

LUIS FERNANDO POZAS

**PREDIÇÃO DO DESGASTE DE BROCAS PARA
PERFURAÇÃO DE POÇOS DE PETRÓLEO
UTILIZANDO REDES NEURONAIS**

**FLORIANÓPOLIS
2003**



**UNIVERSIDADE FEDERAL DE SANTA CATARINA
CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**PREDIÇÃO DO DESGASTE DE BROCAS PARA
PERFURAÇÃO DE POÇOS DE PETRÓLEO
UTILIZANDO REDÊS NEURONAIS**

Dissertação submetida à
Universidade Federal de Santa Catarina
como parte dos requisitos para a
obtenção do grau de Mestre em Engenharia Elétrica.

LUIS FERNANDO POZAS

Florianópolis, junho de 2003.

PREDIÇÃO DO DESGASTE DE BROCAS PARA PERFURAÇÃO DE POÇOS DE PETRÓLEO UTILIZANDO REDES NEURONAIS

Luis Fernando Pozas

‘Esta Dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia Elétrica, Área de Concentração em *Controle, Automação e Informática Industrial*, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina.’

Prof. Dr. Guilherme Bittencourt
Orientador

Edson Roberto de Pieri
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica

Banca Examinadora:

Guilherme Bittencourt
Presidente

Marcelo Ricardo Stemmer

Mauro Roisenberg

Ubirajara Franco Moreno

*À minha família pelo apoio e presença em todos os momentos difíceis e à Consciência Cósmica
pelas orientações e momentos de inspiração...*

AGRADECIMENTOS

O autor agradece o apoio financeiro da Agência Nacional do Petróleo - ANP, e da Financiadora de Estudos e Projetos - FINEP, por meio do Programa de Recursos Humanos da ANP para o Setor Petróleo e Gás - PRH-34-ANP/MCT.

Gostaria de agradecer também a todas as pessoas que de uma forma ou de outra contribuíram para a conclusão deste trabalho, em especial ao amigo Agostinho Plucenio pelas discussões entusiasmadas e pelas dicas sempre oportunas, aos amigos do LCMI com quem compartilhei muitas alegrias e à minha família, pois sem ela nada disso teria sido possível.

Resumo da Dissertação apresentada à UFSC como parte dos requisitos necessários para obtenção do grau de Mestre em Engenharia Elétrica.

PREDIÇÃO DO DESGASTE DE BROCAS PARA PERFURAÇÃO DE POÇOS DE PETRÓLEO UTILIZANDO REDES NEURONAIAS

Luis Fernando Pozas

Junho/2003

Orientador: Prof. Dr. Guilherme Bittencourt

Área de Concentração: Controle, Automação e Informática Industrial

Palavras-chave: Petróleo; Perfuração de poços; Brocas; Redes Neuronaais; Simulador de perfuração;

Número de Páginas: xiv + 86

A operação de perfuração de poços é a segunda fase na busca do petróleo e se dá em locais previamente determinados por pesquisas geológicas e geofísicas. Ela consiste basicamente na manobra de uma sonda de perfuração por um técnico altamente especializado, o sondador. A sonda por sua vez possui em sua extremidade inferior uma broca, que é a responsável por abrir caminho na rocha seja por trituração, por acunhamento seguido de arrancamento ou por raspagem. O desgaste da broca se dá em função de diversos fatores como velocidade de rotação, taxa de penetração, tipo de formação sendo perfurada, etc.

Por outro lado, sabe-se que as redes neuronaais são ótimas ferramentas de representação de conhecimento e são capazes de lidar com sistemas não-lineares possuindo a capacidade de prever a evolução de um dado modelo matemático. Assim, propõe-se o desenvolvimento de um sistema baseado em redes neuronaais, que seja capaz de atuar em conjunto com o sondador indicando o nível de desgaste da broca durante as operações de perfuração.

Abstract of Dissertation presented to UFSC as a partial fulfillment of the requirements for the degree of Master in Electrical Engineering.

DRILL BIT WEAR ANALYSIS WITH THE AID OF NEURAL NETWORKS

Luis Fernando Pozas

June/2003

Advisor: Prof. Dr. Guilherme Bittencourt

Area of Concentration: Control, Automation and Industrial Computing

Key words: Oil; Drilling wells; Drill Bits; Neural Networks; Drilling Well Simulator;

Number of Pages: xiv + 86

Drilling operations take place after the exploration operations chooses the region to begin the search for oil. Basically it consists in driving the drill stem downward the hole by the expert driller, which tries to do it as fast and safe as possible. There is a drill bit attached to the lower extremity of the drill stem which is responsible for digging the hole. Drill bit wear is affected by factors such as rotation speed, rate of penetration, rock properties, etc.

On the other hand, it is a well-established fact that neural networks have a very good performance in the execution of the following tasks: knowledge representation and non-linear systems modeling. The proposal of this work is to develop a neural network based system that reports the bit wear to the expert driller during the drilling operation.

Sumário

| | | |
|----------|---|-----------|
| 1 | Introdução | 1 |
| 2 | Perfuração de poços | 4 |
| 2.1 | O Petróleo no mundo | 4 |
| 2.2 | Perfuração de poços | 5 |
| 2.2.1 | Equipamentos da sonda de perfuração | 6 |
| 2.2.2 | Colunas de perfuração | 13 |
| 2.2.3 | Brocas | 14 |
| 2.2.4 | Fluidos de perfuração | 16 |
| 2.2.5 | Operações normais de perfuração | 17 |
| 2.2.6 | Operações especiais de perfuração | 18 |
| 3 | Redes Neurais | 19 |
| 3.1 | Introdução | 19 |
| 3.1.1 | O que são Redes Neurais? | 19 |
| 3.1.2 | Benefícios das Redes Neurais | 20 |
| 3.2 | Modelo Matemático de Neurônios | 22 |
| 3.2.1 | Tipos de função de ativação | 23 |
| 3.3 | Arquiteturas de Redes Neurais | 24 |
| 3.4 | Aprendizagem | 25 |

| | | |
|----------|--|-----------|
| 3.4.1 | Algoritmos de Aprendizado | 25 |
| 3.4.2 | Paradigmas de aprendizado | 27 |
| 3.4.3 | Tarefas Básicas das Redes Neurais | 29 |
| 4 | Aplicação de redes neurais na previsão do desgaste de uma broca | 31 |
| 4.1 | Definição do problema | 31 |
| 4.2 | Obtenção de dados | 31 |
| 4.2.1 | Obtenção dos dados de treinamento | 32 |
| 4.2.2 | Obtenção dos dados para avaliação da taxa de acerto | 34 |
| 4.2.3 | Obtenção dos dados para avaliação da capacidade de generalização | 34 |
| 4.3 | Treinamento das redes | 35 |
| 4.3.1 | Modelagem do problema | 35 |
| 4.3.2 | Algoritmo de treinamento utilizado | 37 |
| 4.3.3 | Paradigma de aprendizado | 37 |
| 4.4 | Comparação dos desempenhos | 38 |
| 4.5 | Litologia Composta | 38 |
| 5 | Resultados Experimentais | 40 |
| 5.1 | Litologia <i>HardSand</i> | 40 |
| 5.1.1 | Redes recorrentes | 40 |
| 5.2 | Litologia <i>Shale</i> | 47 |
| 5.2.1 | Redes recorrentes | 47 |
| 5.3 | Análise dos resultados | 54 |
| 5.3.1 | Litologia <i>Hard Sand</i> | 54 |
| 5.3.2 | Litologia <i>Shale</i> | 55 |
| 5.4 | Litologia Composta | 56 |

| | | |
|----------|-------------------|-----------|
| 6 | Conclusões | 59 |
| A | Tabelas | 61 |
| B | Gráficos | 77 |

Lista de Figuras

| | | |
|-----|---|----|
| 2.1 | Torre de perfuração | 6 |
| 2.2 | Estaleiro da sonda | 7 |
| 2.3 | Sistema bloco-catarina | 9 |
| 2.4 | <i>Mud Shaker</i> | 10 |
| 2.5 | <i>BOP - Blow-Out Preventer</i> | 12 |
| 2.6 | Comandos | 13 |
| 2.7 | Broca do tipo PDC | 14 |
| 2.8 | Broca do tipo tricônica | 15 |
| 3.1 | Diagrama em blocos de um neurônio. | 22 |
| 3.2 | Função Heaviside | 23 |
| 3.3 | Função Piecewise | 23 |
| 3.4 | Função Sigmoid | 24 |
| 3.5 | Realimentação no processo de aprendizagem | 27 |
| 3.6 | Diagrama de blocos de aprendizagem com supervisor | 27 |
| 3.7 | Aprendizado por reforço | 28 |
| 3.8 | Sistema de Identificação | 30 |
| 3.9 | Identificador de Função Inversa | 30 |
| 4.1 | Arquitetura geral das redes recorrentes | 36 |

| | | |
|------|--|----|
| 5.1 | Evolução do erro de aprendizado e de generalização da Rede7-2Plin | 42 |
| 5.2 | Evolução do erro de aprendizado e de generalização da Rede7-10-2PlinPlin | 44 |
| 5.3 | Evolução do erro de aprendizado das redes 7-10-2PlinPlin, 7-12-2PlinPlin e 7-20-2PlinPlin | 44 |
| 5.4 | Evolução do erro de generalização das redes 7-10-2PlinPlin, 7-12-2PlinPlin e 7-20-2PlinPlin | 45 |
| 5.5 | Evolução do erro de aprendizado e de generalização da Rede7-10-10-2PlinPlinPlin | 47 |
| 5.6 | Evolução do erro de aprendizado e de generalização da Rede7-2Plin | 49 |
| 5.7 | Evolução do erro de aprendizado e de generalização da Rede7-10-2PlinPlin | 51 |
| 5.8 | Evolução do erro de aprendizado das redes 7-10-2PlinPlin, 7-12-2PlinPlin e 7-20-2PlinPlin | 51 |
| 5.9 | Evolução do erro de generalização das redes 7-10-2PlinPlin, 7-12-2PlinPlin e 7-20-2PlinPlin | 52 |
| 5.10 | Evolução do erro de aprendizado e de generalização da Rede7-10-10-2PlinPlinPlin | 54 |
| 5.11 | Comparação entre o desgaste do dente da broca obtido pela Rede8-20-2PlinPlin e obtido diretamente no simulador | 57 |
| 5.12 | Comparação entre o desgaste do rolamento da broca obtido pela Rede8-20-2PlinPlin e obtido diretamente no simulador | 58 |
| B.1 | Evolução do erro de aprendizado e de generalização da Rede7-2Tsig | 77 |
| B.2 | Evolução do erro de aprendizado e de generalização da Rede7-2Lsig | 77 |
| B.3 | Evolução do erro de aprendizado e de generalização da Rede7-10-2TsigPlin | 78 |
| B.4 | Evolução do erro de aprendizado e de generalização da Rede7-10-2LsigPlin | 78 |
| B.5 | Evolução do erro de aprendizado e de generalização da Rede7-10-10-2TsigPlinPlin | 78 |
| B.6 | Evolução do erro de aprendizado e de generalização da Rede7-10-10-2PlinTsigPlin | 79 |
| B.7 | Evolução do erro de aprendizado e de generalização da Rede7-10-10-2PlinPlinTsig | 79 |
| B.8 | Evolução do erro de aprendizado e de generalização da Rede7-2Tsig | 80 |
| B.9 | Evolução do erro de aprendizado e de generalização da Rede7-2Lsig | 80 |

| | | |
|------|--|----|
| B.10 | Evolução do erro de aprendizado e de generalização da Rede7-10-2TsigPlin | 81 |
| B.11 | Evolução do erro de aprendizado e de generalização da Rede7-10-2LsigPlin | 81 |
| B.12 | Evolução do erro de aprendizado e de generalização da Rede7-10-10-2TsigPlinPlin . | 81 |
| B.13 | Evolução do erro de aprendizado e de generalização da Rede7-10-10-2PlinTsigPlin . | 82 |
| B.14 | Evolução do erro de aprendizado e de generalização da Rede7-10-10-2PlinPlinTsig . | 82 |

Lista de Tabelas

| | | |
|-----|---|----|
| 4.1 | Configuração dos parâmetros utilizados em cada perfuração | 33 |
| 4.2 | Transformação de valores da escala para valores numéricos | 33 |
| 4.3 | Configuração utilizada para verificar o aprendizado da rede | 34 |
| 4.4 | Configuração utilizada para verificar a capacidade de generalização da rede | 35 |
| 4.5 | Configuração utilizada na perfuração de formações rochosas compostas | 39 |
| 5.1 | Evolução do erro de aprendizado e erro de generalização da Rede 7-2Plin | 41 |
| 5.2 | Evolução do erro de aprendizado e erro de generalização da Rede 7-10-2PlinPlin | 43 |
| 5.3 | Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2PlinPlinPlin | 46 |
| 5.4 | Evolução do erro de aprendizado e erro de generalização da Rede 7-2Plin | 48 |
| 5.5 | Evolução do erro de aprendizado e erro de generalização da Rede 7-10-2PlinPlin | 50 |
| 5.6 | Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2PlinPlinPlin | 53 |
| A.1 | Evolução do erro de aprendizado e erro de generalização da Rede 7-2TSig | 62 |
| A.2 | Evolução do erro de aprendizado e erro de generalização da Rede 7-2LSig | 63 |
| A.3 | Evolução do erro de aprendizado e erro de generalização da Rede 7-10-2TsigPlin | 64 |
| A.4 | Evolução do erro de aprendizado e erro de generalização da Rede 7-10-2LsigPlin | 65 |
| A.5 | Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2TsigPlinPlin | 66 |
| A.6 | Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2PlinTsigPlin | 67 |
| A.7 | Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2PlinPlinTsig | 68 |

| | | |
|------|---|----|
| A.8 | Evolução do erro de aprendizado e erro de generalização da Rede 7-2Tsig | 70 |
| A.9 | Evolução do erro de aprendizado e erro de generalização da Rede 7-2Lsig | 71 |
| A.10 | Evolução do erro de aprendizado e erro de generalização da Rede 7-10-2TsigPlin . . . | 72 |
| A.11 | Evolução do erro de aprendizado e erro de generalização da Rede 7-10-2LsigPlin . . . | 73 |
| A.12 | Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2TsigPlinPlin | 74 |
| A.13 | Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2PlinTsigPlin | 75 |
| A.14 | Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2PlinPlinTsig | 76 |

Capítulo 1

Introdução

As pesquisas Geológicas e Geofísicas são a primeira fase na busca do petróleo. Com os resultados obtidos destas pesquisas, determinam-se as regiões mais promissoras e a segunda fase tem início. A segunda fase na busca do petróleo consiste basicamente na perfuração de um poço mediante o uso de uma sonda de perfuração. Geralmente, esta atividade é realizada por empresas terceirizadas que cobram por seus serviços a quantia de US\$200.000,00 - custo diário médio de sondas de perfuração marítimas para águas profundas.

A sonda é composta por uma torre, que serve como base de apoio e sustentação, e pela coluna de perfuração que se apóia na torre. A coluna é formada por vários tubos conectados entre si. Na extremidade inferior da coluna encontra-se a broca, que abre caminho nas camadas subterrâneas seja por ação de trituração, acunhamento seguido de arrancamento, ou raspagem, e na extremidade superior estão conectados os equipamentos que têm a função de transmitir torque à coluna e de imprimir peso sobre a broca. É nesta extremidade também que há a injeção do fluido de perfuração. O fluido é um dos elementos de maior importância na atividade de perfuração pois dele dependem a limpeza das brocas, a retirada dos cascalhos do fundo do poço, a manutenção de uma pressão hidrostática ideal no fundo do poço e o estudo geológico da rocha que está sendo perfurada.

