ( minimos_saidas( i ) -
maximos_saidas( i ) );
end

entradas = xlsread('Totais_diretal','Sheet1','a2:r20000');
tamanho_entradas = size(entradas);
Np = tamanho_entradas( 1 ); %Número de pontos
entradas_escala = zeros( Np , Ne);

% Colocando as entradas em escala
for i = 1 : Ne
    for ii = 1 : Np
        entradas_escala( ii, i ) = entradas( ii, i ) * scale_e( i ) +
shift_e( i );
    end
end

```

```
end
end

% PROCESSAMENTO DA REDE
for k = 1 : Np
    % Entrada neuronios camada escondida
    for i = 1 : Nh
        neuronio_h( i ) = 0;
        for ii = 1 : Ne
            % somatório das entradas do neurônio i
            neuronio_h( i ) = neuronio_h( i ) + entradas_escalas( k , ii ) *
W1( i , ii );
        end
        % Somar o Bias
        neuronio_h( i ) = neuronio_h( i ) + B1( i );

        % Função de ativação - cálculo da saída do neurônio
        lambda( i ) = tanh( neuronio_h( i ) );
    end

    % Entrada Neuronios da ultima camada
    for i = 1 : Ns
        neuronio_s( i ) = 0;
        for ii = 1 : Nh
            % somatório das entradas do neurônio i
            neuronio_s( i ) = neuronio_s( i ) + lambda( ii ) * W2( i, ii );
        end
        % Somar o Bias
        neuronio_s( i ) = neuronio_s( i ) + B2( i );

        % Função de ativação - cálculo da saída do neurônio
        saida( i ) = neuronio_s( i ) * 1;
    end

    % Tirando as saídas de escala
    for i = 1 : Ns
        vetor_real( k ) = ( saida( i ) - shift_s( i ) ) / scale_s( i );
    end
    %vetor_saida = saida_real;
    saida_real = vetor_real';
end

end
```

Exemplo de rede direta separada por litologia (carbonato albiانو)

```
% Rede ALB
```

```
clc, clear all
```

```
W1 = [ 9.36156690466884e-002 1.41669934241828e-001 -1.69226728507806e-001
2.95184036504504e-001 -1.42254969966055e-001 1.09552451992414e-001;
1.59635951415631e-001 2.37903154800065e-001 -1.53982647190055e-001 -
1.91134771033943e-001 -4.04766996481645e-001 1.36674198963378e-001;
1.24071378384944e-001 3.06867799229818e-001 -1.86232195640843e-001 -
2.66841416445282e-001 -4.34235619911976e-001 1.01104884447955e-001;
2.17598593453877e-002 4.12052092383395e-001 -1.31624573599217e-001 -
1.51413865940418e-001 -8.64821333710555e-001 7.80115450589526e-002;
4.82602087042364e-003 6.06568847924110e-001 -1.07115285917254e-001
6.73028808453391e-002 -1.19119772914336e+000 6.88783631938751e-002;
1.62230763780093e-001 7.20653008589513e-001 -1.91201740577603e-001 -
2.46986838704163e-001 -1.11730226196117e+000 1.12229941658038e-001;
6.78744813578806e-002 3.33266959877893e-001 -1.14306421034463e-001 -
3.09961689701348e-001 -4.52739485893999e-001 6.63279788490464e-002;
1.09434356126717e-001 3.32100432143827e-001 -1.23060419190793e-001 -
4.10175585759925e-001 -6.17946338444925e-001 1.73909213415384e-001;
1.93256797985006e-001 7.51013671218200e-001 -1.94122257310437e-001 -
2.18936508133698e-001 -1.24759678257048e+000 1.90329184200826e-001;
1.08953513847823e-001 4.37131937484807e-001 -2.05147839058317e-001 -
6.19838270378141e-001 -8.18342121975588e-001 1.87999368470651e-001 ];
```

```
W2 = [ -6.86878440752150e-001 -1.19651900355838e-001 -4.53026683245567e-001
5.57083854792270e-001 8.20597410403881e-001 4.29777545704504e-001 -
2.52693274084011e-001 -1.45638225404779e-001 5.14388859268749e-001 -
4.87940933114333e-001 ];
```

```
B1 = [ -2.17359730858000e-001 1.91089718151049e-002 -1.01729859550128e-001
4.69986908147775e-002 9.96667449256627e-002 1.03427919238781e-001 -
6.63072243985120e-002 4.35982181607958e-002 9.66141151564887e-002 -
5.00209278323047e-002 ];
```

```
B2 = [ 3.69935659203728e-001 ];
```

```
Tamanho1 = size( W1 );
```

```
Tamanho2 = size( W2 );
```

```
Tamanho3 = size( B1 );
```

```
Tamanho4 = size( B2 );
```

```
Ne = Tamanho1( 2 );
```

```
Nh = Tamanho1( 1 );
```

```
Ns = Tamanho2( 1 );
```

```
maximos_entradas = [ 1.20000000000000e+002 4.58100000000000e+001
5.47953911012935e+003 1.01226100000000e+003 1.80975880134535e+000
1.75000000000000e+001 ];
```

```
minimos_entradas = [ 0.00000000000000e+000 4.36600000000000e+001
5.47948035314589e+003 1.00455902050000e+003 1.65268135650742e+000
8.50000000000000e+000 ];
```

```
maximos_saidas = [ 3.12813772865761e-001 ];
```

```
minimos_saidas = [ 2.97714884777228e-001 ];
```

```
for i = 1 : Ne
```

```

        scale_e( i ) = 1 / ( maximos_entradas( i ) - minimos_entradas( i ) );
        shift_e( i ) = minimos_entradas( i ) / ( minimos_entradas( i ) -
maximos_entradas( i ) );
    end
    for i = 1 : Ns
        scale_s( i ) = 1 / ( maximos_saidas( i ) - minimos_saidas( i ) );
        shift_s( i ) = minimos_saidas( i ) / ( minimos_saidas( i ) -
maximos_saidas( i ) );
    end

    entradas = xlsread('ALB','Sheet1','a2:f49');
    tamanho_entradas = size(entradas);
    Np = tamanho_entradas( 1 ); %Número de pontos
    entradas_escala = zeros( Np , Ne);

    % Colocando as entradas em escala
    for i = 1 : Ne
        for ii = 1 : Np
            entradas_escala( ii, i ) = entradas( ii, i ) * scale_e( i ) +
shift_e( i );
        end
    end

    % PROCESSAMENTO DA REDE
    for k = 1 : Np
        % Entrada neuronios camada escondida
        for i = 1 : Nh
            neuronio_h( i ) = 0;
            for ii = 1 : Ne
                % somatório das entradas do neuronio i
                neuronio_h( i ) = neuronio_h( i ) + entradas_escala( k , ii ) *
W1( i , ii );
            end
            % Somar o Bias
            neuronio_h( i ) = neuronio_h( i ) + B1( i );

            % Função de ativação - cálculo da saída do neuronio
            lambda( i ) = exp( neuronio_h( i ) );
        end

        % Entrada Neuronios da ultima camada
        for i = 1 : Ns
            neuronio_s( i ) = 0;
            for ii = 1 : Nh
                % somatório das entradas do neuronio i
                neuronio_s( i ) = neuronio_s( i ) + lambda( ii ) * W2( i, ii );
            end
            % Somar o Bias
            neuronio_s( i ) = neuronio_s( i ) + B2( i );

            % Função de ativação - cálculo da saída do neuronio
            saida( i ) = tanh( neuronio_s( i ) );
        end

        % Tirando as saídas de escala
        for i = 1 : Ns
            saida_real( k ) = ( saida( i ) - shift_s( i ) ) / scale_s( i );
        end
        saida_real = saida_real';
    end
end

```

Rede inversa única

```
% Rede Inversa Única
```

```
clc, clear all
```

```
W1 = [ 2.95712359594122e+000 -1.35914688691645e+001 -2.29183815015742e+000  
5.51235021502242e+000 3.51680789981722e+001 1.26540923799512e+000 -  
1.39162443792000e+001 -2.48985091488341e+001 2.29639041778298e+001  
2.298444454313947e+001 1.77404813820795e+001 -1.76124499360552e+001  
8.85890238108125e+000 -1.79998033891439e+001 7.62152994984278e+000  
8.39242237538886e+000 -1.45878348811939e+001;  
-4.07666792214793e-001 1.13593200065634e+001 5.60276570622903e-001 -  
2.47342068560507e+000 -2.07233697279798e+001 1.51807949759003e+000  
1.32403553223548e+001 -1.49674327541980e+001 9.71603024049497e+000 -  
1.58561291163633e+001 -2.56409546438579e+000 4.24212218280424e+000 -  
4.75935681931190e+000 1.05689635631457e+001 -4.02524889127684e+000 -  
4.82252405912666e+000 7.15246005525515e+000;  
1.29587652293245e+000 3.93644747684317e-002 4.82611324719657e+000  
1.10743188490524e+000 2.46947421154863e+000 -2.20663852963118e+000 -  
5.25655209987313e+000 -4.21394136721084e+000 -6.42400035757605e+000  
5.49987415558242e+000 1.22303954156713e+001 6.08752592513010e+000 -  
2.42038677587258e+000 -2.49660065431793e-001 -1.04918620573622e+000 -  
8.03540429295774e-001 -7.66016120555105e-001;  
7.68630109671159e+000 3.68967575380566e+000 1.52213085162221e+000 -  
2.27800019516546e+000 -7.00909083287539e-001 6.48912636470369e-002 -  
5.06208611454674e+000 -6.56517990552245e+000 7.66838220046740e+000 -  
1.41802753469932e+001 -3.02545823503260e+000 2.74674729754469e+000  
9.05901741026798e+000 1.40158031504332e+000 8.56246544583176e-001  
1.11827470228609e+001 -2.17510432902102e+000;  
4.18445952971681e-001 1.12453887833334e-001 -1.59803547520959e+000 -  
1.28250368156228e+000 -8.67062283224519e+000 7.86203849476290e+000  
1.47730087148386e+000 -1.12058107902729e+001 -7.41991079253098e-001 -  
8.13619678830707e+000 2.25437532373987e+000 -1.33660187836893e+000  
4.73495903833511e+000 3.58742159133667e+000 1.11179365582169e+000  
4.04951806879012e-001 1.36234951394472e-001;  
5.97141359125450e+000 -6.71542620037917e+000 1.00163743482103e+001 -  
6.20831826112697e+000 8.44755226598682e+000 2.29683177436534e-001 -  
5.64251241564699e+000 -1.68889839242905e+001 3.00864903890162e+000  
7.82987622827083e+000 8.09638057570191e+000 -1.15896626791951e+001  
2.40786163559258e+000 5.62216963858205e-001 1.02875792962345e+001  
6.20476448925569e+000 -5.19734304247580e+000;  
2.94525071386416e+001 -1.36201324261165e+001 3.31189071618322e-001 -  
2.09024159615352e+001 2.91000070017978e+001 8.02839630615499e-002 -  
2.74966912816446e+000 -2.05809337319673e+001 1.76207875162806e+001  
5.99169677942221e+000 -1.19105036362122e+001 -7.91080039316335e+000  
8.47610078529402e+000 -3.54106260116319e+000 3.54343974059846e+000  
6.82285327080787e+000 4.18901746697716e+000;  
-2.30091607611800e+000 2.11076350441453e-002 -1.06683007744735e+002  
2.66523054476812e+000 -1.06584263262031e+000 -2.13030383205100e+000  
3.26310192133356e+000 2.69295125247637e+000 1.21127195010662e+001  
7.24545140211937e+000 1.24943467997091e+001 -1.94216444267541e-001 -  
3.31409832903971e+000 4.96381634975614e+000 -2.59340692248350e+001 -  
1.78823832493482e+001 4.54567481137097e+000;  
2.52013318528152e+000 1.13763952895039e-001 -1.21876120687748e+001 -  
3.96984714284029e+000 2.39118601295647e+000 1.27286987408212e+000 -  
2.127996444408200e+000 -1.31104685166428e+001 -9.39232191855126e+000 -  
1.79823486330278e-001 6.93919557986632e+000 3.82553434460410e+000
```