A sonda de perfuração é manobrada por um técnico altamente especializado conhecido como sondador (ou expert driller), que através do controle de variáveis como o peso sobre a broca, a vazão e a pressão do fluido de perfuração, o torque aplicado, a velocidade de rotação, e outras, tenta garantir que a perfuração se dê da maneira mais econômica e segura possível. Para tanto, um grande número de dispositivos indicadores e registradores, o sistema de monitoração, o auxilia nesta tarefa.

Por outro lado, sabe-se que as redes neuronais são ótimas ferramentas de representação de conhecimento, são capazes de lidar com sistemas não-lineares e possuem capacidade de prever a ocorrência de eventos com uma certa antecedência. Justamente por estas características elas têm sido bastante utilizadas no setor de petróleo & gás em pesquisas como análise da evolução de poços [9], pesquisas

geológicas [10] e análise de desgaste de brocas [11]. E, ao contrário dos métodos analíticos tradicionais aonde um modelo matemático do problema precisa ser desenvolvido, as redes neurais exigem apenas a apresentação de pares entrada/saída do sistema em questão durante a fase de aprendizado para que estejam aptas a realizar as tarefas para as quais foram projetadas.

Foi feita uma visita técnica à plataforma SS48 no campo de Coral, aonde todo o processo de perfuração de poços foi observado *in loco*. Durante a visita os sondadores foram entrevistados, e assim, notou-se que um dos maiores empecilhos ao bom andamento da perfuração dos poços é a falta de informações sobre o estado da broca. Em um evento ocorrido durante a visita, a coluna foi retirada totalmente do poço e foi observado que havia um problema com um jato da broca. Se o sondador soubesse que este era o problema talvez não tivesse sido necessário retirar toda a coluna do poço e, portanto, tempo e dinheiro seriam economizados.

Atualmente, os modelos matemáticos que descrevem o desgaste de brocas são não-lineares e extremamente complexos. Alguns trabalhos têm sido desenvolvidos em torno do assunto como pode ser observado em [28], [29], [30], [31], [32], [33], [34], [35], [36], [37], [38], [39].

Assim, raciocinando em torno dos fatos observados e comentados, surgiu a motivação do presente trabalho. O objetivo específico do trabalho é observar o desempenho de algumas configurações de redes neurais na previsão de desgaste de brocas em perfurações de formações rochosas uniformes. Uma vez avaliadas, será necessário fazer a validação das mesmas através de ensaios de campo. Posteriormente, estas redes poderão ser integradas em um equipamento capaz de prever o desgaste de brocas em formações rochosas compostas.

Não houve acesso a dados de perfuração de poços reais, uma vez que as empresas do ramo classificam estas informações como sendo altamente confidenciais. Isto levou à necessidade de obter-se um simulador de perfuração de poços.

Na fase de treinamento da rede, foram utilizados dados provenientes do simulador de perfuração de poços. Como já foi dito, durante a perfuração o sondador não possui nenhuma informação sobre o estado de desgaste da broca, informação esta que somente pode ser obtida com a retirada total da coluna do poço e observação direta da peça. A disponibilidade desta informação poderia auxiliar o sondador na diagnose de algum evento inesperado, na manobra da sonda ou ainda na otimização da perfuração.

O presente trabalho possibilitou a publicação no “2o. Congresso Brasileiro de Petróleo & Gás”, ocorrido no ano de 2003 na cidade do Rio de Janeiro, e também a apresentação no “SPE - South American and Caribbean Student Paper Contest”, que aconteceu em 2003 na cidade de Macaé.

O presente trabalho se organizará da seguinte maneira: No capítulo 2 uma breve introdução à teoria de engenharia de perfuração de poços será feita. No capítulo 3 será visto um pouco de teoria de Redes Neurais, em particular, a teoria sobre as Redes *Feed-Forward Back-Propagation*, utilizadas

no presente trabalho. No capítulo 4 será feita a descrição do problema, aonde será descrito a metodologia aqui proposta. No capítulo 5 serão apresentados os resultados experimentais e no capítulo 6 a conclusão sobre os resultados obtidos no trabalho.

Capítulo 2

Perfuração de poços

Neste capítulo veremos um breve resumo sobre Engenharia de Perfuração de Poços.

2.1 O Petróleo no mundo

De acordo com [27], o registro da participação do petróleo na vida do homem remonta à Antiguidade. Na Babilônia os tijolos eram assentados com asfalto e o betume era largamente utilizado pelos fenícios na calafetação de embarcações. Os egípcios também o utilizaram: para pavimentar estradas, embalsamar os mortos e na construção das pirâmides. Gregos e romanos o utilizaram ainda para fins bélicos. Enfim, desde sempre, este composto já era utilizado com diversas finalidades.

Naquela época, porém, ele era obtido apenas em exsudações naturais. De fato, o início e a sustentação do processo de busca datam de 1859, quando foi iniciada a exploração comercial nos Estados Unidos logo após a descoberta de um poço de 21 metros de profundidade, que produzia apenas 2 m³/dia de óleo, perfurado com um sistema de percussão movido a vapor. Descobriu-se que a destilação do petróleo resultava em produtos que substituíam com grande margem de lucro o querosene obtido a partir do carvão e o óleo de baleia, utilizados para iluminação. Estes fatos marcam o início da era do petróleo. Posteriormente, com a invenção dos motores a gasolina e a diesel, estes derivados ganham importância e adicionam lucros expressivos à atividade.

O método de percussão começou a ser substituído no início do século XX, com o desenvolvimento do processo rotativo de perfuração. O aumento da qualidade do aço, os novos projetos de broca, as novas técnicas de perfuração, e outras inovações técnicas possibilitaram a perfuração de poços com mais de 10.000 metros de profundidade.

A busca do petróleo levou a importantes descobertas nos Estados Unidos, Argentina, Venezuela, Trinidad, Borneu e Oriente Médio. Até 1945 o maior produtor de petróleo do mundo eram os Estados

Unidos, cenário que se modifica após a Segunda Guerra Mundial com a afirmação de um novo pólo produtor mundial no Oriente Médio. Intensificam-se também atividades exploratórias e incursões no mar.

A década de 60 registra a abundância do petróleo disponível no mundo, o que, aliado aos baixos preços praticados pelo mercado, estimula o consumo desenfreado. É durante esta década também que a exploração de petróleo e gás se mostra bastante produtiva no Oriente Médio e na então União Soviética.

A década seguinte foi marcada por brutais elevações nos preços do petróleo, tornando econômicas grandes descobertas no Mar do Norte e Golfo do México. Outras grandes descobertas ocorrem em países do terceiro mundo e em países comunistas, enquanto as grandes reservas de petróleo dos Estados Unidos se encontram esgotadas. Acontecem, então, os grandes avanços tecnológicos no aprimoramento de dispositivos de aquisição, processamento e interpretação de dados sísmicos, como também nos processos de recuperação de petróleo das jazidas já conhecidas.

Nos anos 80 e 90, os avanços tecnológicos reduzem os custos de exploração e de produção, criando um novo ciclo econômico para a indústria petrolífera.

Assim, ao longo do tempo, o petróleo foi se impondo como fonte de energia. Hoje em dia, além da utilização de seus derivados, centenas de novos compostos são produzidos, muitos deles diariamente utilizados, como plásticos, borrachas sintéticas, tintas, corantes, adesivos, solventes, detergentes, produtos farmacêuticos, cosméticos, etc. Com isso, o petróleo, além de produzir combustível, passou a ser imprescindível às facilidades e comodidades da vida moderna.

2.2 Perfuração de poços

Ainda de acordo com [27], a perfuração de um poço de petróleo é realizada através de uma sonda. Na perfuração rotativa, as rochas são perfuradas pela ação da rotação e peso aplicados a uma broca existente na extremidade de uma coluna de perfuração, a qual consiste basicamente de comandos (tubos de paredes espessas) e tubos de perfuração (tubos de paredes finas). Os fragmentos da rocha são removidos continuamente através de um fluido de perfuração. O fluido é injetado por bombas para o interior da coluna de perfuração através da cabeça de injeção, ou swivel, e retorna à superfície através do espaço anular entre a coluna e as paredes do poço. Ao atingir determinada profundidade, a coluna de perfuração é retirada do poço e uma coluna de revestimento de aço, de diâmetro inferior ao da broca, é descida no poço. O anular entre os tubos do revestimento e as paredes do poço é cimentado com a finalidade de isolar as rochas atravessadas, permitindo então o avanço da perfuração com segurança. Após a operação de cimentação, a coluna de perfuração é novamente descida no poço, tendo na sua extremidade uma nova broca, de diâmetro menor do que o do revestimento, para o

prosseguimento da perfuração. Portanto, um poço é perfurado em diversas fases, caracterizadas pelos diferentes diâmetros das brocas.

2.2.1 Equipamentos da sonda de perfuração

Uma sonda é composta de sistemas, cada qual sendo um conjunto de equipamentos responsáveis por determinada função na perfuração de poços. Veremos a seguir os principais sistemas existentes e os equipamentos constituintes.

2.2.1.1 Sistema de sustentação de cargas

A carga aqui referida corresponde ao peso da coluna de perfuração, ou do revestimento, que é transferido para o mastro ou torre, que, por sua vez, a descarrega para a subestrutura e esta para a fundação ou base. Estes são os equipamentos constituintes deste sistema.

- Torre ou Mastro

A torre, ou mastro, é uma estrutura de aço especial, de forma piramidal, de modo a prover um espaçamento vertical livre acima da plataforma de trabalho para permitir a execução das manobras, que são as operações com a coluna para retirar a broca até a superfície. Uma torre é constituída de um grande número de peças, que são montadas uma a uma. Na figura 2.1, pode-se ver uma torre de perfuração.

Já o mastro é uma estrutura treliçada, subdividida em três ou quatro seções que são montadas na posição horizontal e elevadas para a vertical. Por ser de montagem mais fácil e rápida, o mastro tem sido preferido em perfurações terrestres.



Figura 2.1: Torre de perfuração

- Subestruturas

A subestrutura é constituída de vigas de aço especial montadas sobre a fundação de modo a criar um espaço de trabalho aonde são instalados os equipamentos de segurança do poço. A fundação é uma estrutura rígida construída em concreto, aço ou madeira que suporta com segurança as deflexões, vibrações e deslocamentos provocados pela sonda.

- Estaleiros

O estaleiro é o local aonde são dispostas todas as tubulações (comandos, tubos de perfuração, revestimentos, etc.) de maneira a facilitar o seu manuseio e transporte. Pode-se ver na figura 2.2 um estaleiro típico.



Figura 2.2: Estaleiro da sonda

2.2.1.2 Sistema de geração e transmissão de energia

A energia necessária para o acionamento dos equipamentos de uma sonda de perfuração geralmente é fornecida por motores diesel, mas em sondas aonde exista produção de gás é comum a utilização de turbinas a gás para gerar energia para toda a plataforma.

Uma característica importante dos equipamentos de uma sonda, e que afeta o processo de transmissão de energia, é a necessidade deles operarem com velocidade e torque variáveis. Dependendo do modo de transmissão utilizado as sondas são classificadas como sondas mecânicas ou sondas diesel-elétricas.

- Sondas Mecânicas

A energia gerada nos motores diesel é levada a uma transmissão principal através de acoplamentos hidráulicos e embreagens. A transmissão é constituída de diversos eixos, rodas dentadas e correntes que distribuem a energia a todos os sistemas da sonda.

As embreagens permitem que os motores sejam acoplados ou desacoplados propiciando maior eficiência na utilização dos motores diesel.

- Sondas Diesel-Elétricas

Nestas sondas geralmente a geração é feita em corrente alternada e a utilização em corrente contínua (AC/DC).

Os motores a diesel, ou as turbinas a gás, acionam um barramento de 600volts, que também pode ser alimentado pela rede pública quando esta estiver disponível. Os equipamentos da sonda que utilizam corrente contínua recebem a energia de pontes retificadoras, que por sua vez estão conectadas ao barramento; os equipamentos que utilizam corrente alternada recebem a energia de um transformador que também está conectado ao barramento. Existe também sondas AC/AC, aonde não há necessidade de utilização de retificadores, mas há a necessidade de controlar a frequência aplicada aos motores.

2.2.1.3 Sistema de movimentação de carga

É o sistema composto por guincho, bloco de coroamento, catarina, cabo de perfuração, gancho e elevador, responsável por dar ao sondador condições de movimentar as colunas de perfuração, de revestimento e outros equipamentos. Há na figura 2.3 a representação de um sistema bloco-catarina.

- Guincho

O guincho é constituído por: tambor principal, tambor auxiliar, freios, molinetes e embreagens. O tambor principal aciona o cabo de perfuração para movimentar as cargas dentro do poço. O freio tem a função de parar ou retardar o movimento de descida de carga no poço, controlando assim o peso aplicado na broca. O tambor auxiliar é utilizado para movimentar equipamentos leves no poço. O molinete é um tipo de embreagem que permite tracionar cabos ou cordas.

- Bloco de coroamento

É um conjunto de 4 a 7 polias montadas em um eixo suportado por dois mancais de deslizamento, localizado na parte superior do mastro, ou torre.

- Catarina e Gancho

A catarina é um conjunto de 3 a 6 polias móveis que fica suspensa pelo cabo de perfuração e possui em sua extremidade inferior uma alça aonde é preso o gancho. O cabo de perfuração passa alternadamente pelas polias do bloco de coroamento e polias da catarina, formando um

sistema com 8 a 12 linhas passadas. O gancho consiste de um corpo cilíndrico com um sistema interno para amortecer os golpes causados pela movimentação das cargas.

- Cabo de perfuração

É um cabo de aço trançado em torno de um núcleo ou alma. O cabo proveniente do carretel é passado e fixado em uma âncora, aonde se encontra um sensor que mede a tensão no cabo. Ele segue então para o sistema bloco-atarina e posteriormente é enrolado e fixado no tambor do guincho.

- Elevador

O elevador é o equipamento utilizado para movimentar elementos tubulares. Tem a forma de um anel bipartido em que as duas partes são ligadas por uma dobradiça resistente, contendo um trinco especial para seu fechamento.

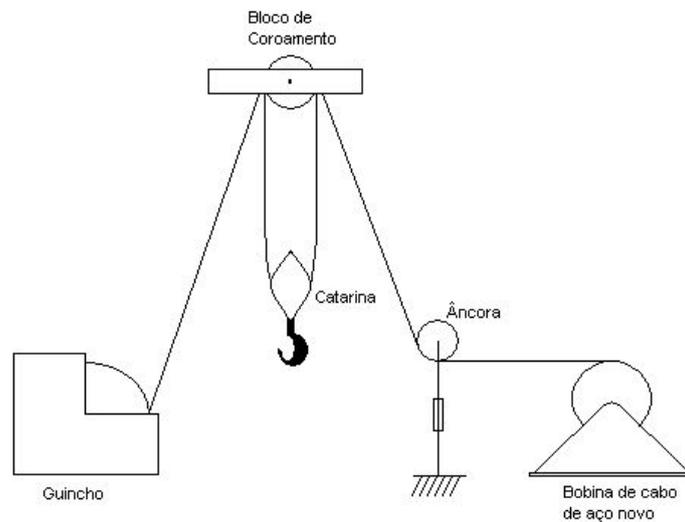


Figura 2.3: Sistema bloco-atarina

2.2.1.4 Sistema de rotação

O sistema de rotação convencional é constituído de equipamentos que promovem ou permitem a livre rotação da coluna de perfuração: mesa rotativa, *kelly* e cabeça de injeção. Geralmente a coluna de perfuração é girada pela mesa de rotação localizada na plataforma da sonda, mas nas sondas equipadas com *top drive* a rotação é transmitida diretamente ao topo da coluna de perfuração por um motor acoplado à catarina. Existe também a possibilidade de se perfurar com um motor de fundo, colocado logo acima da broca, que gera o torque necessário direcionando o fluido de perfuração a uma turbina ou sistema de deslocamento positivo em seu interior.