```

4.85494118274670e+000 1.13160577537981e+000 5.88532373055370e+000
3.48112394249252e+000 -2.60552981824333e+000 ];

W2 = [ 2.43010499188023e+000 2.85162771788688e+000 -8.46865248866806e-001
2.50622565590633e+000 -6.80479620593520e+000 5.77846152844848e+000 -
2.44880968580460e+000 -3.93429035063196e+000 -1.46925459106638e+000;
-7.82419366659209e-002 -1.23732107141108e-001 5.93149992737569e+000
-5.50551376926923e-002 5.82245181295990e+000 3.20652187568349e-001 -
1.05546120337007e-001 -5.65012843077976e+000 -6.01196703847113e+000 ];

B1 = [ -1.52314545048256e+001 6.63941937945033e+000 -4.01732073481648e+000
1.70169753961340e+000 7.37292172017717e+000 2.53180875224467e+000 -
3.37001081616554e-002 -6.70893446251917e+000 1.36260514120040e+000 ];

B2 = [ 5.30215658207732e-002 6.67705237141605e-002 ];

Tamanho1 = size( W1 );
Tamanho2 = size( W2 );
Tamanho3 = size( B1 );
Tamanho4 = size( B2 );

Ne = Tamanho1( 2 );
Nh = Tamanho1( 1 );
Ns = Tamanho2( 1 );

maximos_entradas = [ 5.80353674404941e+003 1.18049502000000e+003
1.31157277708162e+002 3.69257949443443e+000 1.75000000000000e+001 1 1 1 1 1
1 1 1 1 1 1 ];
minimos_entradas = [ 2.78520000000000e+003 0.00000000000000e+000
0.00000000000000e+000 1.63337348972398e-001 8.50000000000000e+000 0 0 0 0 0
0 0 0 0 0 0 ];
maximos_saidas = [ 2.46000000000000e+002 6.99900000000000e+001 ];
minimos_saidas = [ 0.00000000000000e+000 0.00000000000000e+000 ];

for i = 1 : Ne
    scale_e( i ) = 1 / ( maximos_entradas( i ) - minimos_entradas( i ) );
    shift_e( i ) = minimos_entradas( i ) / ( minimos_entradas( i ) -
maximos_entradas( i ) );
end
for i = 1 : Ns
    scale_s( i ) = 1 / ( maximos_saidas( i ) - minimos_saidas( i ) );
    shift_s( i ) = minimos_saidas( i ) / ( minimos_saidas( i ) -
maximos_saidas( i ) );
end

entradas = xlsread('Totais_inversal','Sheet1','a2:q20000');
tamanho_entradas = size(entradas);
Np = tamanho_entradas( 1 ); %Número de pontos
entradas_escala = zeros( Np , Ne);

% Colocando as entradas em escala
for i = 1 : Ne
    for ii = 1 : Np
        entradas_escala( ii, i ) = entradas( ii, i ) * scale_e( i ) +
shift_e( i );
    end
end

```

```

% PROCESSAMENTO DA REDE
for k = 1 : Np
    % Entrada neuronios camada escondida
    for i = 1 : Nh
        neuronio_h( i ) = 0;
        for ii = 1 : Ne
            % somatório das entradas do neuronio i
            neuronio_h( i ) = neuronio_h( i ) + entradas_escala( k , ii ) *
W1( i , ii );
        end
        % Somar o Bias
        neuronio_h( i ) = neuronio_h( i ) + B1( i );

        % Função de ativação - cálculo da saída do neuronio
        lambda( i ) = 1 / ( 1 + exp( - neuronio_h( i ) ) );
    end

    % Entrada Neuronios da ultima camada
    for i = 1 : Ns
        neuronio_s( i ) = 0;
        for ii = 1 : Nh
            % somatório das entradas do neuronio i
            neuronio_s( i ) = neuronio_s( i ) + lambda( ii ) * W2( i , ii );
        end
        % Somar o Bias
        neuronio_s( i ) = neuronio_s( i ) + B2( i );

        % Função de ativação - cálculo da saída do neuronio
        saida( i ) = neuronio_s( i ) * 1;
    end

    % Tirando as saídas de escala
    for i = 1 : Ns
        %saida_real( k , i ) = ( saida( i ) - shift_s( i ) ) / scale_s( i );
        saida_reall( k ) = ( saida( 1 ) - shift_s( 1 ) ) / scale_s( 1 );
        saida_real2( k ) = ( saida( 2 ) - shift_s( 2 ) ) / scale_s( 2 );
    end
    saida_reall = saida_reall';
    saida_real2 = saida_real2';

end

resultado( :,1) = saida_reall;
resultado( :,2) = saida_real2;

% Primeira Coluna = RPM // Segunda coluna = WOB
resultado

```

Exemplo de rede inversa separada por litologia (anidrita)

```

% Rede Inversa para AND
clc, clear all

W1 = [ -2.32202069886714e+000 7.22013155619984e-001 3.59629140768851e+000
5.41487182606142e-002 -1.70469213416386e+000;
      2.60468870429053e+000 -1.89916942591315e+000 -3.65938126523756e+000
2.44889132207190e-001 3.46341879175675e+000;
      -3.72491295713423e-001 -4.23510409165285e-002 2.51733599551230e+000
1.73975262397503e-002 -1.27216429354559e-001;
      2.10921729917614e+000 -2.12445775331910e+000 1.11431916032593e+000
6.84405312007134e-003 -3.55520313852362e-001;
      3.08848572748750e+000 -5.01493755129048e-001 -1.31691162778475e+000
3.02953282149536e-002 2.85598022994703e+000 ];

W2 = [ -4.03242651764883e-001 -9.76118649739098e-001 1.30380099281193e+000
2.97511933082113e+000 2.27787946697390e+000;
      2.67800312278601e+000 1.21623058651563e+000 3.34001481109074e+000 -
3.15650319907134e-001 1.90752323471157e+000 ];

B1 = [ -1.41119652874716e+000 -9.35323016876137e-002 -3.84295110314542e-001
-1.56259236536169e-001 3.10998947358355e-001 ];

B2 = [ 1.41271432342097e+000 -2.80610094305262e+000 ];

Tamanho1 = size( W1 );
Tamanho2 = size( W2 );
Tamanho3 = size( B1 );
Tamanho4 = size( B2 );

Ne = Tamanho1( 2 );
Nh = Tamanho1( 1 );
Ns = Tamanho2( 1 );

maximos_entradas = [ 3.39302883161656e+003 1.00409942000000e+003
3.81143443734974e-001 3.54527534612766e+000 1.75000000000000e+001 ];
minimos_entradas = [ 3.38844000000000e+003 5.63748410000000e+002
0.00000000000000e+000 3.38653897259145e+000 1.22500000000000e+001 ];
maximos_saidas = [ 1.50000000000000e+002 2.16800000000000e+001 ];
minimos_saidas = [ 2.10000000000000e+001 0.00000000000000e+000 ];

for i = 1 : Ne
    scale_e( i ) = 1 / ( maximos_entradas( i ) - minimos_entradas( i ) );
    shift_e( i ) = minimos_entradas( i ) / ( minimos_entradas( i ) -
maximos_entradas( i ) );
end
for i = 1 : Ns
    scale_s( i ) = 1 / ( maximos_saidas( i ) - minimos_saidas( i ) );
    shift_s( i ) = minimos_saidas( i ) / ( minimos_saidas( i ) -
maximos_saidas( i ) );
end

entradas = xlsread('ANDinv','Sheet1','a2:e657');
tamanho_entradas = size(entradas);
Np = tamanho_entradas( 1 ); %Número de pontos
entradas_escala = zeros( Np , Ne);

```

```

% Colocando as entradas em escala
for i = 1 : Ne
    for ii = 1 : Np
        entradas_escala( ii, i ) = entradas( ii, i ) * scale_e( i ) +
shift_e( i );
    end
end

% PROCESSAMENTO DA REDE
for k = 1 : Np
    % Entrada neuronios camada escondida
    for i = 1 : Nh
        neuronio_h( i ) = 0;
        for ii = 1 : Ne
            % somatório das entradas do neuronio i
            neuronio_h( i ) = neuronio_h( i ) + entradas_escala( k , ii ) *
W1( i , ii );
        end
        % Somar o Bias
        neuronio_h( i ) = neuronio_h( i ) + B1( i );

        % Função de ativação - cálculo da saída do neuronio
        lambda( i ) = tanh( neuronio_h( i ) );
    end

    % Entrada Neuronios da ultima camada
    for i = 1 : Ns
        neuronio_s( i ) = 0;
        for ii = 1 : Nh
            % somatório das entradas do neuronio i
            neuronio_s( i ) = neuronio_s( i ) + lambda( ii ) * W2( i, ii );
        end
        % Somar o Bias
        neuronio_s( i ) = neuronio_s( i ) + B2( i );

        % Função de ativação - cálculo da saída do neuronio
        saida( i ) = 1 / ( 1 + exp( - neuronio_s( i ) ) );
    end

    % Tirando as saídas de escala
    for i = 1 : Ns
        %saida_real( k, i ) = ( saida( i ) - shift_s( i ) ) / scale_s( i );
        saida_reall( k ) = ( saida( 1 ) - shift_s( 1 ) ) / scale_s( 1 );
        saida_real2( k ) = ( saida( 2 ) - shift_s( 2 ) ) / scale_s( 2 );
    end
    saida_reall = saida_reall';
    saida_real2 = saida_real2';

end
resultado( :,1) = saida_reall;
resultado( :,2) = saida_real2

```

Gerenciador para previsão de dados usando as redes diretas separadas por litologia

```
% Gerenciador para redes dirtas separadas por litologia
clc, clear all

ALB = 1;
AND = 2;
ARN_MAC = 3;
CLU = 4;
COQ = 5;
CRE = 6;
CRN = 7;
FLH = 8;
HAL = 9;
MRG = 10;
SLT = 11;
TQD = 12;

entradas_totais = xlsread('Totais_direta3','Sheet1','a2:h20000');
Tamanho_entradas = size( entradas_totais );
Npontos = Tamanho_entradas( 1 );

Litologia = entradas_totais( :, 1);

for contador = 1 : Npontos
    entradas = entradas_totais( contador , 2 : 7 );
    if Litologia( contador ) == 1    % Se Litologia = ALB
        RedeALB;
    end
    if Litologia( contador ) == 2    % Se Litologia = AND
        RedeAND;
    end
    if Litologia( contador ) == 3    % Se Litologia = ARN_MAC
        RedeARN_MAC;
    end
    if Litologia( contador ) == 4    % Se Litologia = CLU
        RedeCLU;
    end
    if Litologia( contador ) == 5    % Se Litologia = COQ
        RedeCOQ;
    end
    if Litologia( contador ) == 6    % Se Litologia = CRE
        RedeCRE;
    end
    if Litologia( contador ) == 7    % Se Litologia = CRN
        RedeCRN;
    end
    if Litologia( contador ) == 8    % Se Litologia = FLH
        RedeFLH;
    end
    if Litologia( contador ) == 9    % Se Litologia = HAL
        RedeHAL;
    end
    if Litologia( contador ) == 10   % Se Litologia = MRG
```

```
        RedeMRG;
    end
    if Litologia( contador ) == 11    % Se Litologia = SLT
        RedeSLT;
    end
    if Litologia( contador ) == 12    % Se Litologia = TQD
        RedeTQD;
    end

    if saida_real( 1 ) < 0.1
        saida_real( 1 ) = 0;
    end
    ROP_prev( contador ) = saida_real( 1 );

end
ROP_prev = ROP_prev';
ROP( :, 1 ) = entradas_totais( :, 8 );
ROP( :, 2 ) = ROP_prev;

% Primeira coluna = ROP real  /// Segunda coluna = ROP prevista
ROP
```

Gerenciador para previsão de dados usando as redes inversas separadas por litologia

```
% Gerenciador
clc, clear all

ALB = 1;
AND = 2;
ARN_MAC = 3;
CLU = 4;
COQ = 5;
CRE = 6;
CRN = 7;
FLH = 8;
HAL = 9;
MRG = 10;
SLT = 11;
TQD = 12;

entradas_totais = xlsread('Totais_inversa1','Sheet1','a2:h20000');
Tamanho_entradas = size(entradas_totais);
Npontos = Tamanho_entradas(1);

Litologia = entradas_totais(:, 1);

for contador = 1 : Npontos
    entradas = entradas_totais( contador , 2 : 6 );
    if Litologia( contador ) == 1 % Se Litologia = ALB
        RedeALBinv;
    end
    if Litologia( contador ) == 2 % Se Litologia = AND
        RedeANDinv;
    end
    if Litologia( contador ) == 3 % Se Litologia = ARN_MAC
        RedeARN_MACinv;
    end
    if Litologia( contador ) == 4 % Se Litologia = CLU
        RedeCLUinv;
    end
    if Litologia( contador ) == 5 % Se Litologia = COQ
        RedeCOQinv;
    end
    if Litologia( contador ) == 6 % Se Litologia = CRE
        RedeCREinv;
    end
    if Litologia( contador ) == 7 % Se Litologia = CRN
        RedeCRNinv;
    end
    if Litologia( contador ) == 8 % Se Litologia = FLH
        RedeFLHinv;
    end
    if Litologia( contador ) == 9 % Se Litologia = HAL
        RedeHALinv;
    end
    if Litologia( contador ) == 10 % Se Litologia = MRG
        RedeMRGinv;
    end
    if Litologia( contador ) == 11 % Se Litologia = SLT
```

```
        RedeSLTinv;
    end
    if Litologia( contador ) == 12    % Se Litologia = TQD
        RedeTQDinv;
    end

    if saida_real1( 1 ) < 0.1
        saida_real1( 1 ) = 0;
    end
    if saida_real2( 1 ) < 0.1
        saida_real2( 1 ) = 0;
    end
    RPM( contador ) = saida_real1( 1 );
    WOB( contador ) = saida_real2( 1 );

end
clear RPM_prev
clear WOB_prev
RPM_prev = RPM';
WOB_prev = WOB';
Resultados( : , 1 ) = entradas_totais( : , 7 );
Resultados( : , 2 ) = RPM_prev;
Resultados( : , 6 ) = entradas_totais( : , 8 );
Resultados( : , 7 ) = WOB_prev;

% Primeiras colunas = RRM real X RPM prevista    /// Ultimas colunas = WOB
% real X WOB prevista
Resultados;
```

Código para otimização via método da varredura exaustiva

```

% Otimização de ROP
%clc, clear all

% Códigos das litologias
ALB = 1;
AND = 2;
ARN_MAC = 3;
CLU = 4;
COQ = 5;
CRE = 6;
CRN = 7;
FLH = 8;
HAL = 9;
MRG = 10;
SLT = 11;
TQD = 12;

% Litologia RPM WOB POÇO VAZAO DIF DIAM torque
%entrada = [ ARN_MAC 50 65 4631.19 769.9955 0.6277 12.5 11000];
entradas_totais = entrada( 1 : 7 );
ROP_SP = 128.0664;
gerenciador;
ROP_Model = ROP_prev;
erro = abs( ROP_SP - ROP_Model );
conta = 0;
contal = 0;
diam = entradas_totais( 7 ) * 0.0254;
otimo = 1;
par_otimo = [ NaN NaN NaN ];

for WOB = 1 : 0.1 : 65
    for RPM = 0 : 1 : 600
        contal = contal + 1 ;
        entradas_totais( 2 ) = RPM;
        entradas_totais( 3 ) = WOB;
        gerenciador;
        ROP_Model = ROP_prev;
        erro = abs( ROP_SP - ROP_Model );
        par_alt( contal , 1 ) = RPM;
        par_alt( contal , 2 ) = WOB;
        par_alt( contal , 3 ) = ROP_Model;
        par_alt( contal , 4 ) = erro;
        if erro < 0.5
            conta = conta + 1;
            par( conta , 1 ) = RPM;
            par( conta , 2 ) = WOB;
            par( conta , 3 ) = ROP_Model;

            % Calculo da EMS
            ab = ( pi * diam ^ 2 ) / 4;
            EMS( conta ) = 0.35 * ( 1.422334331 * WOB / ab + 0.0172025 * pi
* RPM * entrada( 8 ) / ( ab * ROP_Model ) );

            if conta == 1
                par_otimo = par( otimo , 1 : 3 );
                ENERGIA = EMS( contador );
            else

```

```
        if EMS( conta ) < EMS( otimo )
            otimo = conta;
            par_otimo = par( otimo , 1 : 3 );
            ENERGIA = EMS( contador );
        end
    end
end
end
end

resultados = size( par_alt );

par_otimo;
```

Código do algoritmo PSO

```

%Initialization

clear
clc
iterations = 30;
inertia = 1.0;
correction_factor = 2.0;
swarm_size = 49;

% ---- initial swarm position ----
index = 1;
for i = 1 : 7
    for j = 1 : 7
        swarm(index, 1, 1) = i;
        swarm(index, 1, 2) = j;
        index = index + 1;
    end
end

swarm(:, 4, 1) = 1;           % best value so far
swarm(:, 2, :) = 0;         % initial velocity

    fonte = xlsread('pocoo','Sheet1','a1584:r1584');
    cc = fonte( 3 );
    dd = fonte( 4 );
    ee = fonte( 5 );
    ff = fonte( 6 );
    gg = fonte( 7 );
    hh = fonte( 8 );
    iii = fonte( 9 );
    jj = fonte( 10 );
    kk = fonte( 11 );
    ll = fonte( 12 );
    mm = fonte( 13 );
    nn = fonte( 14 );
    oo = fonte( 15 );
    pp = fonte( 16 );
    qq = fonte( 17 );
    rr = fonte( 18 );
    ROP_setpoint = 3;

%Iterations

for iter = 1 : iterations

    %-- evaluating position & quality ---
    for i = 1 : swarm_size
        swarm(i, 1, 1) = swarm(i, 1, 1) + swarm(i, 2, 1)/1.3;           %update x
    position

```

```

        swarm(i, 1, 2) = swarm(i, 1, 2) + swarm(i, 2, 2)/1.3;      %update y
position
        x = swarm(i, 1, 1);
        y = swarm(i, 1, 2);

        val = abs(ROP_setpoint - calculasaida( y, x, cc, dd, ee, ff, gg,
hh, iii, jj, kk, ll, mm, nn, oo, pp, qq, rr))
        %val = 50 - 20 * y * ( ( x / 12 ) + 60 ) ^ 2;
        %val = (x - 15)^2 + (y - 20)^2;          % fitness evaluation (you
may replace this objective function with any function having a global
minima)

        if val < swarm(i, 4, 1)                    % if new position is better
            swarm(i, 3, 1) = swarm(i, 1, 1);      % update best x,
            swarm(i, 3, 2) = swarm(i, 1, 2);      % best y postions
            swarm(i, 4, 1) = val;                 % and best value
        end
    end
    [temp, gbest] = min(swarm(:, 4, 1));          % global best position

    %--- updating velocity vectors
    for i = 1 : swarm_size
        swarm(i, 2, 1) = rand*inertia*swarm(i, 2, 1) +
correction_factor*rand*(swarm(i, 3, 1) - swarm(i, 1, 1)) +
correction_factor*rand*(swarm(gbest, 3, 1) - swarm(i, 1, 1)); %x velocity
component
        swarm(i, 2, 2) = rand*inertia*swarm(i, 2, 2) +
correction_factor*rand*(swarm(i, 3, 2) - swarm(i, 1, 2)) +
correction_factor*rand*(swarm(gbest, 3, 2) - swarm(i, 1, 2)); %y velocity
component
    end

    %% Plotting the swarm
    clf
    plot(swarm(:, 1, 1), swarm(:, 1, 2), 'x')    % drawing swarm movements
    axis([-2 80 -2 80]);
    pause(.2)
end