- Mesa rotativa

Equipamento que transmite rotação à coluna de perfuração e permite o livre deslizamento do *kelly* em seu interior. Em certas operações a mesa rotativa deve suportar o peso da coluna de perfuração.

- *Kelly*

O *kelly* é um comando que transmite a rotação da mesa rotativa à coluna de perfuração através da seção poligonal de seu corpo.

- Cabeça de injeção

É através da cabeça de injeção que o fluido de perfuração é injetado no interior da coluna de perfuração. Este equipamento faz também a interface entre os equipamentos rotativos e os equipamentos estacionários da sonda de perfuração.

2.2.1.5 Sistema de circulação

O fluido de perfuração é bombeado através da coluna de perfuração até a broca, retornando pelo espaço anular até a superfície, trazendo consigo os cascalhos cortados pela broca. Os cascalhos são retirados do fluido pelo *mud shaker*, como pode ser visto na figura 2.4, e levados para análise pelos geólogos. O fluido é então armazenado em tanques aonde recebe um tratamento químico para que fique dentro da especificação exigida pelo projeto do poço. Após o tratamento o fluido fica disponível para ser injetado novamente na coluna. O sistema de circulação é composto por todos os equipamentos que permitem a circulação e o tratamento do fluido.



Figura 2.4: *Mud Shaker*

- Fase de injeção

O fluido é bombeado na coluna de perfuração pelas bombas de lama em direção à broca, até passar ao anular entre o poço e a coluna por orifícios conhecidos como jatos da broca. Durante

a perfuração, as vazões e pressões de bombeio variam com a profundidade e a geometria do poço. É tarefa do sondador ajustar estes parâmetros para que a perfuração se dê da melhor maneira possível.

- Fase de retorno

Esta fase tem início com a saída do fluido de perfuração nos jatos da broca e termina ao chegar no *mud shaker*, percorrendo o espaço anular entre a coluna de perfuração e a parede do poço, ou o revestimento.

- Fase de tratamento

Durante a perfuração, o fluido tem que estar dentro da especificação de determinadas propriedades químicas. Para garantir a qualidade do fluido é necessário que o mesmo seja submetido a constantes análises e, quando for necessário, que passe por um tratamento químico. Basicamente o tratamento consiste em retirar as partículas sólidas e adicionar aditivos químicos para ajustar a acidez, a densidade, etc.

2.2.1.6 Sistema de segurança do poço

É o sistema constituído de todos os equipamentos que possibilitam o fechamento e controle do poço, sendo o *BOP (Blow-Out Preventer)* - um conjunto de válvulas para fechamento do poço - o mais importante deles. Pode-se observar na figura 2.5 um *BOP* típico.

Sempre que houver um kick, ou fluxo indesejável do fluido contido numa formação para dentro do poço, o sistema de segurança deve ser acionado para controlar o poço. Caso contrário, o fluido do poço pode começar a fluir totalmente sem controle, criando uma situação extremamente perigosa aonde podem ocorrer danos aos equipamentos da sonda, acidentes pessoais, perda parcial ou total do reservatório, poluição e danos ao meio ambiente. Os principais equipamentos do sistema de segurança são:

- Cabeça de poço

A cabeça de poço é constituída de diversos equipamentos que permitem a ancoragem e vedação das colunas de revestimento na superfície: A cabeça de revestimento tem a finalidade de sustentar os revestimentos intermediários e de produção, de propiciar vedação e acesso a estes, e de servir de base para a instalação dos demais elementos da cabeça do poço e preventores. O suspensor de revestimento permite a ancoragem do revestimento e a vedação do anular deste revestimento com o corpo da cabeça na qual foi ancorado. O carretel de revestimento é semelhante à cabeça de revestimento, possuindo ainda duas saídas laterais para acesso ao espaço anular e um alojamento para assentamento do suspensor de revestimento. A cabeça de



Figura 2.5: BOP - *Blow-Out Preventer*

produção é também um carretel que possui a capacidade de impedir a passagem de pressões altas. O carretel de perfuração é um equipamento com duas saídas laterais que recebem as linhas de controle do poço: *kill line*, e *choke line*.

- Preventores

Os preventores são os equipamentos de segurança responsáveis por fechar o espaço anular de um poço. Os preventores anulares atuam ao deslocar um pistão dentro de um corpo cilíndrico, comprimindo um elemento de borracha que se ajusta contra a parede da tubulação. Os preventores de gavetas atuam ao deslocar duas gavetas, uma contra a outra, transversalmente ao eixo do poço.

2.2.1.7 Sistema de monitoração

São os equipamentos necessários ao controle da perfuração: manômetros, indicador de peso na broca, indicador de torque, tacômetro, etc. Com a evolução das técnicas de perfuração observou-se que um máximo de eficiência e economia seria atingido quando houvesse uma perfeita combinação entre os vários parâmetros da perfuração. Disto surgiu a necessidade do uso de equipamentos para o registro e controle destes parâmetros. Eles podem ser classificados em indicadores, que apenas indicam o valor do parâmetro em consideração, e registradores, que traçam curvas dos valores medidos.

É neste sistema que se encontra o foco do presente trabalho. Maiores detalhes podem ser encontrados no capítulo 4.

2.2.2 Colunas de perfuração

Para cortar as formações rochosas é necessária a concentração de grande quantidade de energia na broca. A coluna de perfuração é responsável por transferir toda esta energia, em forma de rotação e peso aplicados, à broca no fundo do poço. Os principais componentes da coluna são os comandos, os tubos pesados e os tubos de perfuração.

2.2.2.1 Comandos

Os comandos são elementos tubulares fabricados em aço forjado que têm como função principal fornecer peso à broca e prover rigidez à coluna, permitindo melhor controle da trajetória do poço. A conexão destes elementos é feita por uniões enroscáveis usinadas diretamente no corpo do tubo. Pode-se ver na figura 2.6 alguns exemplos de comandos.



Figura 2.6: Comandos

2.2.2.2 Tubos pesados

São elementos tubulares de aço forjado que têm como função principal promover uma transição de rigidez entre os comandos e os tubos de perfuração, diminuindo a possibilidade de falha por fadiga.

2.2.2.3 Tubos de perfuração

Os tubos de perfuração (*Drill Pipes*) são tubos de aço sem costura, tratados internamente com aplicação de resinas para diminuição do desgaste interno e corrosão.

2.2.3 Brocas

São os equipamentos que promovem a ruptura e desagregação das rochas ou formações rochosas. O estudo das brocas, considerando seu desempenho e economicidade, é um dos fatores importantes na perfuração de poços de petróleo.

2.2.3.1 Brocas sem partes móveis

De acordo com [27], os principais tipos são: integral de lâminas de aço, diamantes naturais e diamantes artificiais (PDC/TSP). As brocas de lâmina de aço foram as primeiras brocas a serem usadas. Têm a característica de perfurar por ação de cisalhamento e possuem jatos que permitem uma boa limpeza de suas lâminas, no entanto, sua estrutura cortante apresenta uma vida útil muito curta o que fez com que praticamente desaparecessem depois do surgimento das brocas de cones.

As brocas de diamantes naturais perfuram pelo efeito de esmerilhamento. No início eram utilizadas para perfurar formações rochosas duras, mas hoje em dia são utilizadas principalmente em operações de testemunhagem ou em perfurações de formações extremamente duras e abrasivas, uma vez que existem brocas recentes menos custosas capazes de perfurar formações duras. As brocas com estrutura cortante de diamantes naturais constam de um grande número de diamantes industrializados fixados numa matriz metálica especial. O tamanho e a quantidade dos diamantes na broca determinam a sua aplicabilidade.

Ao final da década de 70 surgiram as brocas *PDC* (*Polycrystalline Diamond Compact*), cuja estrutura de corte é formada por pastilhas ou compactos, montadas sobre bases cilíndricas, instalada no corpo da broca. A pastilha é composta por uma camada fina de partículas de diamantes aglutinados com cobalto, fixada a outra camada composta de carbureto de tungstênio. Perfura por ação de cisalhamento ao promover um efeito de cunha. Pode-se ver na figura 2.7 uma broca do tipo PDC.



Figura 2.7: Broca do tipo PDC

Foram desenvolvidos também os compactos *TSP* (*Thermally Stable Polycrystalline*) para substituir as brocas PDC em perfurações aonde o calor gerado é mais intenso.

No geral, a inexistência de partes móveis e rolamentos diminui a possibilidade de falhas destas brocas.

2.2.3.2 Brocas com partes móveis

As brocas com partes móveis podem ter de um a quatro cones, sendo as mais utilizadas as brocas tricônicas pela sua eficiência e menor custo inicial em relação às demais. Possuem dois elementos principais: a estrutura cortante e os rolamentos. Pode-se ver na figura 2.8 um exemplo de broca tricônica.



Figura 2.8: Broca do tipo tricônica

- Estrutura cortante

As brocas tricônicas são divididas em brocas dentes de aço, que têm sua estrutura cortante fresada no próprio cone, e brocas de insertos, que têm os insertos de carbureto de tungstênio instalados por processo de interferência em orifícios abertos na superfície do cone. Existem vários formatos de dente e de inserto, cada qual para um tipo de formação. A ação da estrutura cortante das brocas tricônicas envolve a combinação de ações de raspagem, lascamento, esmagamento e erosão por impacto dos jatos de fluido de perfuração. Dependendo das características da broca, um ou outro mecanismo se sobrepõe aos demais.

- Rolamentos

Existem três tipos de rolamentos que equipam as brocas: com roletes e esferas não-selados, com roletes e esferas selados e com mancais de fricção tipo *journal*. Os não-selados são lubrificados pelo próprio fluido de perfuração enquanto nos selados há um sistema interno de lubrificação

que não permite o contato do fluido de perfuração com os rolamentos, aumentando a vida útil da broca. Nas brocas com rolamentos do tipo *journal* os roletes são substituídos por mancais de fricção. São as de maior custo, mas são as mais eficazes e as que apresentam mais baixo índice de falhas.

2.2.4 Fluidos de perfuração

Os fluidos de perfuração são misturas complexas de sólidos, líquidos, produtos químicos e, por vezes, até gases. Podem ser à base de água, à base de óleo e ainda à base de ar. Alguns dos fluidos mais conhecidos são: Bentonita em solução aquosa; Polímero adicionado de Cloreto de potássio em solução aquosa; compostos em solução oleosa, etc.

Os fluidos de perfuração devem ser especificados de forma a garantir uma perfuração rápida e segura. Assim, é desejável que o fluido apresente as seguintes características:

- ✓ ser estável quimicamente;
- ✓ estabilizar as paredes do poço, mecânica e quimicamente;
- ✓ facilitar a separação dos cascalhos na superfície;
- ✓ manter os sólidos em suspensão quando estiver em repouso;
- ✓ aceitar qualquer tratamento, físico e químico;
- ✓ ser bombeável;
- ✓ apresentar baixo grau de corrosão e de abrasão em relação à coluna e demais equipamentos do sistema de circulação;
- ✓ facilitar as interpretações geológicas do material retirado;
- ✓ apresentar custo compatível com a operação;

Basicamente, os fluidos de perfuração possuem as seguintes funções:

- Transportar os cascalhos do fundo do poço para a superfície;
- Exercer pressão hidrostática sobre as formações, de modo a evitar influxos ou perda de fluido;
- Resfriar e lubrificar a coluna de perfuração e a broca;

2.2.5 Operações normais de perfuração

Durante a perfuração de um poço uma série de operações desempenham papéis importantes no processo.

2.2.5.1 Alargamento e Repassamento

O alargamento é a operação em que o poço é reperfurado com uma broca de diâmetro maior do que a utilizada em sua perfuração, já o repassamento é a operação utilizada quando por algum motivo o poço se estreita e faz-se necessário repassar a broca no trecho descalibrado.

2.2.5.2 Conexão, Manobra e Circulação

Quando o topo do *kelly* atinge a mesa rotativa, é necessário acrescentar um novo tubo de perfuração à coluna. Esta operação é chamada de conexão. A operação de retirada e descida da coluna de perfuração para trocar a broca é chamada de manobra. Já a circulação consiste de manter a broca um pouco acima do fundo do poço e apenas circular o fluido de perfuração para remover os cascalhos do espaço anular.

2.2.5.3 Revestimento de um poço de petróleo

Desde a antiguidade o homem tem perfurado poços na crosta terrestre, reconhecendo a necessidade de revesti-los total ou parcialmente para proteger suas paredes. O revestimento constitui uma das parcelas mais expressivas do custo de perfuração de um poço de petróleo. O número de fases e o comprimento das colunas de revestimento são determinados em função das pressões de poro e de fratura previstas, que indicam o risco de prisão da coluna por diferencial de pressão, ocorrência de *kicks*, desmoronamento das paredes do poço ou perda do fluido de perfuração para as formações.

2.2.5.4 Cimentação de poços de petróleo

Após a operação de revestimento do poço, é necessário que o espaço anular entre a parede do poço e o revestimento seja preenchido com cimento, de modo a fixar a tubulação e evitar que haja migração de fluidos entre as diversas zonas permeáveis atravessadas pelo poço, por detrás do revestimento. A cimentação do espaço anular é realizada, basicamente, pelo bombeio de pasta de cimento e água, que é deslocada através da própria tubulação de revestimento. Após o endurecimento da pasta, o cimento deve ficar fortemente aderido à superfície externa do revestimento e à parede do poço.

2.2.5.5 Perfilagem

Após a perfuração de uma fase, alguns aparelhos são descidos no interior do poço para efetuar a análise de algumas propriedades das formações, fundamentais para caracterização e avaliação econômica. Esta operação é conhecida como perfilagem.

2.2.6 Operações especiais de perfuração

Durante a perfuração de um poço, várias operações especiais podem ocorrer: controle de *kicks*, operações de pescaria, testemunhagem e teste de formação.

2.2.6.1 Controle de *kicks*

Uma das principais funções do fluido de perfuração é exercer pressão hidrostática sobre as formações a serem perfuradas pela broca para evitar que o fluido contido nos reservatórios fluam para dentro do poço. Se houver influxo mas ele for controlável ele é chamado de *kick*, se for incontrolável diz-se que é um *blowout*. Há vários indícios que identificam uma potencial situação de *kick*. Quando previamente reconhecidos e interpretados eles permitem que sejam tomadas as providências adequadas para evitar que se torne um *blowout*.

As principais informações do *kick* são as pressões lidas nos manômetros quando o poço é fechado, e o volume ganho nos tanques. Estando o poço fechado, o engenheiro prepara um plano para restabelecer o controle do poço, que consiste na circulação do fluido invasor para fora do poço e, quando necessário, na elevação da densidade do fluido.

2.2.6.2 Pescaria

Na indústria de petróleo é comum chamar de “peixe” qualquer objeto estranho que tenha caído, se partido ou ficado preso no poço, impedindo o prosseguimento das operações normais de perfuração. A operação de retirada dos “peixes” é chamada então de pescaria. A pescaria é uma operação sempre indesejável pois acarreta perda de tempo e pode causar danos mecânicos.

2.2.6.3 Testemunhagem

A testemunhagem é o processo de obtenção de uma amostra real de rocha de subsuperfície, chamado testemunho, com alterações mínimas nas propriedades naturais da rocha. Com a análise deste testemunho obtém-se informações como litologia, textura, porosidade, permeabilidade, saturação de óleo e água, etc.

Capítulo 3

Redes Neurais

Neste capítulo é feita uma breve abordagem sobre as redes neuronais. Descreve-se o que são redes neuronais, seu princípio de funcionamento, arquiteturas mais utilizadas e algoritmos de treinamento.

3.1 Introdução

3.1.1 O que são Redes Neurais?

O reconhecimento de que o cérebro humano trabalha de maneira completamente diferente do que um computador digital tem motivado a pesquisa em redes neuronais artificiais (RN's). O cérebro é um sistema de processamento de informações altamente complexo, paralelo e não linear, que tem a capacidade de organizar seus elementos estruturais, conhecidos como neurônios, de tal forma que se torna capaz de realizar algumas computações muitas vezes mais rápido do que alguns computadores digitais de hoje em dia. Seja, por exemplo, uma tarefa de reconhecimento visual. O cérebro continuamente faz representações do meio ambiente em que está imerso em questões de décimos de segundos. A realização de tarefas muito mais simples do que esta pode levar horas em computadores convencionais.

A neurobiologia explica, até certo ponto, como o cérebro é capaz de realizar tais façanhas. Inicialmente ele possui uma grande estrutura e a habilidade de construir suas próprias interconexões guiado pelo que é popularmente conhecido como tentativa e erro, ou experiência acumulada. Assim, a experiência é acumulada através do tempo, e o cérebro conhece seu desenvolvimento mais dramático nos dois primeiros anos de vida, passando a partir daí a se desenvolver em um ritmo mais lento.

De maneira geral, pode-se dizer que uma rede neuronal artificial é uma máquina que é projetada para modelar a forma com que o cérebro realiza uma determinada tarefa. A rede normalmente

é implementada através do uso de componentes eletrônicos ou de simulações em softwares. Para alcançar uma boa performance as RN's dependem de uma intensa interconexão entre seus elementos de processamento.

O procedimento utilizado para realizar o processo de aprendizado da RN é chamado de algoritmo de aprendizado, e ele atua ao modificar organizadamente os pesos sinápticos - a contrapartida artificial para as sinapses dos neurônios - de maneira que o sinal de saída da rede esteja o mais próximo possível de um sinal desejado.

3.1.2 Benefícios das Redes Neurais

De acordo com [12] as RN's devem seu poder primeiro à sua estrutura maciçamente paralela-distribuída, e segundo à sua capacidade de aprender e também de generalizar. O termo generalização refere-se à capacidade das RN's de apresentar saídas satisfatórias para entradas não apresentadas no conjunto de treinamento. Estas habilidades fazem com que as RN's sejam capazes de resolver problemas complexos que são intratáveis atualmente. Na prática, contudo, elas não resolvem sozinhas o problema. Ao contrário, dado um problema complexo, ele é decomposto em um número de tarefas relativamente simples. Um conjunto de tarefas é designado à uma rede neuronal com capacidade inerente para resolvê-las. É importante reconhecer, contudo, que há um longo caminho a percorrer antes que uma arquitetura de computador de funcionamento similar a um cérebro humano seja construída.

Em [12] está escrito que o trabalho com redes neurais apresenta os seguintes aspectos:

1. **Linearidade.** Uma RN pode ser linear ou não-linear. Uma rede neuronal constituída de interconexões de neurônios não-lineares será não-linear. Ainda mais, é uma não-linearidade bem particular, no sentido de que ela é distribuída através da rede.
2. **Mapeamento de Entrada/Saída.** Um paradigma popular de aprendizado conhecido como aprendizado supervisionado envolve modificações nos pesos sinápticos de uma rede neuronal através da apresentação de um conjunto de dados denominado amostras de treinamento ou exemplos de tarefa. Cada exemplo constitui-se de um único sinal de entrada e uma resposta desejada correspondente. Um exemplo escolhido aleatoriamente dentro do conjunto de dados é apresentado à rede, que terá seus pesos sinápticos ajustados para minimizar a diferença (de acordo com um critério estatístico) entre a resposta atual e a resposta desejada. O processo é repetido para muitos exemplos até o ponto em que não há mudança significativa dos valores dos pesos. Assim, a rede obtém conhecimento através do mapeamento de entradas/saídas.
3. **Adaptatividade.** As RN's têm uma característica própria de ajustar seus pesos sinápticos de acordo com mudanças que ocorram no ambiente. Em particular, uma RN treinada para operar em um dado ambiente pode ser facilmente retreinada para lidar com pequenas mudanças neste

ambiente. E mais, quando inserida em um ambiente não-estacionário (i.e., um em que suas propriedades estatísticas mudem com o tempo), uma RN pode ser projetada para ajustar seus pesos em tempo real. Esta propriedade adaptativa faz com que RN's sejam muito utilizadas em tarefas como processamento adaptativo de sinais, classificação adaptativa de padrões e controle adaptativo. Como regra geral podemos dizer que, uma vez garantida a sua estabilidade, quanto mais adaptativo um sistema mais robusto será sua performance quando operando em ambientes não estacionários. Deve ser enfatizado, no entanto, que a adaptatividade não leva necessariamente à robustez; na verdade, muitas vezes pode acontecer justamente o contrário.

4. **Certeza da Resposta.** No contexto da classificação de padrões, uma rede neuronal pode ser projetada para fornecer informações não somente sobre a classificação do padrão, mas também indicar o grau de incerteza desta informação. Isto pode ser útil para rejeitar padrões ambíguos, se eles surgirem, e assim melhorar a qualidade da classificação.
5. **Informação Contextual.** O conhecimento é representado pela estrutura e pelos estados de ativação da rede. Cada neurônio é potencialmente afetado pela atividade global dos outros neurônios da rede. Conseqüentemente, informações contextuais são naturalmente tratadas pelas RN's.
6. **Tolerância a Falhas.** Uma rede neuronal implementada em hardware é potencialmente tolerante a falhas no sentido de que sua performance degrada suavemente sob condições adversas de operação. Por exemplo, se um neurônio ou suas conexões estão danificadas, a obtenção de um padrão previamente armazenado não terá a mesma qualidade. No entanto, devido à natureza distribuída da informação armazenada na rede, este defeito tem que ser bastante extenso para que a resposta da rede como um todo seja seriamente prejudicada.
7. **Implementação em VLSI.** A natureza maciçamente paralela das RN's faz com que a execução de determinadas tarefas seja potencialmente rápida. Esta mesma propriedade as torna particularmente aptas a serem implementadas utilizando tecnologia *VLSI (Very Large Scale Integrated)*.
8. **Uniformidade de Análise e Projeto.** Basicamente, as RN's gozam de universalidade como processadores de informações. Isto quer dizer que a mesma notação é utilizada em todos seus domínios de aplicação.
9. **Analogia com a Neurobiologia.** O projeto de RN's é motivado pela analogia com o cérebro, que é uma prova viva que o processamento paralelo robusto não é apenas fisicamente possível mas também rápido e poderoso. Os engenheiros procuram na neurobiologia idéias novas que possam solucionar problemas mais complexos. Por outro lado, os pesquisadores de neurobiologia enxergam as RN's como uma ferramenta de pesquisa para a interpretação de fenômenos naturais. As duas áreas se ajudam mutuamente. Esta ajuda mútua é bastante salutar para a ciência.

3.2 Modelo Matemático de Neurônios

Um neurônio é a unidade fundamental de processamento de informações da rede neuronal. A figura 3.1 apresenta um diagrama em blocos de um neurônio. Nele pode-se perceber:

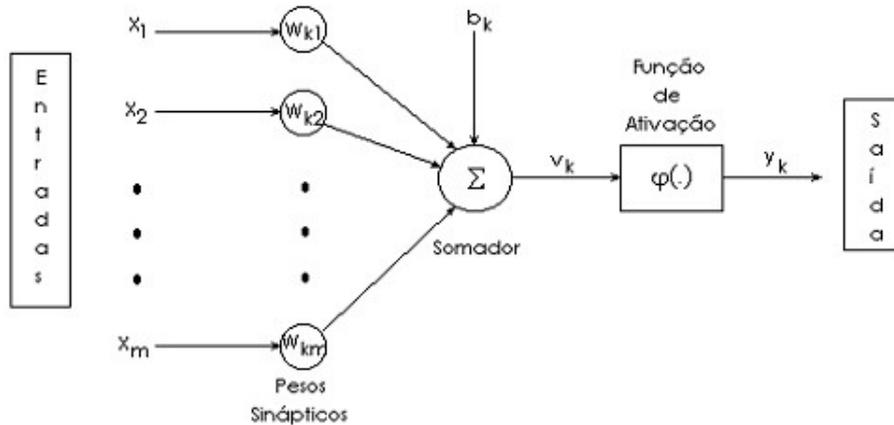


Figura 3.1: Diagrama em blocos de um neurônio.

1. Um conjunto de sinapses ou conexões, cada qual caracterizada por apresentar um peso ou força própria. Especificamente, um sinal x_j aplicado na entrada de uma sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} ;
2. Um somador para somar todos os sinais de entrada já multiplicados pelos seus respectivos pesos;
3. Uma função de ativação para limitar a amplitude da saída do neurônio. Ela também é conhecida como função de compressão por ‘comprimir’ a faixa de amplitude permissível para o sinal de saída a um valor finito.

O modelo da figura inclui também um sinal de bias, denotado de b_k , que aumenta ou diminui o nível do sinal na entrada da função de ativação. Em termos matemáticos, pode-se descrever um neurônio k através do seguinte par de equações:

$$u_k = \sum_{j=0}^m w_{kj}x_j \quad (3.1)$$

$$y_k = \varphi(v_k) \quad (3.2)$$

Aonde,

$$v_k = u_k + b_k, \quad (3.3)$$

$$x_0 = 1, e \quad (3.4)$$

$$w_{k0} = b_k \quad (3.5)$$

3.2.1 Tipos de função de ativação

A função de ativação, denotada por $\varphi(\cdot)$, determina a saída do neurônio em termos do potencial de ativação v_k . As três funções de ativação mais utilizadas de acordo com [12] são:

1. **Heaviside.** Na literatura da engenharia é normalmente referida como função de Heaviside:

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (3.6)$$

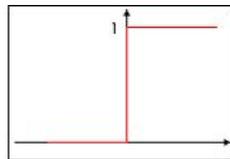


Figura 3.2: Função Heaviside

2. **Linear em partes.**

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0.5 \\ v, & \text{se } 0.5 > v > -0.5 \\ 0, & \text{se } v \leq -0.5 \end{cases} \quad (3.7)$$

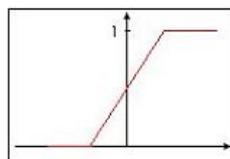


Figura 3.3: Função Piecewise

3. **Sigmóide.** O seu gráfico tem a forma de um 's'. É de longe a mais utilizada em redes neurais por ser diferenciável:

$$\varphi(v) = \frac{1}{1 + e^{-a*v}}, \quad (3.8)$$

onde a é uma constante.

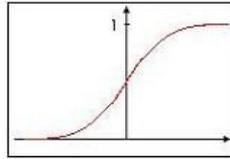


Figura 3.4: Função Sigmoid

Todas as funções de ativação aqui apresentadas têm suas amplitudes entre 0 e 1. No entanto, algumas vezes pode ser desejável que os valores de amplitude estejam dentro do intervalo -1 e +1, casos nos quais as funções de ativação apresentam-se como anti-simétricas em relação à origem.

3.3 Arquiteturas de Redes Neurais

Segundo [12], a maneira que os neurônios de uma rede estão estruturados está intimamente ligada ao algoritmo usado para treiná-la. Pode-se dizer então que os algoritmos de aprendizado utilizados são algoritmos estruturados. Em geral, identifica-se três classes fundamentais de arquiteturas de redes neurais:

1. *Redes diretas de camada única*

Os neurônios de uma rede neuronal são organizados em camadas. Em sua forma mais simples, uma rede é constituída de uma camada de entrada (nós de entrada), com links direcionados para uma camada de saída (nós computacionais). Tal tipo de rede é chamado de camada única (single-layer) porque apenas os nós computacionais são levados em conta.

2. *Redes diretas de múltiplas camadas*

A segunda classe de redes diretas se distingue por apresentar uma ou mais camadas ocultas (hidden layers), cujos nós computacionais são chamados neurônios ocultos ou unidades ocultas. A função dos neurônios ocultos é de intervir entre a entrada da rede e a camada de saída de uma maneira proveitosa. Ao serem adicionadas mais camadas ocultas a rede torna-se capaz de extrair estatísticas de ordem mais elevada, o que pode ser bastante interessante em situações em que a camada de entrada seja extensa. Uma RN é dita completamente conectada quando todos os nós em uma determinada camada estão ligados a todos os nós da camada adjacente posterior. Caso contrário, a RN é dita parcialmente conectada.

3. *Redes recorrentes*

Uma rede recorrente difere de uma rede direta por apresentar pelo menos um loop de realimentação. Por exemplo, uma rede recorrente pode ser constituída de uma única camada na qual a saída de alguns de seus neurônios é realimentada na entrada de alguns destes mesmos neurônios. A presença de loops de realimentação tem um profundo impacto na capacidade de aprendizado e na performance da rede.

3.4 **Aprendizagem**

Em [12] está escrito que a propriedade mais significativa das redes neuronais é sua capacidade de obter conhecimento a partir de dados obtidos no ambiente em que estão imersas, e de melhorar sua performance através deste aprendizado. A melhora na performance se dá com o passar do tempo e seguindo uma dada metodologia. Uma RN aprende sobre o ambiente através de um processo iterativo de ajuste de seus pesos sinápticos e nível de bias. Idealmente, a rede torna-se mais eficiente após cada iteração do processo de aprendizagem. Ainda em [12] o aprendizado no contexto de RN's é definido da seguinte maneira:

“Aprendizado é um processo pelo qual os parâmetros livres de uma RN são adaptados através de um processo guiado por estímulos provenientes do ambiente. O tipo de aprendizado é determinado pela forma com que a mudança dos parâmetros é feita.”