RPMotim = y
WOBotim = x

```

APÊNDICE B

Avaliação das Redes Separadas por Litologia

Neste apêndice, são apresentadas as figuras usadas na avaliação das redes separadas por litologia. As Figuras B.1 a B.12 mostram gráficos de ROP prevista *versus* ROP real usados para auxiliar a avaliação das redes diretas separadas por litologias. As Figuras B.13 a B.36 mostram gráficos de WOB prevista *versus* WOB real e RPM prevista *versus* RPM real usadas para auxiliar a avaliação das redes inversas separadas por litologia. Vale ressaltar que, assim como nas demais figuras o tipo já apresentadas neste trabalho, a equação da reta mostrada se refere à reta formada pelos pontos reais *versus* previstos, que não necessariamente é a reta que aparece nos gráficos. A reta visível nestes gráficos é a bissetriz, sobre a qual os pontos deveriam se alinhar em um caso de predição perfeita. Somente nestes casos, a equação mostrada descreveria a reta que aparece nas figuras. Da mesma forma, o coeficiente de correlação (R) mostrado abaixo da equação da reta se refere aos pontos e não à bissetriz.

A Figura B.1 mostra o gráfico de ROP prevista *versus* ROP real gerado pela rede direta específica para o carbonato albiano. Note que os pontos estão muito próximos da bissetriz, o que indica uma boa previsão da rede.

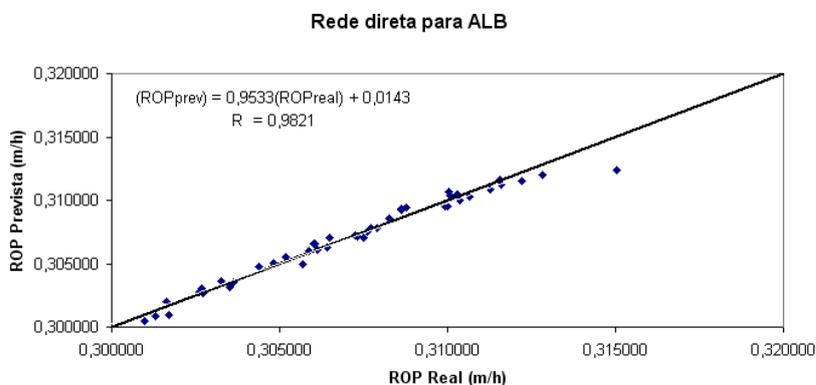


Figura B.1. ROP real *versus* ROP prevista – Rede para Carbonato Albiano

A Figura B.2 mostra o gráfico de ROP prevista *versus* ROP real gerado pela rede direta específica para a anidrita. Apesar de um pequeno desvio para as taxas mais elevadas, a figura mostra uma boa capacidade de predição da rede.

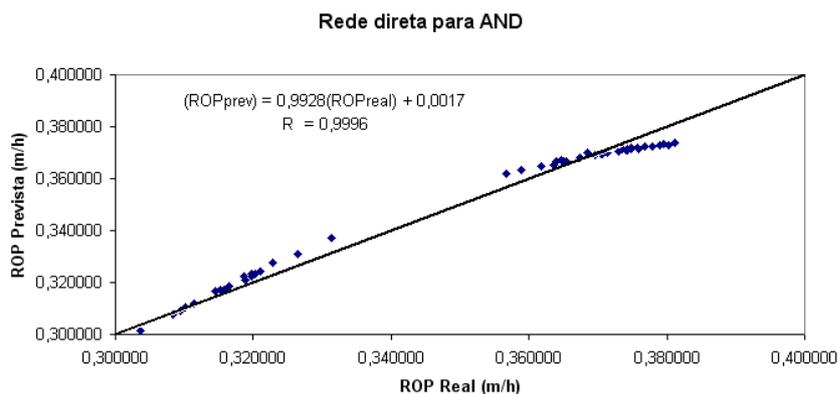


Figura B.2. ROP real *versus* ROP prevista – Rede para Anidrita

A Figura B.3 mostra o gráfico de ROP prevista *versus* ROP real gerado pela rede direta específica para o arenito. Os pontos estão alinhados sobre ou muito próximos à bissetriz, o que mostra uma boa capacidade de predição da rede.

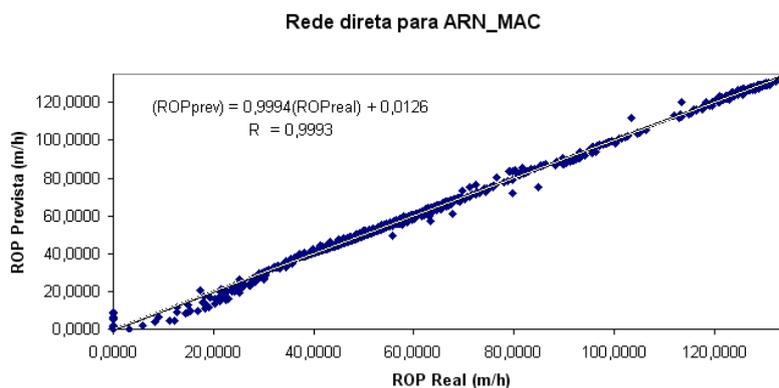


Figura B.3. ROP real *versus* ROP prevista – Rede para Arenito

A Figura B.4 mostra o gráfico de ROP prevista *versus* ROP real gerado pela rede direta específica para o calcilito. Os pontos estão alinhados sobre ou muito próximos à bissetriz, o que mostra uma boa capacidade de predição da rede.

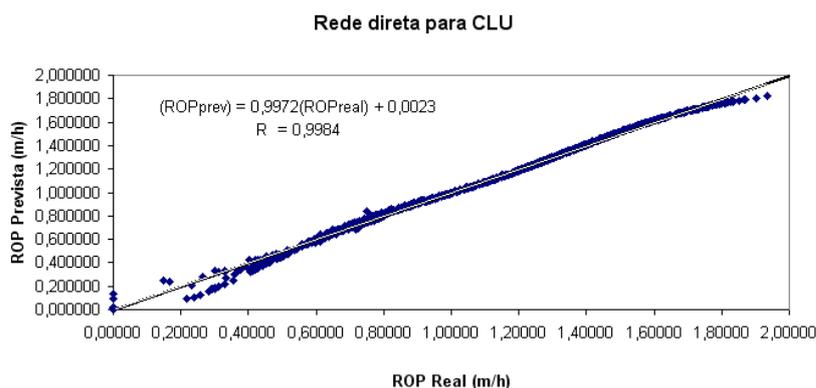


Figura B.4. ROP real *versus* ROP prevista – Rede para Calcilito

A Figura B.5 mostra o gráfico de ROP prevista *versus* ROP real gerado pela rede direta específica para a coquina. Apesar dos bons coeficientes angular linear, percebe-se os pontos estão acima da bissetriz, o que indica que a rede prevê taxas superiores às reais. Especificamente para o caso da coquina, este efeito não deve causar grandes erros nas previsões, pois esta litologia possui uma perfurabilidade bastante baixa, o que leva a taxas de penetrações também baixas. Para este trabalho, a rede para a coquina foi usada apesar do problema identificado. No entanto, deve-se ter em mente que esta rede não apresentou resultados satisfatórios e deve ser aprimorada. Provavelmente, os dados coletados para esta litologia foram poucos, o que prejudica a obtenção de uma rede confiável. Torna-se necessário a coleta de mais dados para esta litologia, com condições mais diversas para o treinamento de uma rede mais efetiva.

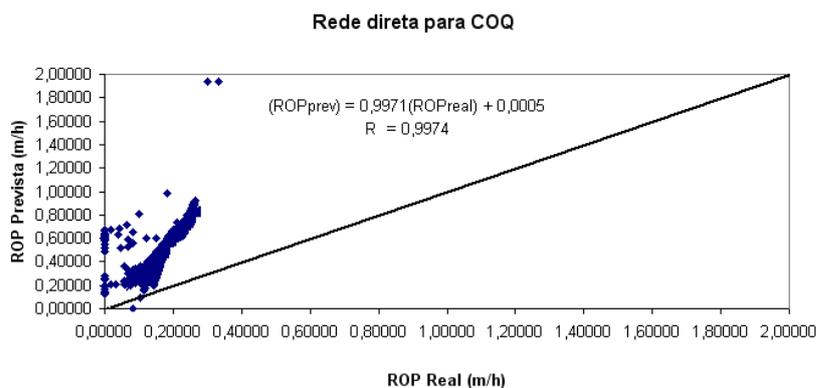


Figura B.5. ROP real *versus* ROP prevista – Rede para Coquina

A Figura B.6 mostra o gráfico de ROP prevista *versus* ROP real gerado pela rede direta específica para o calcarenito. Os pontos estão muito bem alinhados sobre a bissetriz, o que mostra uma boa capacidade de predição da rede.