Esta definição implica a seguinte seqüência de eventos:

- A rede é estimulada pelo ambiente;
- A rede submete seus parâmetros a mudanças como resultado deste estímulo;
- A rede agora responde de maneira diferente ao ambiente por causa desta adaptação;

3.4.1 **Algoritmos de Aprendizado**

De acordo com [12], pode-se definir um algoritmo de aprendizado como sendo um conjunto prescrito de regras bem definidas para a solução do problema de aprendizado. Não existe apenas um algoritmo para o treinamento de redes neuronais, pelo contrário, existe um “kit de ferramentas” representado por uma variedade de algoritmos diferentes, cada um com suas vantagens próprias, como por exemplo aprendizado baseado em memorização, aprendizado de Hebb, aprendizado competitivo e aprendizado por correção de erro. Basicamente, eles diferem entre si pela maneira com que os ajustes nos pesos sinápticos é formulada. Este último será visto em maiores detalhes a seguir:

3.4.1.1 Aprendizado por correção de erro

Seja um neurônio k . Em sua entrada aplica-se um sinal $x(n)$ produzido por uma ou mais camadas ocultas, que por sua vez tem um vetor de entrada (estímulo) aplicado em sua entrada. O argumento n refere-se à discretização de tempo, ou ainda, a um dado instante de tempo. O sinal de saída do neurônio k é denotado por $y_k(n)$. Este sinal, representando no caso a única saída da rede neuronal, é comparado a uma resposta desejada, denotada por $d_k(n)$. Conseqüentemente, um sinal de erro é gerado. Assim, temos:

$$e_k(n) = d_k(n) - y_k(n) \quad (3.9)$$

Este sinal de erro atua em um mecanismo de controle, que tem o propósito de aplicar a seqüência de ajustes aos pesos sinápticos. Os ajustes corretivos são aplicados para fazer com que o sinal de saída $y_k(n)$ se aproxime do sinal desejado $d_k(n)$ em um certo número de iterações. Este objetivo é alcançado através da minimização de uma função objetivo, definida em termos do sinal de erro:

$$\xi(n) = \frac{1}{2} e_k^2(n) \quad (3.10)$$

As iterações continuam até que o sistema se estabilize. Em particular, a minimização desta função objetivo leva a uma regra de aprendizado normalmente conhecida como regra de Widrow-Hoff. Seja $w_{kj}(n)$ o valor do peso sináptico do neurônio k excitado pelo elemento $x_j(n)$ do vetor $X(n)$ no instante n . De acordo com a regra, o ajuste $\Delta w_{kj}(n)$ aplicado ao peso $w_{kj}(n)$ é dado por:

$$\Delta w_{kj}(n) = \eta e_k(n) x_j(n) \quad (3.11)$$

aonde η é uma constante positiva que representa a taxa de aprendizado entre duas iterações. É natural então que η seja referida como parâmetro da taxa de aprendizado.

Tudo que foi dito até aqui sobre esta regra levou em consideração que o sinal de erro é diretamente mensurável. Para que isso seja verdade é necessário que haja uma fonte externa para suprir o sinal desejado de modo que o sinal de erro possa ser obtido. Tendo sido aplicados os ajustes necessários, o valor atualizado do peso passa a ser:

$$w_{kj}(n+1) = w_{kj}(n) + \Delta w_{kj}(n) \quad (3.12)$$

Na Figura 3.5 um grafo representando o processo de ajuste dos pesos é apresentado. Nele pode-se perceber que este processo é um exemplo de um sistema realimentado em malha fechada, e sendo

assim, sua estabilidade depende dos parâmetros que constituem esta realimentação. Um destes parâmetros é a taxa de aprendizado η , que tem que ser cuidadosamente escolhida para que o processo de aprendizado atinja a estabilidade.

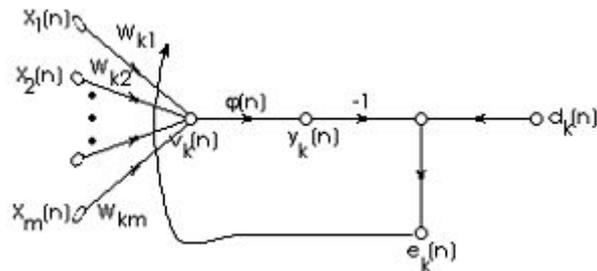


Figura 3.5: Realimentação no processo de aprendizagem

3.4.2 Paradigmas de aprendizado

3.4.2.1 Aprendizado supervisionado

Na figura 3.6 um diagrama em blocos ilustra esta forma de aprendizado.

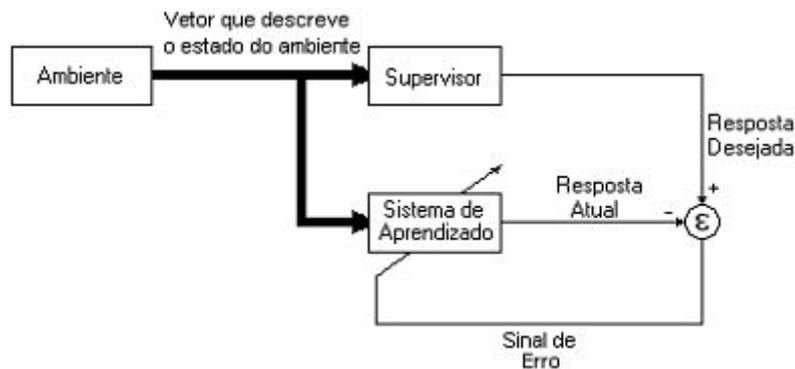


Figura 3.6: Diagrama de blocos de aprendizagem com supervisor

Em termos conceituais, podemos pensar no supervisor como uma entidade que tem conhecimento do ambiente em que está inserido, sendo este conhecimento representado por um conjunto de vetores de entrada-saída. No entanto, o ambiente é desconhecido para a RN em questão. Suponha que a RN e o supervisor sejam ambos expostos a um vetor de treinamento obtido a partir do ambiente. Devido ao conhecimento que possui, o supervisor é capaz de fornecer à rede a resposta desejada para aquele vetor de entrada. Assim, os parâmetros da rede são ajustados de acordo com a influência combinada do vetor de treinamento e do sinal de erro. Este ajuste é feito com o objetivo de que após algumas iterações o sistema de aprendizado emule o sistema supervisor. Desta maneira, o conhecimento sobre o ambiente é transferido do supervisor para o sistema de aprendizado. Quando esta condição é alcançada, o supervisor é dispensado e a RN assume a tarefa por inteiro.

3.4.2.2 Aprendizado sem supervisor

No paradigma conhecido por aprendizado sem supervisor não há uma entidade responsável pela supervisão do processo de aprendizagem. Ou seja, não há exemplos rotulados da função a ser aprendida pela rede. Duas subdivisões são identificadas:

1. *Aprendizado por reforço/Programação neurodinâmica*

Neste tipo, o aprendizado de um mapeamento entrada-saída é feito através de uma interação contínua com o ambiente com o intuito de minimizar um índice escalar de performance. A figura 3.7 mostra o diagrama de blocos de um sistema de aprendizado por reforço construído em torno do crítico, bloco que converte o sinal de reforço primário obtido do ambiente em um sinal de reforço de maior qualidade, chamado sinal de reforço heurístico, sendo ambos escalares.

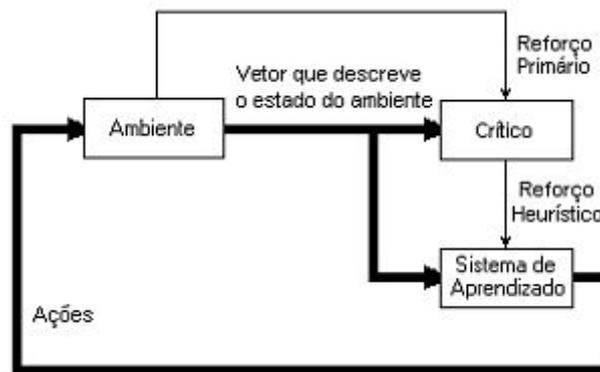


Figura 3.7: Aprendizado por reforço

O sistema é desenvolvido para observar uma seqüência temporal de estímulos do ambiente, o que eventualmente resulta na geração do sinal de reforço heurístico. O objetivo é minimizar uma função de custo, definida como a expectativa do custo acumulado das ações tomadas em seqüência ao invés do custo imediato. Pode ser que certas ações tomadas previamente sejam as melhores determinantes do comportamento de um sistema como um todo. A função do sistema de aprendizado é de descobrir estas ações e retorná-las ao ambiente.

2. *Aprendizado não supervisionado*

No aprendizado não supervisionado, ou ainda auto-organizável, não há um supervisor externo e nem sequer um crítico. Ao contrário, avalia-se a qualidade da representação que deseja-se ver aprendida pela rede, e baseado no resultado desta avaliação os parâmetros livres da rede são ajustados. Uma vez que a RN esteja sintonizada com as regularidades estatísticas dos dados de entrada, ela desenvolve a capacidade de formar representações internas para classificar as propriedades da entrada e assim criar novas classes automaticamente.

3.4.3 Tarefas Básicas das Redes Neurais

As redes neurais são sistemas inteligentes aptos a desempenharem de maneira bastante razoável algumas tarefas. De acordo com [12], a escolha do algoritmo de aprendizado está bastante ligada à tarefa a ser desempenhada pela rede. Assim, as redes são utilizadas em diversas aplicações, como por exemplo: Associação de padrões, Reconhecimento de padrões, Controle, Filtros Adaptativos, Aproximação de funções, entre outras. Este último é de interesse no presente trabalho e será visto em maiores detalhes. Maiores informações podem ser conseguidas em [12], [14] e [15].

3.4.3.1 Aproximação de funções

Considere um mapeamento não linear de entrada-saída descrito pela relação funcional

$$d = f(x) , \quad (3.13)$$

onde x é o vetor de entrada e d o vetor de saída. A função vetorial $f(\cdot)$ é considerada desconhecida. Para compensar a falta de conhecimento sobre a função, um conjunto de pares entrada-saída é dado:

$$\mathfrak{S} = \{(x_i, d_i)\}_{i=1}^N \quad (3.14)$$

O objetivo é projetar uma rede cuja função equivalente $F(\cdot)$ seja próxima o suficiente em termos euclidianos da função desconhecida $f(\cdot)$:

$$\|F(x) - f(x)\| < \varepsilon, \text{ para todo } x \quad (3.15)$$

aonde ε é um número positivo pequeno. Uma vez que o tamanho do conjunto de treinamento, N , seja suficientemente grande e a rede seja equipada com um número adequado de parâmetros livres, o erro de aproximação ε pode ser diminuído sensivelmente. O problema de aproximação descrito aqui é um candidato perfeito para um aprendizado supervisionado, onde x_i desempenharia o papel de vetor de entrada e d_i de resposta desejada. Por outro lado, pode-se ver o aprendizado supervisionado como um problema de aproximação. A habilidade das RN's de realizar aproximações pode ser explorada de duas maneiras:

1. *Identificação de Sistemas:* Seja o sistema desconhecido da figura 3.8. Se dispusermos a rede como apresentado na figura podemos fazer com que a rede aproxime o funcionamento do sistema através de um sistema supervisionado.

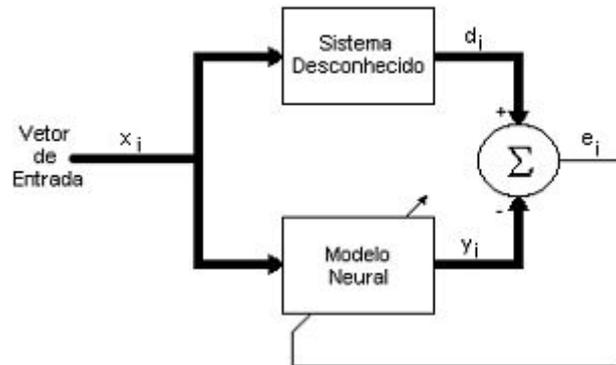


Figura 3.8: Sistema de Identificação

2. *Sistema Inverso*: Suponha que seja dado um sistema cuja relação entrada-saída seja conhecida. O objetivo neste caso é construir um sistema inverso que produza em sua saída um vetor x em resposta ao estímulo d em sua entrada. O sistema inverso é descrito por:

$$x = f^{-1}(d) \quad (3.16)$$

aonde a função vetorial $f^{-1}(\cdot)$ denota a função inversa de $f(\cdot)$. Na prática, em muitas situações é difícil formular matematicamente a função inversa de uma função conhecida. Dado o conjunto de pares de entrada-saída da função $f(\cdot)$, é possível construir um sistema de acordo com o esquema da figura 3.9 que aproxime a função inversa.

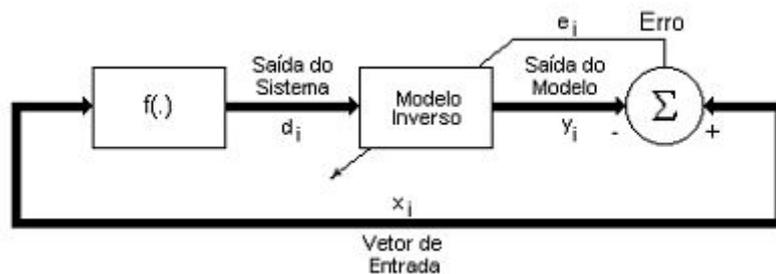


Figura 3.9: Identificador de Função Inversa

Capítulo 4

Aplicação de redes neuronais na previsão do desgaste de uma broca

Neste capítulo será descrita a metodologia criada para treinar e avaliar redes neuronais na previsão do desgaste de brocas de perfuração de poços.

4.1 Definição do problema

O presente trabalho visa observar e comparar o desempenho de algumas configurações de redes neuronais na tarefa de inferir o desgaste de brocas de perfuração de poços de petróleo. Para tanto, uma metodologia foi criada e consiste basicamente em: obtenção de dados; treinamento das redes e comparação dos desempenhos. Tendo em mãos a rede com o melhor desempenho, esta foi escolhida para a outra etapa do presente trabalho, que é avaliar o desempenho da rede em uma formação rochosa composta por seções de litologia do tipo *HardSand* e *Shale*.

4.2 Obtenção de dados

Os dados foram obtidos a partir de simulações utilizando o software MaxSimul PayZone J. Este é um simulador de perfuração de poços de petróleo que entre outras coisas permite gravar em um arquivo de saída a evolução minuto a minuto dos dados envolvidos na simulação. Este software indica ainda o desgaste de brocas de acordo com uma escala. A escala é estabelecida pelo software da seguinte maneira:

- Valores entre T0 e T8 indicam o desgaste dos dentes da broca, aonde T8 indica o nível máximo de desgaste do dente antes da ruptura.

- Valores entre B0 e B8 indicam o desgaste dos rolamentos da broca, aonde B8 indica o nível máximo de desgaste do rolamento antes da ruptura.

4.2.1 Obtenção dos dados de treinamento

O simulador permite o ajuste de alguns parâmetros da operação de perfuração através de controles gráficos. Assim, é possível modificar diretamente com o mouse o valor do peso na broca, a velocidade de rotação, etc. de maneira similar ao que seria feito manualmente em uma situação real. No presente trabalho optou-se por atuar apenas nos seguintes parâmetros: peso aplicado na broca ou *WOB (Weight on Bit)*; velocidade de rotação ou *RPM (Rotation/min)*, e vazão do fluido de perfuração ou *GPM (Galons/min)*.

O seguinte procedimento foi adotado para obter os dados para treinamento das redes:

Foram feitas simulações de perfurações em litologias uniformes até que a broca atingisse seu desgaste completo. Foram feitas simulações em litologias do tipo *Hard Sand* e em litologias do tipo *Shale*. A litologia *Hard Sand*, ou ainda arenito, é uma formação rochosa compactada, cuja granulometria apresenta grãos de tamanho entre médio e grande, e por esta característica apresenta uma abrasividade relativamente alta. Já a litologia *Shale*, ou argila, é uma formação rochosa cuja granulometria apresenta grãos extremamente pequenos, e não possui porosidades. Por isso sua abrasividade é menor, mas causa um desgaste maior nos rolamentos.

Cada perfuração foi efetuada mantendo-se constantes os valores dos parâmetros da perfuração. Por sua vez, os parâmetros da perfuração foram escolhidos de maneira que uma grande faixa de operação fosse atingida. Assim, por exemplo, foram feitas simulações de perfurações com um peso aplicado na broca dentro de uma faixa de valores que vai de 10000 lb a 90000 lb. Os valores escolhidos para os parâmetros da perfuração em cada simulação feita estão detalhados na tabela 4.1. De maneira geral, não é comum operar em valores fora dessa faixa.