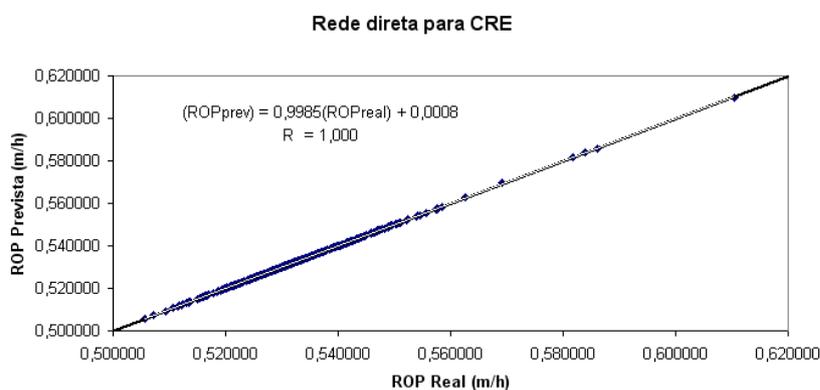


Figura B.6. ROP real *versus* ROP prevista – Rede para Calcarenito

A Figura B.7 mostra o gráfico de ROP prevista *versus* ROP real gerado pela rede direta específica para a carnalita. Os pontos se alinham sobre ou muito próximos à bissetriz, o que mostra uma boa capacidade de predição da rede.

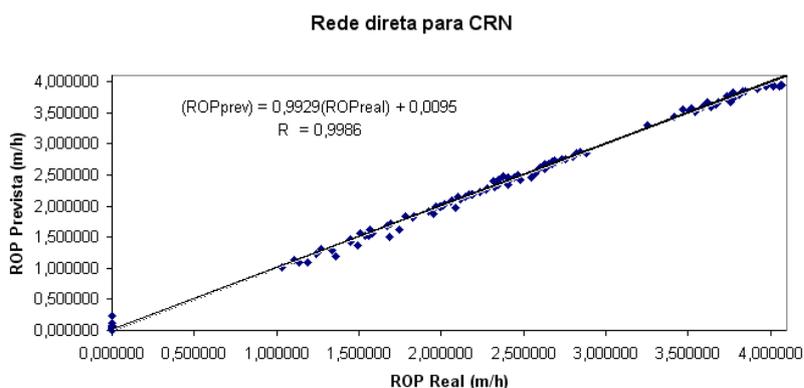
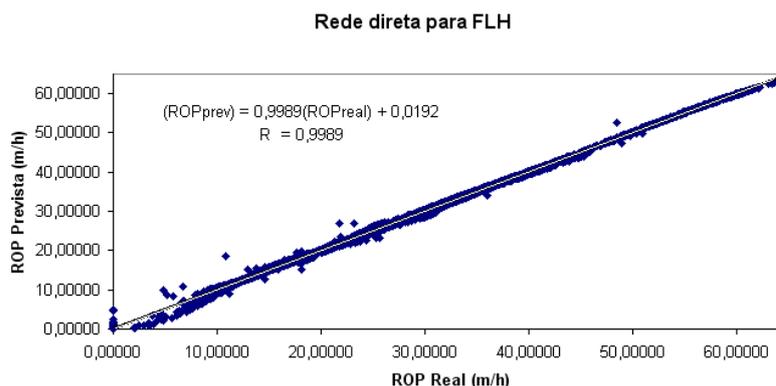
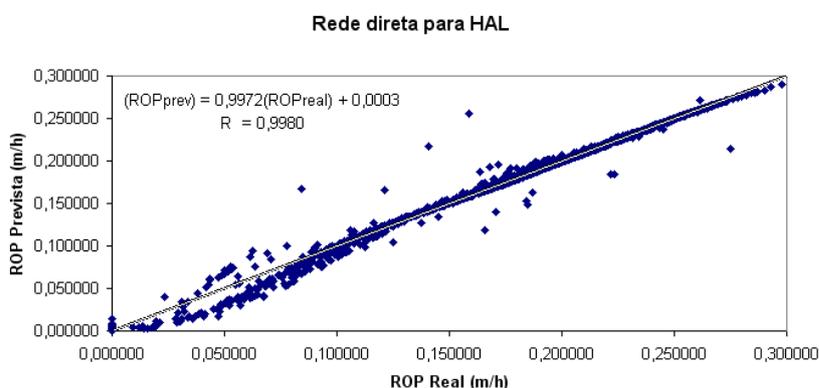


Figura B.7. ROP real *versus* ROP prevista – Rede para Carnalita

A Figura B.8 mostra o gráfico de ROP prevista *versus* ROP real gerado pela rede direta específica para o folhelho. Os pontos se alinham muito bem sobre a bissetriz, o que mostra uma boa capacidade de predição da rede.

Figura B.8. ROP real *versus* ROP prevista – Rede para Folhelho

A Figura B.9 mostra o gráfico de ROP prevista *versus* ROP real gerado pela rede direta específica para a halita. Apesar de apresentar uma dispersão maior os outros casos apresentados, de uma maneira geral, os pontos estão bem alinhados sobre ou muito próximos à bissetriz. Isto indica que a rede é capaz de prever com boa precisão as taxas de penetração para este tipo de litologia.

Figura B.9. ROP real *versus* ROP prevista – Rede para Halita

A Figura B.10 mostra o gráfico de ROP prevista *versus* ROP real gerado pela rede direta específica para a margá. Fora um pequeno desvio para as taxas mais elevadas, os pontos se alinham muito bem sobre a bissetriz, o que mostra uma boa capacidade de predição da rede.

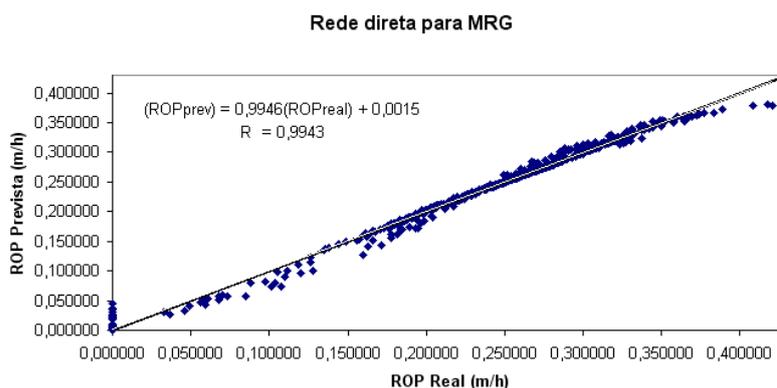


Figura B.10 - ROP real *versus* ROP prevista – Rede para Marga

A Figura B.11 mostra o gráfico de ROP prevista *versus* ROP real gerado pela rede direta específica para o siltito. Os pontos se alinham muito bem sobre a bissetriz, o que mostra uma boa capacidade de predição da rede.

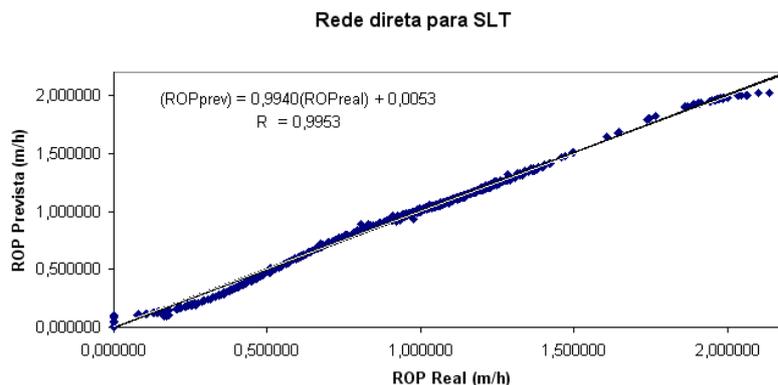


Figura B.11 - ROP real *versus* ROP prevista – Rede para Siltito

Por fim, a Figura B.12 mostra o gráfico de ROP prevista *versus* ROP real gerado pela rede direta específica para a taquidrita. Os pontos se alinham sobre ou bem próximos à bissetriz, o que mostra uma boa capacidade de predição da rede.

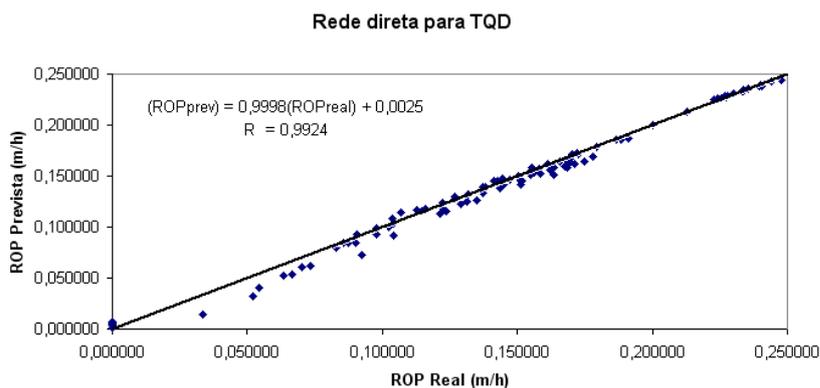


Figura B.12. ROP real versus ROP prevista – Rede para Taquidrita

As Figuras seguintes mostram os gráficos usados para a avaliação das redes inversas separadas por litologia. As Figuras B.13 e B.14 mostram, respectivamente, os gráficos de RPM real versus RPM prevista e WOB real versus WOB previsto para o carbonato albiano. Note que a previsão para RPM é bastante pobre.

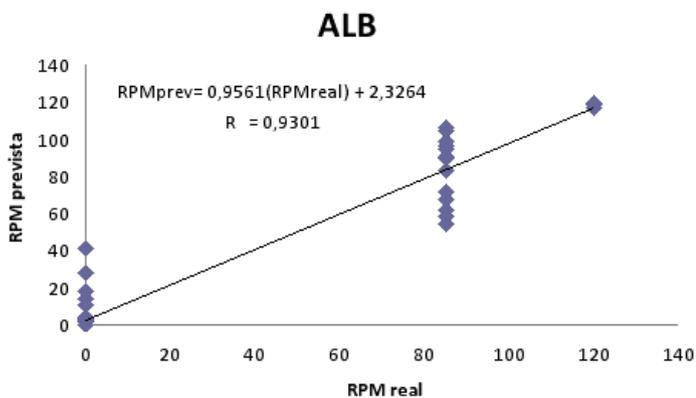


Figura B.13. RPM real versus RPM prevista – rede inversa para Carbonato Albiano

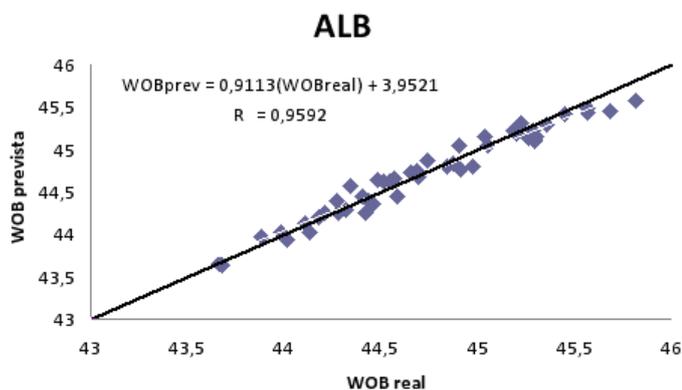


Figura B.14. WOB real versus WOB prevista – rede inversa para Carbonato Albiano

As Figuras B.15 e B.16 mostram, respectivamente, os gráficos de RPM real *versus* RPM prevista e WOB real *versus* WOB previsto para a anidrita. Como no caso anterior, a rede foi capaz de prever bem os pesos sobre broca, mas a predição de rotação de coluna é bastante pobre.

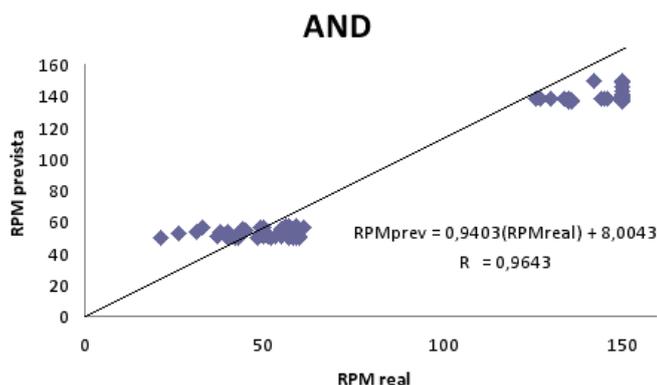


Figura B.15. RPM real versus RPM prevista – rede inversa para Anidrita

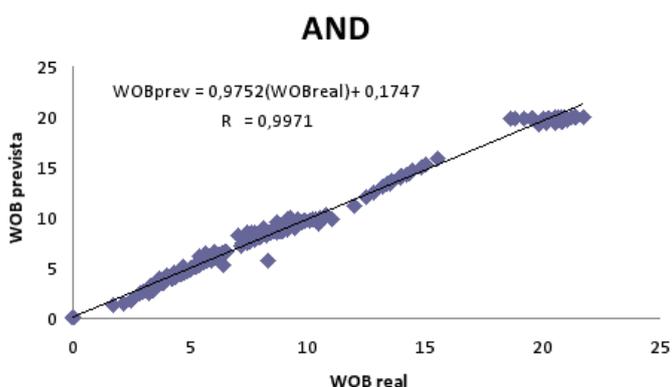


Figura B.16. WOB real versus WOB prevista – rede inversa para Anidrita