Em todas as simulações de perfuração foi utilizada uma broca do tipo *Milled Tooth*, com 3 jatos de injeção de fluido, diâmetro de 12 1/4" e dentes de tamanho médio. Além disso, foi utilizado, em todas as simulações, um fluido do tipo *Betonite/Water*, com uma densidade de 10ppg.

Para cada perfuração simulada, foram gravados dois arquivos de saída: um contendo informações minuto a minuto sobre variáveis envolvidas na perfuração, dentre as quais o torque instantâneo e a taxa de penetração ou *ROP - Rate of Penetration*; o outro contendo as informações sobre o desgaste da broca, tanto do dente quanto do rolamento, minuto a minuto. Favor reportar a [41] para maiores informações sobre o simulador utilizado.

Os valores do torque e da taxa de penetração foram agrupados juntamente com os valores do peso na broca, velocidade de rotação e vazão do fluido de perfuração constituindo assim um conjunto

Tabela 4.1: Configuração dos parâmetros utilizados em cada perfuração

| Configuração | WOB (em 1000xlb) | RPM | GPM |
|--------------|---------------------|-----|------|
| 1 | 10 | 100 | 900 |
| 2 | 30 | 100 | 900 |
| 3 | 50 | 100 | 900 |
| 4 | 70 | 100 | 900 |
| 5 | 90 | 100 | 900 |
| 6 | 50 | 20 | 900 |
| 7 | 50 | 80 | 900 |
| 8 | 50 | 150 | 900 |
| 9 | 50 | 220 | 900 |
| 10 | 50 | 280 | 900 |
| 11 | 50 | 100 | 200 |
| 12 | 50 | 100 | 410 |
| 13 | 50 | 100 | 610 |
| 14 | 50 | 100 | 1000 |

de dados de entrada da rede neuronal. Assim, de acordo com a tabela 4.1, podemos observar que existem 14 conjuntos de dados de entrada diferentes, um para cada configuração de parâmetros, e com tamanho que depende do tempo que a broca leva para se desgastar em cada perfuração, variando entre um mínimo de 26 minutos e um máximo de 5706 minutos. Os conjuntos de dados de entrada passaram ainda por normalizações para que seus valores ficassem compreendidos entre os valores 0 e 1.

No arquivo que contém informações sobre o desgaste da broca, os valores estavam indicados de acordo com a escala supra-citada. Assim, inicialmente foi preciso transformar os valores da escala em valores numéricos para que a rede neuronal pudesse trabalhar com eles. A transformação utilizada está demonstrada na tabela 4.2.

Tabela 4.2: Transformação de valores da escala para valores numéricos

| Desgaste do Dente → Valor Numérico | Desgaste da Broca → Valor Numérico |
|------------------------------------|------------------------------------|
| T0 → 0.1 | B0 → 0.1 |
| T1 → 0.2 | B1 → 0.2 |
| T2 → 0.3 | B2 → 0.3 |
| T3 → 0.4 | B3 → 0.4 |
| T4 → 0.5 | B4 → 0.5 |
| T5 → 0.6 | B5 → 0.6 |
| T6 → 0.7 | B6 → 0.7 |
| T7 → 0.8 | B7 → 0.8 |
| T8 → 0.9 | B8 → 0.9 |

Os valores transformados foram agrupados e constituem um conjunto de dados de saída da rede neuronal. Obviamente, existem também 14 conjuntos de dados de saída diferentes. O conjunto de

dados de entrada e seu respectivo conjunto de dados de saída constitui um par de entrada/saída. Estes 14 pares de entrada/saída constituem o conjunto de dados de treinamento da rede.

Quando trabalha-se com treinamento de redes neuronais, é interessante avaliar a taxa de acerto e a capacidade de generalização da rede. Para o primeiro caso devemos separar um par de entrada/saída pertencente ao conjunto de treinamento, já para o segundo caso é necessário obter-se um par de entrada/saída que não faça parte do conjunto de treinamento. Veremos a seguir um pouco mais a fundo.

4.2.2 Obtenção dos dados para avaliação da taxa de acerto

A taxa de acerto indica se a rede está fazendo o mapeamento de entrada/saída de maneira satisfatória para os vetores que fazem parte do conjunto de treinamento.

O procedimento para avaliar a taxa de acerto adotado foi o seguinte: apresentar na entrada da rede um vetor que faz parte do conjunto de dados de entrada de treinamento; verificar a diferença entre o vetor obtido na saída da rede e o vetor do conjunto de dados de saída de treinamento correspondente. Se a diferença, ou ainda erro de aprendizado, for pequena dizemos que a rede aprendeu razoavelmente bem.

No presente caso, para verificar o aprendizado da rede foi escolhido, aleatoriamente, dentro do conjunto de treinamento o par de entrada/saída resultante da simulação com a configuração número 3:

Tabela 4.3: Configuração utilizada para verificar o aprendizado da rede

| Configuração | WOB (em 1000xlb) | RPM | GPM |
|--------------|---------------------|-----|-----|
| 3 | 50 | 100 | 900 |

4.2.3 Obtenção dos dados para avaliação da capacidade de generalização

A capacidade de generalização indica se a rede consegue apresentar em sua saída um vetor próximo ao esperado quando submetida a um vetor de entrada que não faz parte do conjunto de treinamento. Ou seja, como a rede se comporta em relação a uma situação totalmente desconhecida.

O procedimento adotado para avaliar a capacidade de generalização é bastante similar ao utilizado para avaliar a taxa de acerto: apresentar na entrada da rede o vetor que não faz parte do conjunto de dados de entrada de treinamento; verificar a diferença entre o desgaste da broca indicado na saída da rede e o desgaste da broca indicado pelo simulador quando submetido às mesmas condições de entrada. Se a diferença, ou ainda erro de generalização, for pequena dizemos que a rede generaliza razoavelmente bem.

Foi escolhida uma configuração que se situa mais ou menos em um nível central dos parâmetros utilizados. Deste modo, o par entrada/saída que não faz parte do conjunto de treinamento foi obtido com a seguinte configuração de ajuste dos parâmetros:

Tabela 4.4: Configuração utilizada para verificar a capacidade de generalização da rede

| Configuração | WOB (em 1000xlb) | RPM | GPM |
|--------------|---------------------|-----|-----|
| 15 | 70 | 180 | 700 |

4.3 Treinamento das redes

O *software Matlab 6.5*, mais especificamente o *toolbox nntol*, foi utilizado para efetuar a modelagem das redes neuronais artificiais.

4.3.1 Modelagem do problema

A concretização de previsões acuradas do desgaste de brocas depende da modelagem adequada da rede neuronal empregada na representação do conhecimento. A percepção de inter-relações complexas entre os parâmetros que influenciam o desempenho de uma rede neuronal e as inúmeras possibilidades de projeto da arquitetura do modelo conexionista disponibilizam ampla liberdade para a construção de algum modelo que produza o aprendizado efetivo das informações nele representadas.

A arquitetura de uma rede neuronal artificial é definida pelo agrupamento de suas unidades de processamento, ou seja, pela disposição dos neurônios artificiais e pelo modo de estabelecimento das conexões entre eles. O desafio está na identificação do número apropriado de camadas para que uma solução satisfatória seja alcançada, assim como do número de unidades de processamento da cada camada.

No presente trabalho algumas redes com arquitetura diferentes foram estudadas com o intuito de se escolher a mais apta à tarefa de inferir o desgaste de uma broca.

4.3.1.1 Redes recorrentes

Todas as arquiteturas de redes recorrentes aqui estudadas possuem camadas de entrada e de saída idênticas. A camada de entrada possui sete nós de entrada, sendo eles respectivamente:

Nó 1 - Entrada dos valores de peso aplicado na broca;

Nó 2 - Entrada dos valores de velocidade de rotação;

Nó 3 - Entrada dos valores de vazão do fluido de perfuração;

Nó 4 - Entrada dos valores de torque na coluna;

Nó 5 - Entrada dos valores de taxa de penetração;

Nó 6 - Realimentação da saída da rede referente ao desgaste do dente da broca;

Nó 7 - Realimentação da saída da rede referente ao desgaste do rolamento da broca;

A camada de saída possui dois neurônios, sendo eles respectivamente:

Neurônio 1 - Desgaste do dente da broca;

Neurônio 2 - Desgaste do rolamento da broca;

Para melhor visualização, a arquitetura geral das redes recorrentes estudadas está mostrada na figura 4.1.

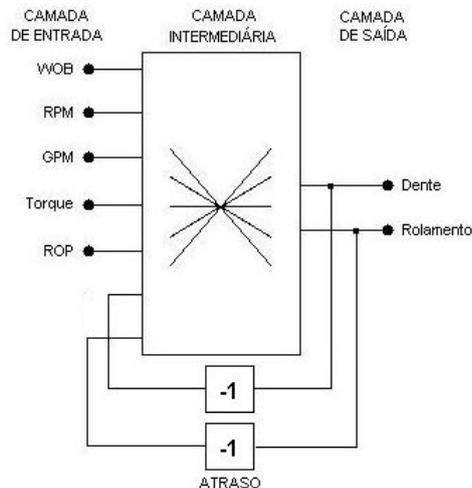


Figura 4.1: Arquitetura geral das redes recorrentes

O sinal de saída sofre um atraso e depois é realimentado nos nós 6 e 7. Isto é feito para a RN ter informação sobre o estado de desgaste atual da broca. Além disso, caso a RN seja submetida a uma perfuração já iniciada, faz-se necessário informá-la do estado da broca naquele momento. Esta informação é passada à RN também através destes dois nós. Pensando um pouco mais adiante, será necessário também adicionar um sistema de reset para inicializar o sinal nestes dois nós no caso de se estar iniciando uma perfuração. Durante o treinamento, o sinal apresentado nos nós 6 e 7 da rede

foi, respectivamente, o desgaste do dente e o desgaste do rolamento obtidos do par entrada/saída, atrasados de um período de amostragem.

Dentro desta arquitetura geral estudou-se as seguintes arquiteturas:

- rede 7-2 (sem nenhuma camada intermediária);
- rede 7-10-2 (com uma camada intermediária com dez neurônios);
- rede 7-12-2 (com uma camada intermediária com doze neurônios);
- rede 7-20-2 (com uma camada intermediária com vinte neurônios);
- rede 7-10-10-2 (com duas camadas intermediárias de dez neurônios cada uma);

4.3.2 Algoritmo de treinamento utilizado

Todas as redes estudadas são redes recorrentes, algumas de camada única, outras multi-camadas, com conexão total entre os neurônios. Isso permitiu o uso do algoritmo de treinamento conhecido como aprendizado por correção de erro com retro-propagação (do inglês *back-propagation*).

Um parâmetro que interfere na convergência do aprendizado é a taxa de aprendizado. Sua influência está relacionada à mudanças nos pesos entre as conexões das unidades de processamento: taxas de aprendizado muito pequenas implicam um tempo de treinamento longo; contudo, taxas de aprendizado muito grandes podem provocar oscilações em torno da solução. No presente trabalho a taxa de aprendizado foi mantida em:

$$\mu = 0.01 \quad (4.1)$$

Outro parâmetro que interfere na convergência do aprendizado é conhecido como *momentum*. Ele atua ao diminuir progressivamente o valor da taxa de aprendizado, e desta maneira procura diminuir a possibilidade de oscilações durante a execução do algoritmo. O valor do *momentum* foi fixado em:

$$\zeta = 0.9 \quad (4.2)$$

4.3.3 Paradigma de aprendizado

Como já foi visto no capítulo 3, o supervisor é uma entidade que possui conhecimento do ambiente em que está inserido, sendo este conhecimento representado em um conjunto de pares de

entrada/saída. Devido ao conhecimento que possui, o supervisor é capaz de fornecer à rede a resposta desejada para aquele vetor de entrada.

No presente trabalho o pesquisador faz o papel de supervisor ao executar a obtenção dos dados e organizá-los em pares de entrada/saída como visto na seção 4.2.

O treinamento da rede também foi feito no *software Matlab v6.5*. Para tanto, os pares de entrada/saída foram agrupados em *structures* e alguns *scripts* foram desenvolvidos. De maneira geral, os *scripts* fazem o seguinte: um par de entrada/saída é apresentado à rede que passa por um processo de ajuste de seus pesos. Este procedimento é repetido para os 13 pares de entrada/saída restantes, constituindo assim um ciclo de treinamento.

Para cada arquitetura de rede estudada foram feitos 2150 ciclos de treinamento. A cada 50 ciclos são calculados o erro médio quadrático de treinamento e o erro médio quadrático de generalização. O erro médio quadrático é calculado da seguinte maneira:

$$\epsilon = \frac{\sqrt{\sum_{x=1}^N \left(\frac{D(x)-Y(x)}{D(x)} \right)^2}}{N}, \quad (4.3)$$

onde N é a dimensão dos vetores D e Y , $D(x)$ é o vetor resposta desejada, no caso o vetor apresentado pelo supervisor, e $Y(x)$ é a resposta obtida, no caso a saída da rede neuronal.

4.4 Comparação dos desempenhos

Para alcançar o objetivo do presente trabalho que é escolher uma configuração de rede neuronal com o melhor desempenho na tarefa de inferir o desgaste de uma broca de perfuração de poços, fez-se a comparação entre o desempenho das diversas redes aqui estudadas.

Dentre as redes recorrentes buscou-se indicar qual das redes se sobressaiu, levando em consideração o erro de aprendizado e o erro de generalização para os dois tipos de litologia. Assim, buscou-se indicar qual seria a melhor escolha global de redes recorrentes.

4.5 Litologia Composta

Nesta etapa, uma rede com arquitetura próxima à rede de melhor desempenho observado foi treinada com ambos os conjuntos de treinamento das perfurações em litologias Hard Sand e Shale. Após treinamento, foi avaliada sua capacidade de prever o desgaste de uma broca na perfuração de uma formação rochosa composta por porções destas duas litologias.

Para criar esta formação rochosa utilizou-se o Litho Editor, que é um módulo pertencente ao simulador PayZone, aonde é possível criar-se litologias a serem perfuradas. As propriedades das litologias foram ajustadas para serem iguais às utilizadas anteriormente nos testes de desempenho das redes.

A formação criada é composta por uma seção de 200 pés de espessura de litologia do tipo Shale e, logo embaixo, uma seção de 400 pés de espessura de litologia do tipo HardSand.

A rede utilizada nesta etapa possui oito nós de entrada. Como foram utilizados dois tipos de litologia diferentes na formação rochosa criada, e em cada tipo o desgaste da broca se dá de maneira diferente, a rede precisa saber qual litologia está sendo perfurada. O oitavo nó é então utilizado para informar à rede qual litologia está sendo perfurada da seguinte maneira:

- Se o valor na entrada do nó 8 for 0, está sendo perfurada a litologia do tipo *Hard Sand*;
- Se o valor na entrada do nó 8 for 1, está sendo perfurada a litologia do tipo *Shale*;

A configuração do ajuste dos parâmetros de perfuração pode ser observado na tabela 4.5

Tabela 4.5: Configuração utilizada na perfuração de formações rochosas compostas

| WOB (em 1000xlb) | RPM | GPM |
|---------------------|-----|-----|
| 50 | 100 | 900 |

Uma perfuração foi efetuada e novamente foram gerados dois arquivos de saída: um contendo informações sobre o andamento das variáveis de perfuração e o outro contendo informações do desgaste da broca. Ao primeiro arquivo foi adicionado a informação sobre a litologia sendo perfurada. Posteriormente este arquivo foi submetido à rede neuronal. O desgaste da broca obtido na resposta da rede foi comparado com o resultado obtido diretamente no simulador.

Capítulo 5

Resultados Experimentais

A partir dos critérios relacionados na seção anterior, as redes neuronais artificiais foram modeladas e o aprendizado efetuado. A convergência e generalização dos modelos desenvolvidos foram analisados.

5.1 Litologia *HardSand*

5.1.1 Redes recorrentes

5.1.1.1 Rede 7-2

Dentre as Redes 7-2, foram testadas as seguintes configurações:

- Rede7-2Plin: rede sem camada oculta e com função de ativação Plin (Puramente Linear) na camada de saída;
- Rede7-2Lsig: rede sem camada oculta e com função de ativação Lsig (Sigmóide Logarítmico) na camada de saída;
- Rede7-2Tsig: rede sem camada oculta e com função de ativação Tsig (Tangente Sigmóide) na camada de saída;

Está mostrado na tabela 5.1 a evolução do erro de aprendizado e do erro de generalização para o treinamento da Rede 7-2Plin.

Tabela 5.1: Evolução do erro de aprendizado e erro de generalização da Rede 7-2Plin

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 4.04% | 16.45% |
| 100 | 1.82% | 7.33% |
| 150 | 1.09% | 3.10% |
| 200 | 1.01% | 2.31% |
| 250 | 0.52% | 2.31% |
| 300 | 0.51% | 2.31% |
| 350 | 0.51% | 2.72% |
| 400 | 0.51% | 2.11% |
| 450 | 0.49% | 1.60% |
| 500 | 0.47% | 1.25% |
| 550 | 0.45% | 1.18% |
| 600 | 0.44% | 0.97% |
| 650 | 0.22% | 0.89% |
| 700 | 0.12% | 0.81% |
| 750 | 0.00% | 0.81% |
| 800 | 0.00% | 0.81% |
| 850 | 0.00% | 0.81% |
| 900 | 0.00% | 0.81% |
| 950 | 0.00% | 0.81% |
| 1000 | 0.00% | 0.81% |
| 1050 | 0.00% | 0.81% |
| 1100 | 0.00% | 0.81% |
| 1150 | 0.00% | 0.81% |
| 1200 | 0.00% | 0.81% |
| 1250 | 0.00% | 0.81% |
| 1300 | 0.00% | 0.81% |
| 1350 | 0.00% | 0.81% |
| 1400 | 0.00% | 0.81% |
| 1450 | 0.00% | 0.81% |
| 1500 | 0.00% | 0.81% |
| 1550 | 0.00% | 0.81% |
| 1600 | 0.00% | 0.81% |
| 1650 | 0.00% | 0.81% |
| 1700 | 0.00% | 0.81% |
| 1750 | 0.00% | 0.81% |
| 1800 | 0.00% | 0.81% |
| 1850 | 0.00% | 0.81% |
| 1900 | 0.00% | 0.81% |
| 1950 | 0.00% | 0.81% |
| 2000 | 0.00% | 0.81% |
| 2050 | 0.00% | 0.81% |
| 2100 | 0.00% | 0.81% |
| 2150 | 0.00% | 0.81% |

A evolução dos erros pode ser melhor visualizada na figura 5.1.

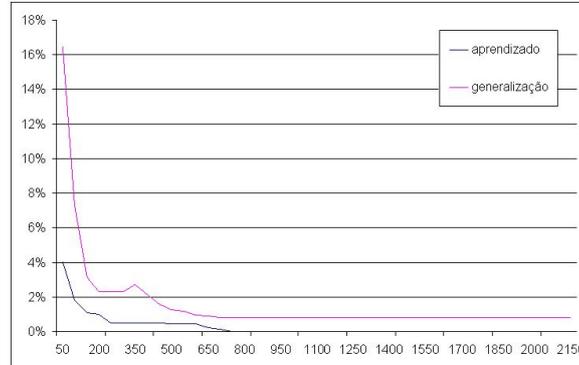


Figura 5.1: Evolução do erro de aprendizagem e de generalização da Rede7-2Plin

Por motivos de espaço não serão apresentadas aqui as tabelas de evolução dos erros de todas as redes 7-2 testadas nem suas representações gráficas, no entanto elas constam nos apêndices A e B, respectivamente.

5.1.1.2 Rede 7-10-2

Dentre as Redes 7-10-2, foram testadas as seguintes configurações:

- Rede7-10-2PlinPlin: rede com 10 neurônios na camada oculta e função de ativação Plin tanto na camada oculta quanto na camada de saída;
- Rede7-10-2LsigPlin: rede com 10 neurônios na camada oculta, função de ativação Lsig na camada oculta e Plin na camada de saída;
- Rede7-10-2TsigPlin: rede com 10 neurônios na camada oculta, função de ativação Tsig na camada oculta e Plin na camada de saída;

Está mostrado na tabela 5.2 a evolução do erro de aprendizagem e do erro de generalização para o treinamento da Rede 7-10-2PlinPlin.

Tabela 5.2: Evolução do erro de aprendizado e erro de generalização da Rede 7-10-2PlinPlin

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 5.07% | 11.13% |
| 100 | 2.02% | 3.45% |
| 150 | 1.27% | 1.14% |
| 200 | 0.45% | 0.91% |
| 250 | 0.45% | 1.34% |
| 300 | 0.40% | 1.21% |
| 350 | 0.38% | 1.06% |
| 400 | 0.38% | 1.01% |
| 450 | 0.36% | 0.90% |
| 500 | 0.34% | 0.86% |
| 550 | 0.32% | 0.81% |
| 600 | 0.30% | 0.81% |
| 650 | 0.28% | 0.81% |
| 700 | 0.27% | 0.81% |
| 750 | 0.27% | 0.81% |
| 800 | 0.20% | 0.81% |
| 850 | 0.15% | 0.81% |
| 900 | 0.11% | 0.81% |
| 950 | 0.09% | 0.81% |
| 1000 | 0.08% | 0.81% |
| 1050 | 0.06% | 0.81% |
| 1100 | 0.00% | 0.81% |
| 1150 | 0.00% | 0.81% |
| 1200 | 0.00% | 0.81% |
| 1250 | 0.00% | 0.81% |
| 1300 | 0.00% | 0.81% |
| 1350 | 0.00% | 0.81% |
| 1400 | 0.00% | 0.81% |
| 1450 | 0.00% | 0.81% |
| 1500 | 0.00% | 0.81% |
| 1550 | 0.00% | 0.81% |
| 1600 | 0.00% | 0.81% |
| 1650 | 0.00% | 0.81% |
| 1700 | 0.00% | 0.81% |
| 1750 | 0.00% | 0.81% |
| 1800 | 0.00% | 0.81% |
| 1850 | 0.00% | 0.81% |
| 1900 | 0.00% | 0.81% |
| 1950 | 0.00% | 0.81% |
| 2000 | 0.00% | 0.81% |
| 2050 | 0.00% | 0.81% |
| 2100 | 0.00% | 0.81% |
| 2150 | 0.00% | 0.81% |

A evolução dos erros pode ser melhor visualizada na figura 5.2.

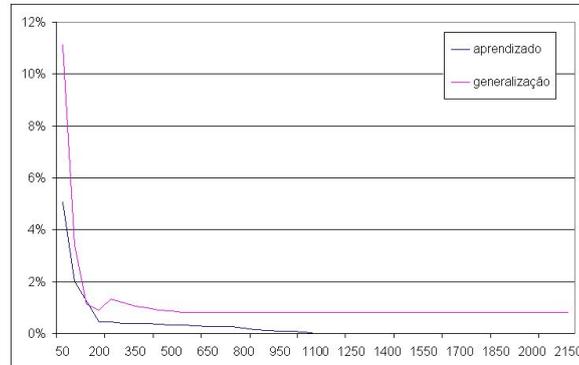


Figura 5.2: Evolução do erro de aprendizado e de generalização da Rede 7-10-2PlinPlin

Para observar a influência que a quantidade de neurônios da camada oculta causa no desempenho da rede, foram também estudadas as redes 7-12-2PlinPlin (rede com 12 neurônios na camada oculta e função de ativação Plin na camada oculta e na camada de saída) e 7-20-2PlinPlin (rede com 20 neurônios na camada oculta e função de ativação Plin na camada oculta e na camada de saída). Estas foram comparadas com a rede 7-10-2PlinPlin. Na figura 5.3 estão mostradas a evolução do erro de aprendizado das três redes diferentes.

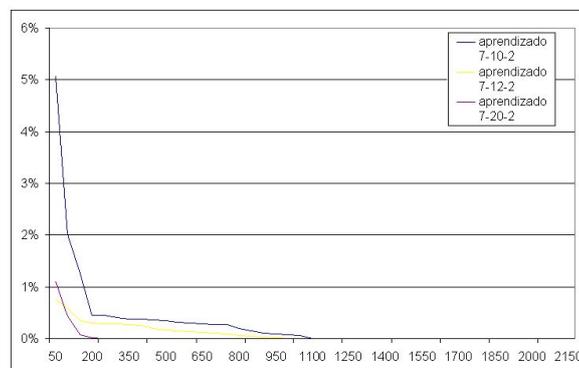


Figura 5.3: Evolução do erro de aprendizado das redes 7-10-2PlinPlin, 7-12-2PlinPlin e 7-20-2PlinPlin

Já na figura 5.4 estão mostradas a evolução do erro de generalização das três redes diferentes.

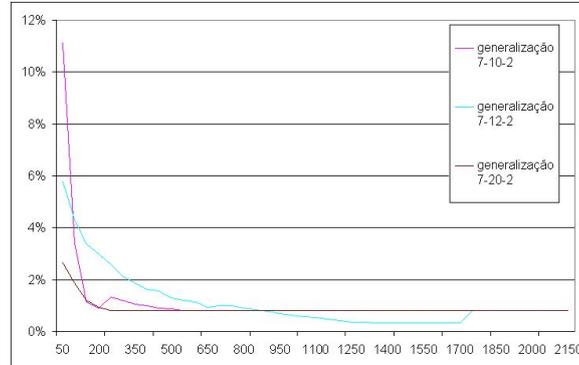


Figura 5.4: Evolução do erro de generalização das redes 7-10-2PlinPlin, 7-12-2PlinPlin e 7-20-2PlinPlin

Novamente, por motivos de espaço não serão apresentadas aqui as tabelas de evolução dos erros de todas as redes testadas nesta seção, nem suas representações gráficas, no entanto elas constam nos apêndices A e B, respectivamente.

5.1.1.3 Rede 7-10-10-2

Dentre as Redes 7-10-10-2, foram testadas as seguintes configurações:

- Rede7-10-10-2TsigPlinPlin: rede com 10 neurônios na primeira camada oculta e função de ativação Tsig, 10 neurônios na segunda camada oculta e função de ativação Plin, e função de ativação Plin na camada de saída.
- Rede7-10-10-2PLinTsigPlin: rede com 10 neurônios na primeira camada oculta e função de ativação Plin, 10 neurônios na segunda camada oculta e função de ativação Tsig, e função de ativação Plin na camada de saída.
- Rede7-10-10-2PlinPlinPlin: rede com 10 neurônios na primeira camada oculta e função de ativação Plin, 10 neurônios na segunda camada oculta e função de ativação Plin, e função de ativação Plin na camada de saída.

Está mostrado na tabela 5.3 a evolução do erro de aprendizado e do erro de generalização para o treinamento da Rede 7-10-10-2PlinPlinPlin.

Tabela 5.3: Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2PlinPlinPlin

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 1.23% | 6.76% |
| 100 | 0.57% | 1.68% |
| 150 | 0.25% | 0.34% |
| 200 | 0.06% | 0.81% |
| 250 | 0.00% | 0.81% |
| 300 | 0.00% | 0.81% |
| 350 | 0.00% | 0.81% |
| 400 | 0.00% | 0.81% |
| 450 | 0.00% | 0.81% |
| 500 | 0.00% | 0.81% |
| 550 | 0.00% | 0.81% |
| 600 | 0.00% | 0.81% |
| 650 | 0.00% | 0.81% |
| 700 | 0.00% | 0.81% |
| 750 | 0.00% | 0.81% |
| 800 | 0.00% | 0.81% |
| 850 | 0.00% | 0.81% |
| 900 | 0.00% | 0.81% |
| 950 | 0.00% | 0.81% |
| 1000 | 0.00% | 0.81% |
| 1050 | 0.00% | 0.81% |
| 1100 | 0.00% | 0.81% |
| 1150 | 0.00% | 0.81% |
| 1200 | 0.00% | 0.81% |
| 1250 | 0.00% | 0.81% |
| 1300 | 0.00% | 0.81% |
| 1350 | 0.00% | 0.81% |
| 1400 | 0.00% | 0.81% |
| 1450 | 0.00% | 0.81% |
| 1500 | 0.00% | 0.81% |
| 1550 | 0.00% | 0.81% |
| 1600 | 0.00% | 0.81% |
| 1650 | 0.00% | 0.81% |
| 1700 | 0.00% | 0.81% |
| 1750 | 0.00% | 0.81% |
| 1800 | 0.00% | 0.81% |
| 1850 | 0.00% | 0.81% |
| 1900 | 0.00% | 0.81% |
| 1950 | 0.00% | 0.81% |
| 2000 | 0.00% | 0.81% |
| 2050 | 0.00% | 0.81% |
| 2100 | 0.00% | 0.81% |
| 2150 | 0.00% | 0.81% |

Está mostrado na figura 5.5 a evolução do erro de aprendizado e do erro de generalização para o treinamento da Rede 7-10-10-2PlinPlinPlin.

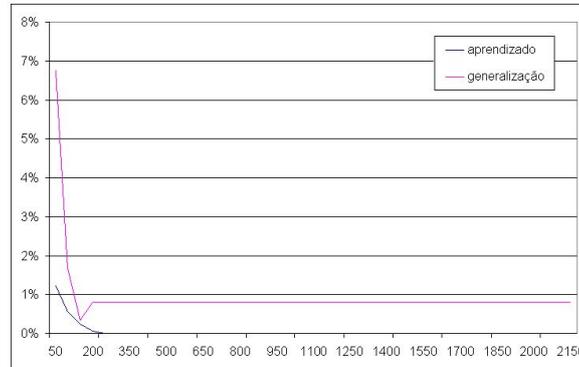


Figura 5.5: Evolução do erro de aprendizado e de generalização da Rede7-10-10-2PlinPlinPlin

Por motivos de espaço não serão apresentadas aqui as tabelas de evolução dos erros de todas as redes 7-10-10-2 testadas nem suas representações gráficas, no entanto elas constam nos apêndices A e B, respectivamente.

5.2 Litologia *Shale*

Para que seja possível fazer uma comparação entre os desempenhos e, desta maneira, escolher a rede com o melhor desempenho geral, as mesmas configurações de redes utilizadas nos testes com litologia *Hard Sand* foram utilizadas nos testes com litologia do tipo *Shale*.

5.2.1 Redes recorrentes

5.2.1.1 Rede 7-2

Está mostrado na tabela 5.4 a evolução do erro de aprendizado e do erro de generalização para o treinamento da Rede 7-2Plin.