As Figuras B.17 e B.18 mostram, respectivamente, os gráficos de RPM real *versus* RPM prevista e WOB real *versus* WOB previsto para o arenito. Note que, apesar de prever razoavelmente bem os pesos sobre broca, a predição da rotação de coluna é extremamente pobre. Observa-se uma nuvem ao redor da bissetriz, o que comprova a falta de capacidade da rede para prever este parâmetro.

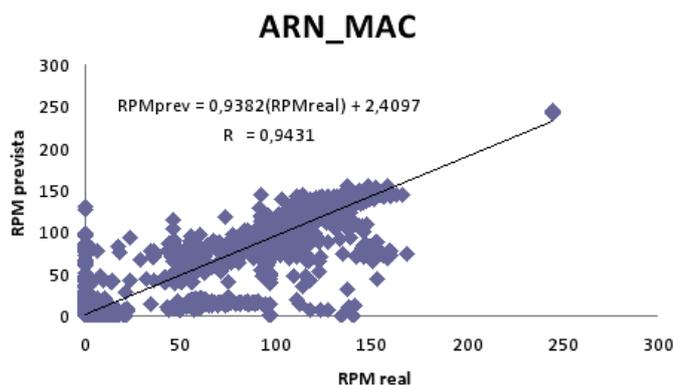


Figura B.17. RPM real versus RPM prevista – rede inversa para Arenito

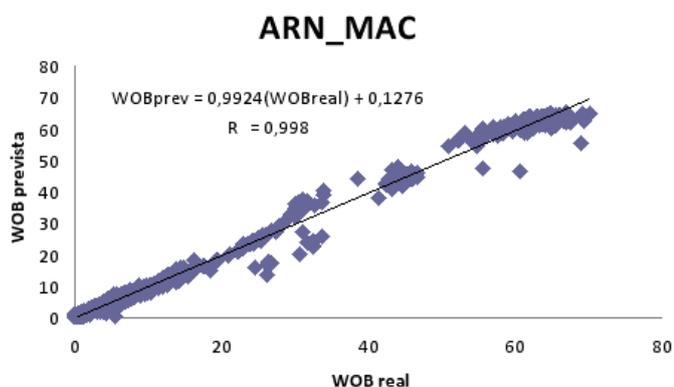


Figura B.18. WOB real versus WOB prevista – rede inversa para Arenito

As Figuras B.19 e B.20 mostram, respectivamente, os gráficos de RPM real *versus* RPM prevista e WOB real *versus* WOB previsto para o calcilutito. Note que a rede predisse muito bem o peso sobre broca, mas, como nos casos anteriores, o mesmo não se repetiu para a rotação da broca.

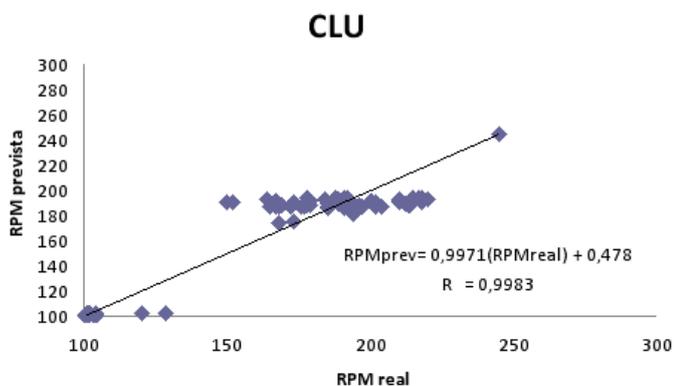


Figura B.19. RPM real versus RPM prevista – rede inversa para Calcilutito

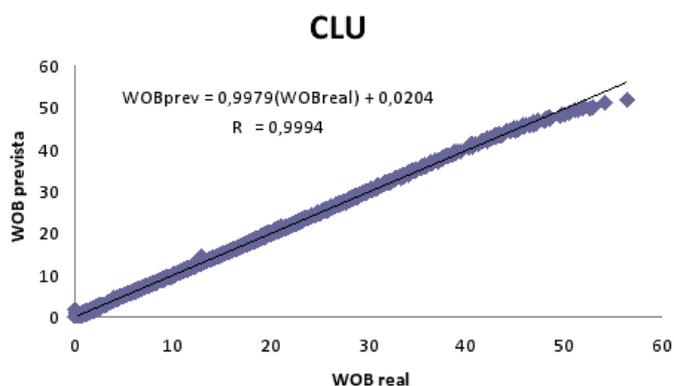


Figura B.20. WOB real versus WOB prevista – rede inversa para Calculutito

As Figuras B.21 e B.22 mostram, respectivamente, os gráficos de RPM real *versus* RPM prevista e WOB real *versus* WOB previsto para a coquina. Novamente, a rede prevê muito bem o peso sobre broca, mas o mesmo não se repetiu para a rotação da broca.

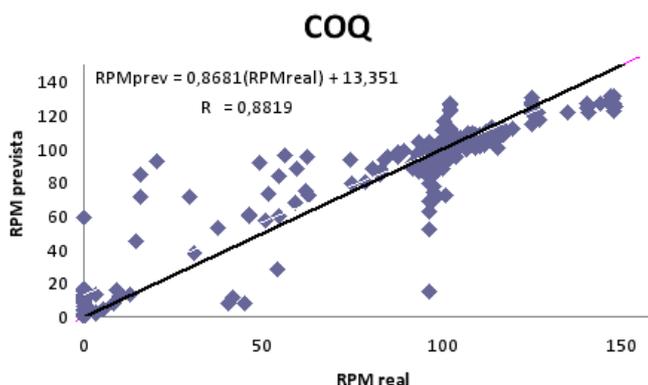


Figura B.21. RPM real versus RPM prevista – rede inversa para Coquina

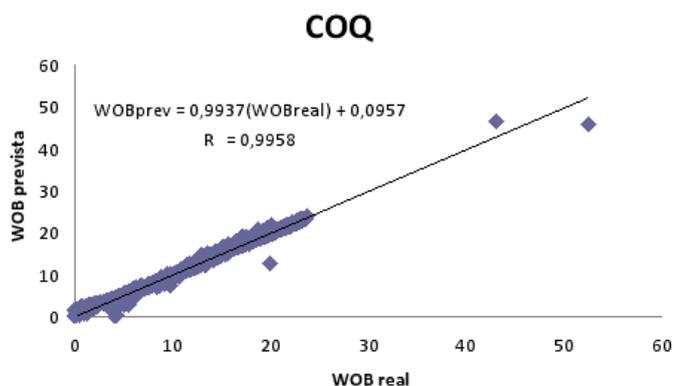


Figura B.22. WOB real versus WOB prevista – rede inversa para Coquina

As Figuras B.23 e B.24 mostram, respectivamente, os gráficos de RPM real *versus* RPM prevista e WOB real *versus* WOB previsto para o calcarenito. A rede prevê muito bem o peso sobre broca, mas a predição de rotação de coluna, apesar de um pouco melhor do que a dos casos anteriores, ainda é pobre.

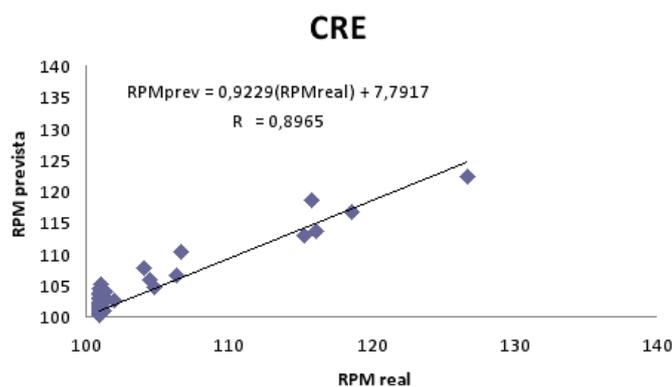


Figura B.23. RPM real versus RPM prevista – rede inversa para Calcarenito

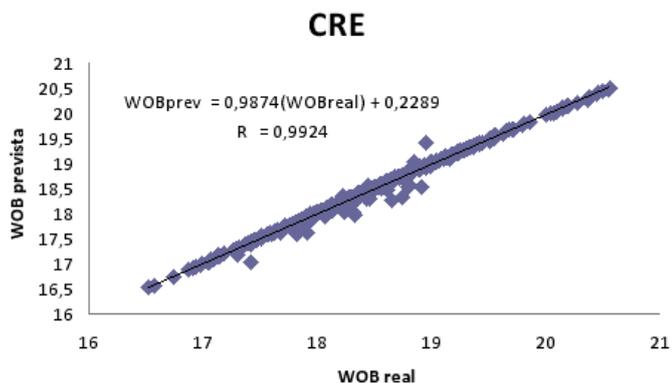


Figura B.24. WOB real versus WOB prevista – rede inversa para Calcarenito

As Figuras B.25 e B.26 mostram, respectivamente, os gráficos de RPM real *versus* RPM prevista e WOB real *versus* WOB previsto para a carnalita. A rede prevê muito bem o peso sobre broca, mas a predição de rotação de coluna, como nos casos anteriores, é pobre.

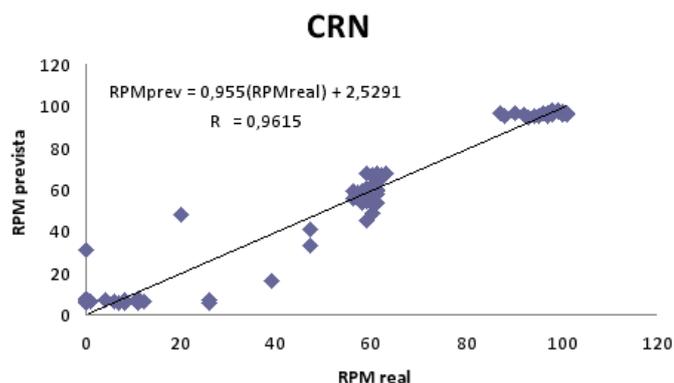


Figura B.25. RPM real versus RPM prevista – rede inversa para Carnallita

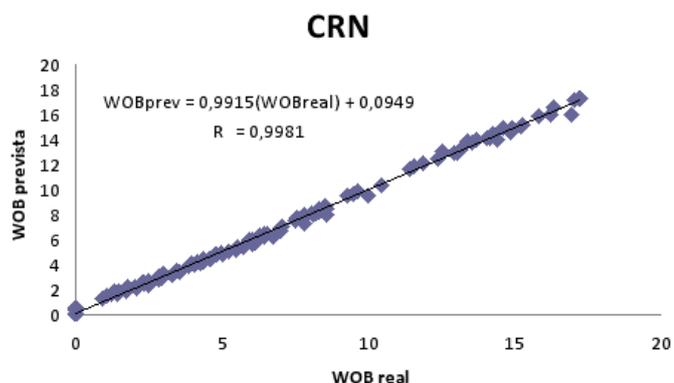


Figura B.26. WOB real versus WOB prevista – rede inversa para Carnallita

As Figuras B.27 e B.28 mostram, respectivamente, os gráficos de RPM real *versus* RPM prevista e WOB real *versus* WOB previsto para o folhelho. A rede prevê bem o peso sobre broca, mas a predição de rotação de coluna é pobre. Note que os pontos formam uma nuvem ao redor da bissetriz.

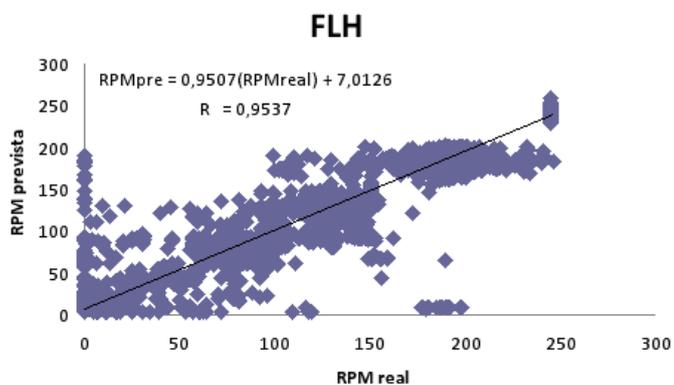


Figura B.27. RPM real versus RPM prevista – rede inversa para Folhelho

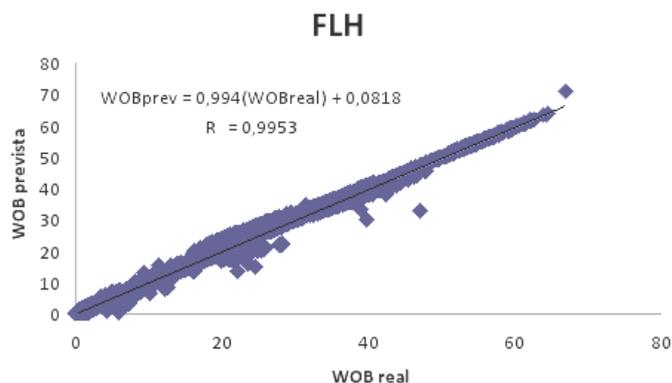


Figura B.28. WOB real versus WOB prevista – rede inversa para Folhelho

As Figuras B.29 e B.30 mostram, respectivamente, os gráficos de RPM real *versus* RPM prevista e WOB real *versus* WOB previsto para a halita. A rede prevê bem o peso sobre broca, mas a predição de rotação de coluna é pobre. Como no caso do folhelho, os pontos formam uma nuvem ao redor da bissetriz.

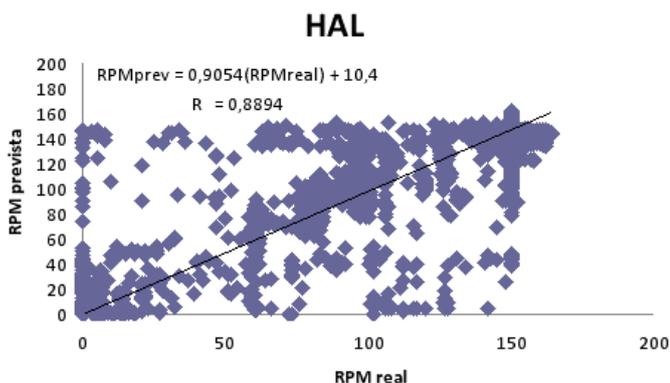


Figura B.29. RPM real versus RPM prevista – rede inversa para Halita

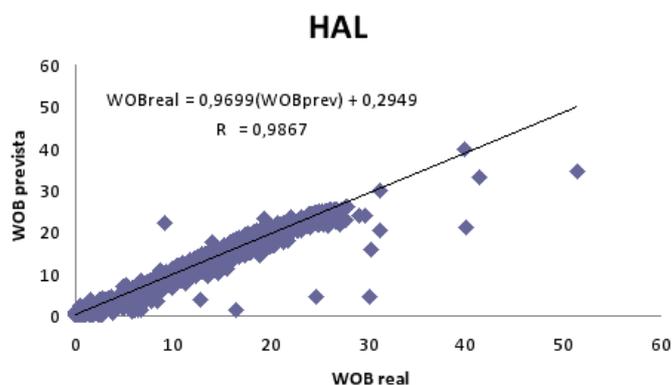


Figura B.30. WOB real versus WOB prevista – rede inversa para Halita

As Figuras B.31 e B.32 mostram, respectivamente, os gráficos de RPM real *versus* RPM prevista e WOB real *versus* WOB previsto para a margá. A rede prevê muito bem o peso sobre broca, mas a predição de rotação de coluna é pobre.

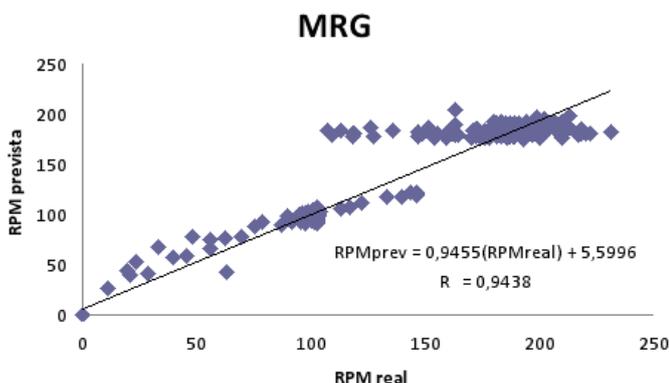


Figura B.31. RPM real versus RPM prevista – rede inversa para Margá

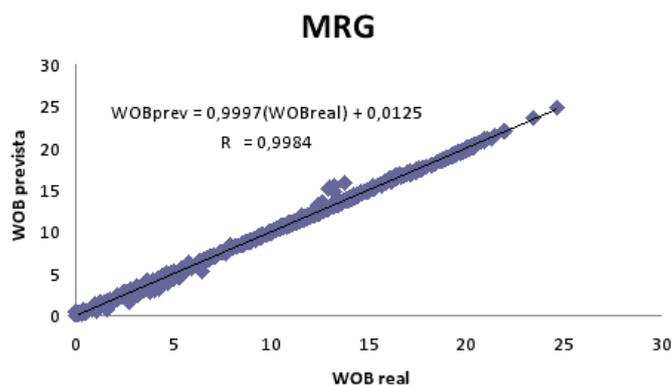


Figura B.32. WOB real versus WOB prevista – rede inversa para Margá

As Figuras B.33 e B.34 mostram, respectivamente, os gráficos de RPM real *versus* RPM prevista e WOB real *versus* WOB previsto para o silito. A rede prevê muito bem o peso sobre broca, mas a predição de rotação de coluna é bastante pobre.

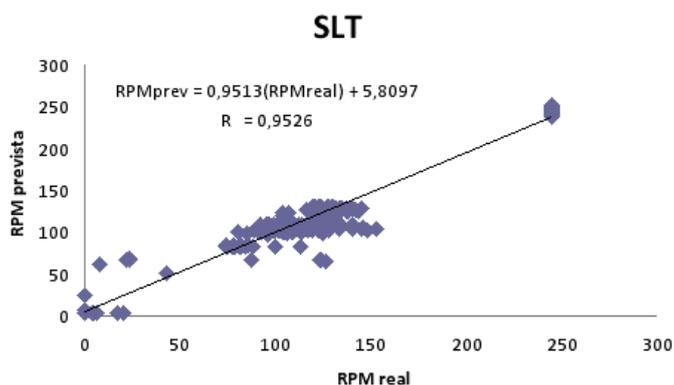


Figura B.33. RPM real versus RPM prevista – rede inversa para Siltito

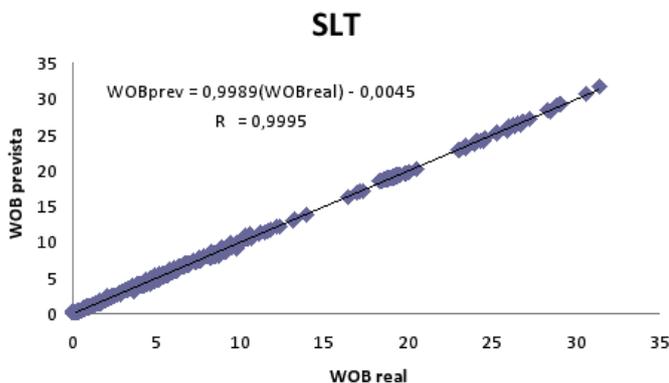


Figura B.34. WOB real versus WOB prevista – rede inversa para Siltito

Finalmente, as Figuras B.35 e B.36 mostram, respectivamente, os gráficos de RPM real *versus* RPM prevista e WOB real *versus* WOB previsto para o siltito. A rede prevê muito bem o peso sobre broca, mas a predição de rotação de coluna é bastante pobre.

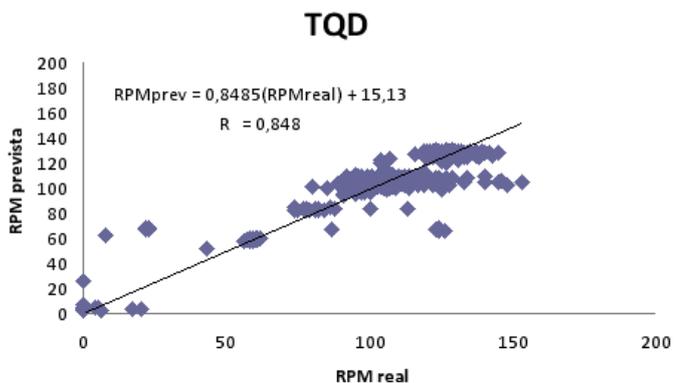


Figura B.35. RPM real versus RPM prevista – rede inversa para Taquidrita

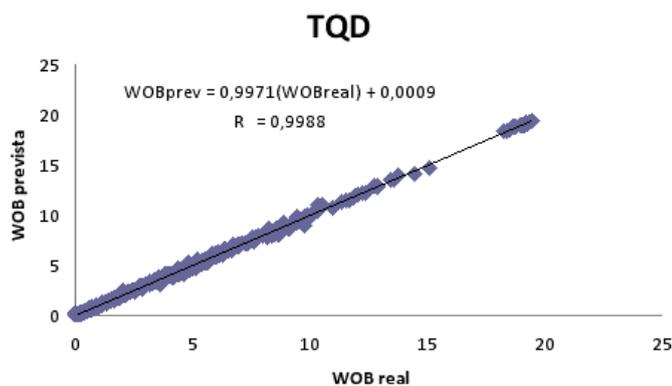


Figura B.36. WOB real versus WOB prevista – rede inversa para Taquidrita

As figuras acima mostram que, de maneira geral, as redes diretas separadas por litologia tiveram bastante sucesso na previsão das taxas de penetração reais. Exceto pela coquina, todos os pontos se alinharam muito bem sobre a (ou muito próximos à) bissetriz, o que indica uma boa previsão. Além disso, os parâmetros mostrados na Tabela 4.7 confirmam a boa capacidade de predição deste tipo de arquitetura.

Quanto às redes inversas separadas por litologia, observa-se uma boa capacidade de predição do peso sobre broca. Mas o mesmo não ocorre com a rotação de broca. Nenhuma das redes foi capaz de prever adequadamente este parâmetro. Todos os pontos dos gráficos de RPM prevista *versus* RPM real se situam distante da bissetriz. Alguns gráficos mostram uma nuvem em volta da bissetriz. O gráfico da Figura B.13 é particularmente interessante. Observa-se que para uma única RPM real, a rede prevê diversos valores diferentes. Neste caso, apenas três rotações diferentes foram observadas durante a perfuração: rotação nula, cerca de 85 rpm e cerca de 120 rpm. Evidentemente, as condições da perfuração mudaram ao longo do tempo (profundidade, *overbalance*, etc). A rede não foi capaz de capturar corretamente a influência destas variáveis na ROP e, conseqüentemente, predisse rotações diferentes.

A má predição das rotações de broca é causada pela natureza não unívoca no processo. Como já foi comentado anteriormente, existe uma grande multiplicidade de pares de RPM e WOB para uma mesma ROP. Isso inviabiliza o uso de redes neurais para a previsão de rotação e peso sobre broca, com as entradas adotadas.

Vale ressaltar que a avaliação mostrada na seção 4.3 e neste Apêndice foi feita, em grande parte, com dados usados no próprio treinamento da rede (excetuando-se os dados de teste e seleção, correspondentes a 30% dos dados totais). Para se tirar conclusões mais

acuradas sobre a real capacidade de predição das redes diretas separadas por litologia é ainda necessária uma etapa de validação com dados totalmente inéditos.

APÊNDICE C

Otimização Através das Redes Inversas

Otimização dos dados do poço A com a rede inversa

A Figura C.1 mostra a os gráficos de RPM e o WOB para o poço A ao longo do tempo gerados pela rede inversa única para manter a taxa de penetração em 45 m/h. Ou seja, a Figura C.1 mostra os gráficos dos valores de RPM e WOB necessários ao longo do tempo para manter a taxa de penetração em um valor desejado de 45 m/h, de acordo com o modelo da rede inversa única. As mudanças observadas nos valores ocorrem devido às mudanças nas condições operacionais, tais como aumento da profundidade, mudanças na vazão, mudanças na litologia perfurada, etc.

Porém, como comentado anteriormente, a rede inversa é capaz de prever apenas um par de RPM e WOB e não há garantia nenhuma de que este seja o ponto de menor energia mecânica específica na broca. Além disso, a má capacidade que as redes inversas apresentaram em prever RPM e WOB também levam à falta de garantia de que os valores previstos pela rede geram, de fato, o *setpoint* de ROP desejado.

A Figura C.2 mostra o gráfico de energia específica na broca ao longo do tempo para os parâmetros determinados pela rede e as demais condições operacionais (vazão, profundidade, pressões, etc).

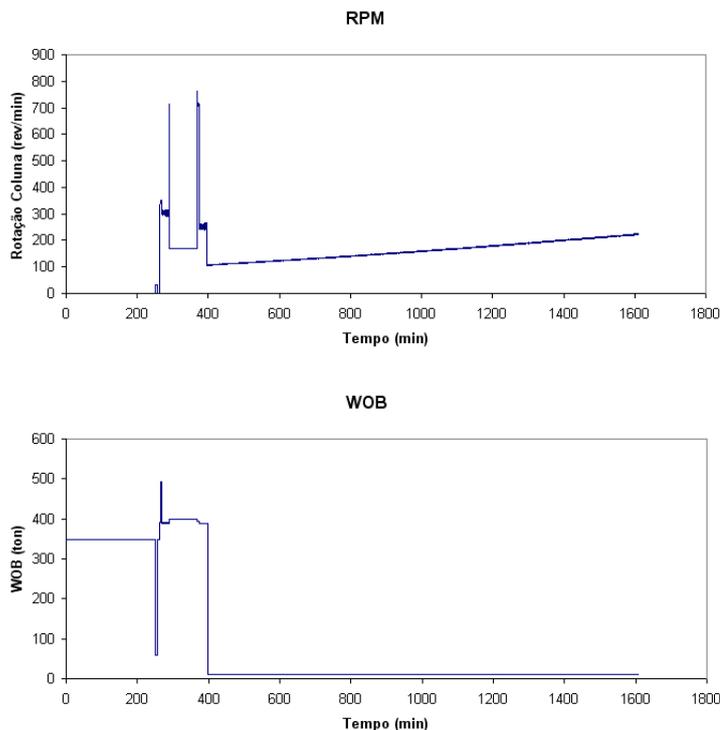


Figura C.1. RPM e WOB ao longo do tempo gerados pela rede inversa única para manter a taxa de penetração em 45 m/h – Poço A

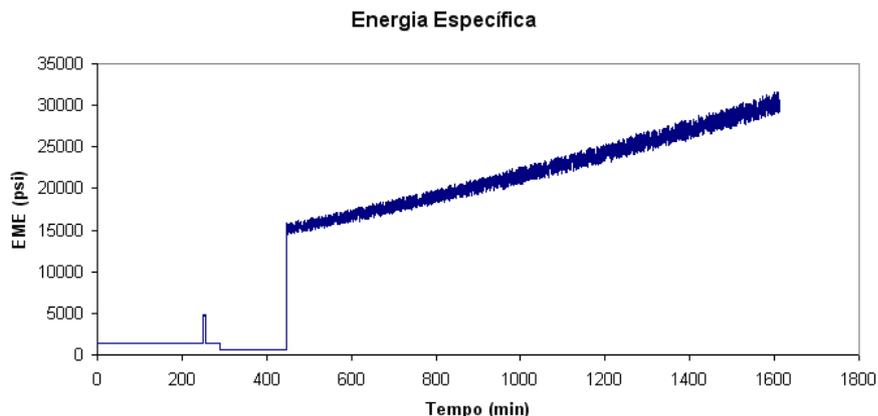


Figura C.2. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela rede inversa única – Poço A

Otimização dos dados do poço B com a rede inversa

A Figura C.3 mostra a os gráficos de RPM e o WOB para o poço B ao longo do tempo gerados pela rede inversa única para manter a taxa de penetração em 45 m/h. A Figura C.4 mostra o gráfico de energia específica na broca ao longo do tempo para os parâmetros determinados pela rede e as demais condições operacionais no poço B.

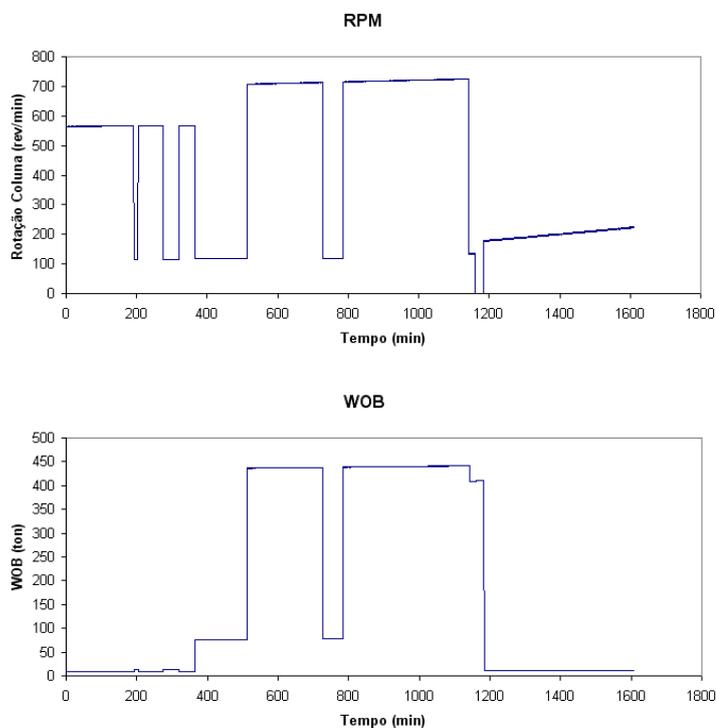


Figura C.3. RPM e WOB ao longo do tempo gerados pela rede inversa única para manter a taxa de penetração em 45 m/h – Poço B

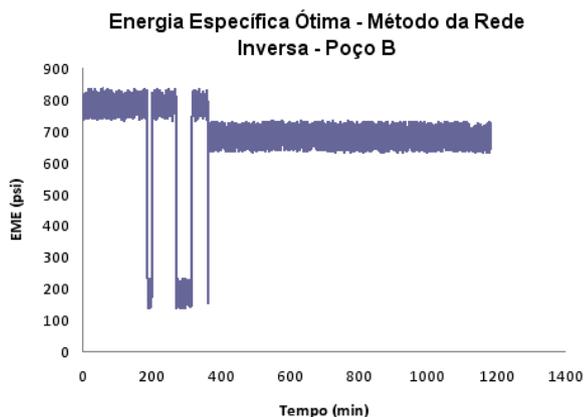


Figura C.4. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela rede inversa única – Poço B

Otimização dos dados do poço C com a rede inversa

A Figura C.5 mostra a os gráficos de RPM e o WOB para o poço C ao longo do tempo gerados pela rede inversa única para manter a taxa de penetração em 45 m/h. A Figura C.6 mostra o gráfico de energia específica na broca ao longo do tempo para os parâmetros determinados pela rede e as demais condições operacionais.

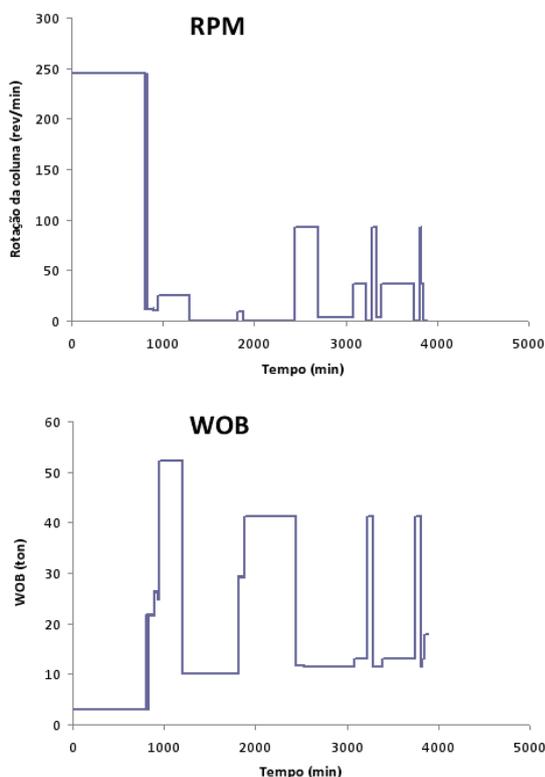


Figura C.5. RPM e WOB ao longo do tempo gerados pela rede inversa única para manter a taxa de penetração em 45 m/h – Poço C

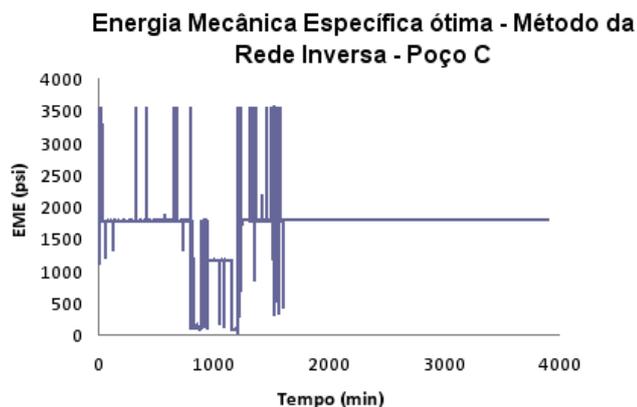


Figura C.6. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela rede inversa única – Poço C

Otimização dos dados do poço D com a rede inversa

A Figura C.7 mostra a os gráficos de RPM e o WOB determinados pela rede inversa para uma ROP de *setpoint* de 45 m/h para o poço D. Os valores são mostrados ao longo do tempo. A Figura C.8 mostra o gráfico de energia específica na broca calculada, ao longo do tempo, para os valores de RPM e WOB determinados pela rede e as demais condições operacionais.

Note que a energia específica apresenta um comportamento extremamente errático. Isso acontece porque os valores de RPM e WOB previsto pela rede inversa são, também, erráticos.

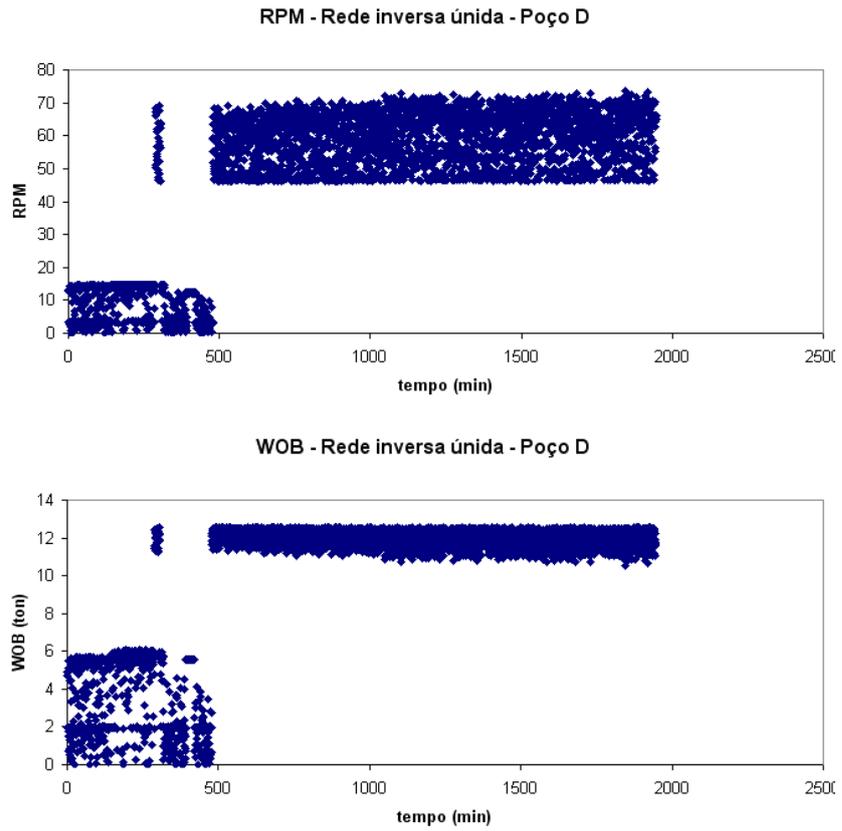


Figura C.7. RPM e WOB ao longo do tempo gerados pela rede inversa única para manter a taxa de penetração em 45 m/h – Poço D

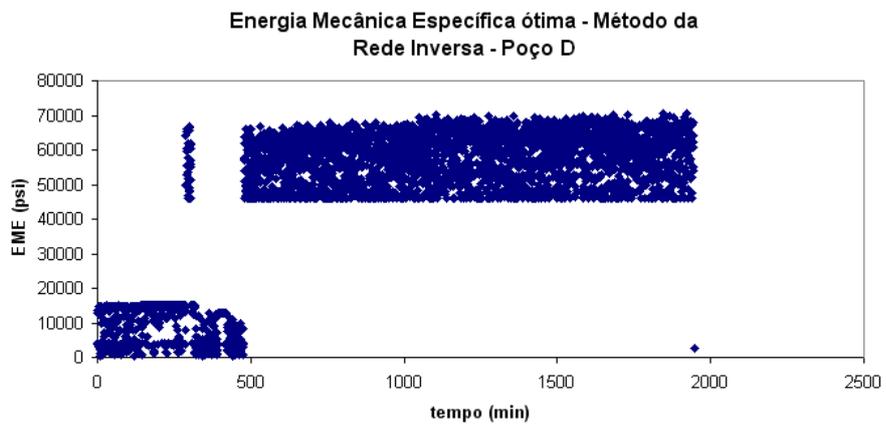


Figura C.8. Energia mecânica específica na broca ao longo do tempo para manter a taxa em 45 m/h, calculada segundo os parâmetros fornecidos pela rede inversa - Poço D