Tabela 5.4: Evolução do erro de aprendizado e erro de generalização da Rede 7-2Plin

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 0.09% | 97.44% |
| 100 | 0.00% | 88.50% |
| 150 | 0.00% | 73.50% |
| 200 | 0.00% | 57.35% |
| 250 | 0.00% | 37.74% |
| 300 | 0.00% | 33.12% |
| 350 | 0.00% | 33.12% |
| 400 | 0.00% | 33.12% |
| 450 | 0.00% | 31.58% |
| 500 | 0.00% | 31.58% |
| 550 | 0.00% | 31.58% |
| 600 | 0.00% | 31.58% |
| 650 | 0.00% | 31.58% |
| 700 | 0.00% | 31.58% |
| 750 | 0.00% | 31.58% |
| 800 | 0.00% | 31.58% |
| 850 | 0.00% | 31.58% |
| 900 | 0.00% | 31.58% |
| 950 | 0.00% | 31.58% |
| 1000 | 0.00% | 31.58% |
| 1050 | 0.00% | 31.58% |
| 1100 | 0.00% | 31.58% |
| 1150 | 0.00% | 31.58% |
| 1200 | 0.00% | 31.58% |
| 1250 | 0.00% | 31.58% |
| 1300 | 0.00% | 31.58% |
| 1350 | 0.00% | 31.58% |
| 1400 | 0.00% | 31.58% |
| 1450 | 0.00% | 31.58% |
| 1500 | 0.00% | 31.58% |
| 1550 | 0.00% | 31.58% |
| 1600 | 0.00% | 31.58% |
| 1650 | 0.00% | 31.58% |
| 1700 | 0.00% | 31.58% |
| 1750 | 0.00% | 31.58% |
| 1800 | 0.00% | 31.58% |
| 1850 | 0.00% | 31.58% |
| 1900 | 0.00% | 31.58% |
| 1950 | 0.00% | 31.58% |
| 2000 | 0.00% | 31.58% |
| 2050 | 0.00% | 31.58% |
| 2100 | 0.00% | 31.58% |
| 2150 | 0.00% | 31.58% |

A evolução dos erros pode ser melhor visualizada na figura 5.6.

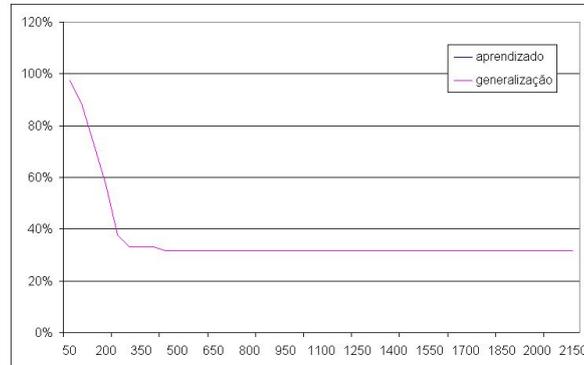


Figura 5.6: Evolução do erro de aprendizagem e de generalização da Rede 7-2Plin

Por motivos de espaço não serão apresentadas aqui as tabelas de evolução dos erros de todas as redes 7-2 testadas nem suas representações gráficas, no entanto elas constam nos apêndices A e B, respectivamente.

5.2.1.2 Rede 7-10-2

Está mostrado na tabela 5.5 a evolução do erro de aprendizagem e do erro de generalização para o treinamento da Rede 7-10-2PlinPlin.

Tabela 5.5: Evolução do erro de aprendizado e erro de generalização da Rede 7-10-2PlinPlin

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 4.96% | 113.38% |
| 100 | 2.74% | 115.43% |
| 150 | 1.87% | 120.04% |
| 200 | 1.87% | 117.74% |
| 250 | 1.87% | 91.58% |
| 300 | 1.87% | 78.12% |
| 350 | 1.87% | 78.12% |
| 400 | 0.36% | 78.12% |
| 450 | 0.00% | 75.68% |
| 500 | 0.00% | 75.68% |
| 550 | 0.00% | 75.68% |
| 600 | 0.00% | 75.68% |
| 650 | 0.00% | 71.07% |
| 700 | 0.00% | 66.45% |
| 750 | 0.00% | 66.45% |
| 800 | 0.00% | 66.45% |
| 850 | 0.00% | 66.45% |
| 900 | 0.00% | 64.91% |
| 950 | 0.00% | 61.45% |
| 1000 | 0.00% | 52.22% |
| 1050 | 0.00% | 52.22% |
| 1100 | 0.00% | 52.22% |
| 1150 | 0.00% | 36.07% |
| 1200 | 0.00% | 29.15% |
| 1250 | 0.00% | 29.15% |
| 1300 | 0.00% | 29.15% |
| 1350 | 0.00% | 29.15% |
| 1400 | 0.00% | 27.82% |
| 1450 | 0.00% | 27.82% |
| 1500 | 0.00% | 27.82% |
| 1550 | 0.00% | 27.82% |
| 1600 | 0.00% | 27.82% |
| 1650 | 0.00% | 27.82% |
| 1700 | 0.00% | 27.82% |
| 1750 | 0.00% | 27.82% |
| 1800 | 0.00% | 27.82% |
| 1850 | 0.00% | 27.82% |
| 1900 | 0.00% | 27.82% |
| 1950 | 0.00% | 27.82% |
| 2000 | 0.00% | 27.82% |
| 2050 | 0.00% | 27.82% |
| 2100 | 0.00% | 27.82% |
| 2150 | 0.00% | 27.82% |

A evolução dos erros pode ser melhor visualizada na figura 5.7.

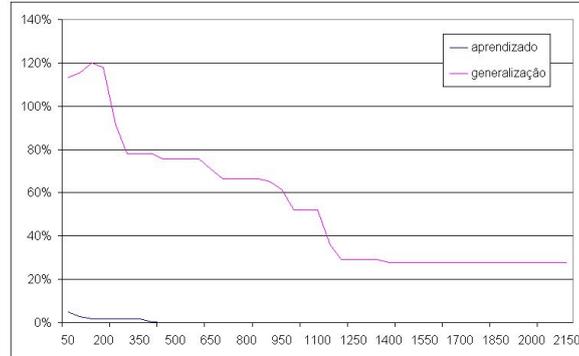


Figura 5.7: Evolução do erro de aprendizado e de generalização da Rede 7-10-2PlinPlin

Novamente, foram também estudadas as redes 7-12-2PlinPlin e 7-20-2PlinPlin. Estas foram comparadas com a rede 7-10-2PlinPlin. Na figura 5.8 estão mostradas a evolução do erro de aprendizado das três redes diferentes.

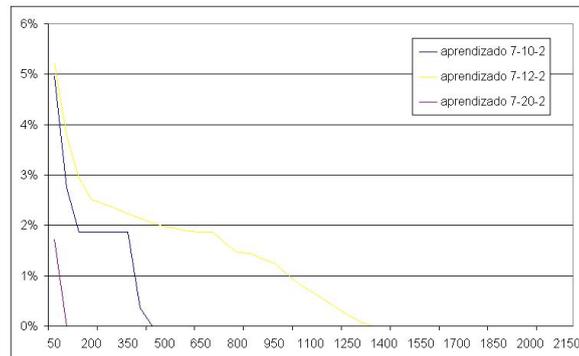


Figura 5.8: Evolução do erro de aprendizado das redes 7-10-2PlinPlin, 7-12-2PlinPlin e 7-20-2PlinPlin

Já na figura 5.9 estão mostradas a evolução do erro de generalização das três redes diferentes.

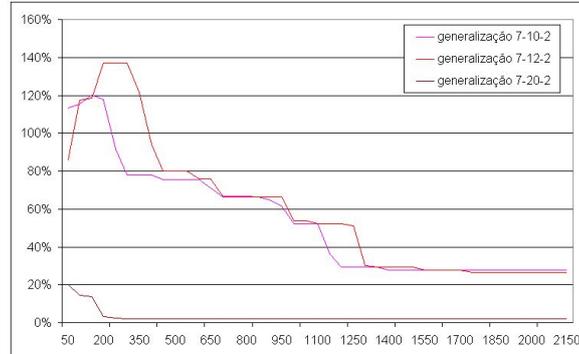


Figura 5.9: Evolução do erro de generalização das redes 7-10-2PlinPlin, 7-12-2PlinPlin e 7-20-2PlinPlin

Novamente, por motivos de espaço não serão apresentadas aqui as tabelas de evolução dos erros de todas as redes testadas nesta seção, nem suas representações gráficas, no entanto elas constam nos apêndices A e B, respectivamente.

5.2.1.3 Rede 7-10-10-2

Está mostrado na tabela 5.6 a evolução do erro de aprendizado e do erro de generalização para o treinamento da Rede 7-10-10-2PlinPlinPlin.

Tabela 5.6: Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2PlinPlinPlin

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 0.00% | 29.36% |
| 100 | 0.00% | 26.67% |
| 150 | 0.00% | 24.74% |
| 200 | 0.00% | 24.74% |
| 250 | 0.00% | 24.74% |
| 300 | 0.00% | 24.36% |
| 350 | 0.00% | 22.31% |
| 400 | 0.00% | 21.54% |
| 450 | 0.00% | 21.54% |
| 500 | 0.00% | 21.54% |
| 550 | 0.00% | 21.54% |
| 600 | 0.00% | 21.54% |
| 650 | 0.00% | 21.54% |
| 700 | 0.00% | 21.54% |
| 750 | 0.00% | 21.54% |
| 800 | 0.00% | 19.62% |
| 850 | 0.00% | 18.46% |
| 900 | 0.00% | 18.46% |
| 950 | 0.00% | 18.46% |
| 1000 | 0.00% | 18.46% |
| 1050 | 0.00% | 18.46% |
| 1100 | 0.00% | 16.92% |
| 1150 | 0.00% | 11.54% |
| 1200 | 0.00% | 9.62% |
| 1250 | 0.00% | 8.08% |
| 1300 | 0.00% | 8.08% |
| 1350 | 0.00% | 8.08% |
| 1400 | 0.00% | 8.46% |
| 1450 | 0.00% | 8.08% |
| 1500 | 0.00% | 5.77% |
| 1550 | 0.00% | 3.08% |
| 1600 | 0.00% | 0.77% |
| 1650 | 0.00% | 0.77% |
| 1700 | 0.00% | 0.77% |
| 1750 | 0.00% | 0.77% |
| 1800 | 0.00% | 0.77% |
| 1850 | 0.00% | 0.56% |
| 1900 | 0.00% | 0.56% |
| 1950 | 0.00% | 0.56% |
| 2000 | 0.00% | 2.09% |
| 2050 | 0.00% | 2.09% |
| 2100 | 0.00% | 2.09% |
| 2150 | 0.00% | 2.09% |

Está mostrado na figura 5.10 a evolução do erro de aprendizado e do erro de generalização para o treinamento da Rede 7-10-10-2PlinPlinPlin.

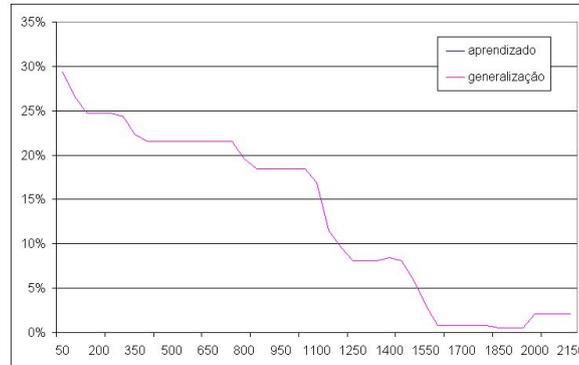


Figura 5.10: Evolução do erro de aprendizado e de generalização da Rede 7-10-10-2PlinPlinPlin

Por motivos de espaço não serão apresentadas aqui as tabelas de evolução dos erros de todas as redes 7-10-10-2 testadas nem suas representações gráficas, no entanto elas constam nos apêndices A e B, respectivamente.

5.3 Análise dos resultados

Com os resultados obtidos até aqui podemos fazer a escolha da rede que apresentou o melhor desempenho. Para tanto, foi escolhido como critério de escolha em primeiro lugar a rede que apresentou menor erro de aprendizado, em segundo lugar a rede com o menor erro de generalização e em terceiro lugar quantos ciclos de treinamento foram necessários para se alcançar este nível de treinamento.

5.3.1 Litologia *Hard Sand*

A rede 7-2 com o melhor desempenho observado foi a rede 7-2Plin. Para esta rede, o erro de aprendizado se torna praticamente desprezível após 750 ciclos de treinamento, e o erro de generalização mínimo obtido é de 0.81%, um valor um tanto quanto razoável. Já as redes 7-2Tsig e 7-2Lsig não conseguem apresentar um erro de aprendizado menor do que 2.61% e um erro de generalização menor do que 16.16% dentro de 2150 ciclos de treinamento. Isto sugere que a melhor função de ativação a ser utilizada nas outras configurações é a Plin.

Dentre as redes 7-10-2 testadas, a que apresentou o melhor desempenho foi a rede 7-10-2PlinPlin. As redes 7-10-2TsigPlin e 7-10-2LsigPlin apresentaram desempenho bastante similar entre si, mas muito inferior ao da 7-10-2PlinPlin. Novamente observa-se a presença da função de ativação Plin na rede com o melhor desempenho. No entanto, apesar de ser a rede com melhor desempenho dentre as

redes 7-10-2, ela levou 1100 ciclos de treinamento para atingir o erro mínimo de aprendizado, 350 ciclos a mais do que a rede 7-2. Isto sugere que o número de neurônios na camada oculta é insuficiente.

Para observar a influência da quantidade de neurônios no desempenho da rede foram testadas as redes 7-12-2PlinPlin e 7-20-2PlinPlin. Enquanto para a rede 7-10-2PlinPlin foram necessários 1100 ciclos de treinamento para eliminar o erro de aprendizado, para a rede 7-20-2PlinPlin foram necessários apenas 250 ciclos de treinamento, confirmando assim as suspeitas.

Por fim foram treinadas as redes 7-10-10-2. Como a função Lsig esteve presente nas redes anteriores que apresentaram o pior desempenho, ela não foi incluída nos treinamentos das redes com duas camadas ocultas. Observando o desempenho destas redes, verificamos que a rede com o melhor desempenho foi novamente a rede em que utilizou-se unicamente a função de ativação Plin. E, de maneira similar à rede 7-20-2PlinPlin, apresentou o mesmo erro de generalização e necessitou de apenas 250 ciclos de treinamento para não apresentar erro de aprendizado. Enfim, não houve ganhos consideráveis que justificassem a escolha de uma rede com duas camadas ocultas quando uma rede com uma camada oculta e um número suficiente de neurônios apresenta uma performance equivalente.

Assim, a rede escolhida como de melhor desempenho na primeira etapa foi a rede 7-20-2PlinPlin.

5.3.2 Litologia Shale

Dentre as redes 7-2 testadas, novamente a rede 7-2Plin é a que apresenta o melhor desempenho. O erro de aprendizado desaparece após 100 ciclos de treinamento, mas o erro mínimo de generalização se mantém em patamares elevados, em torno de 31.58%. Já as redes 7-2Tsig e 7-2Lsig não conseguem apresentar um erro de aprendizado menor do que 2.04% e um erro de generalização menor do que 36.45% dentro de 2150 ciclos de treinamento.

Observando a performance das três redes 7-10-2 testadas, percebe-se que a rede 7-10-2LsigPlin é de longe a que apresenta o pior desempenho, enquanto à primeira vista a rede 7-10-2TsigPlin parece apresentar o melhor desempenho. No entanto, lembrando que em todos os testes realizados até aqui as redes que apresentam apenas função de ativação linear foram as que responderam com um erro menor, uma comparação mais profunda entre o desempenho das redes 7-10-2TsigPlin e 7-10-2PlinPlin foi realizado. Assim, foi observado o erro que as redes apresentaram em relação a sete outros pares do conjunto de treinamento, e como resultado verificou-se que em relação à soma destes erros a rede 7-10-2PlinPlin apresentou o melhor desempenho. Entretanto, esta rede apresentou um erro de generalização de 27.82%, um erro que pode ser considerado alto. Novamente, foram estudadas duas outras redes para verificar a influência da quantidade de neurônios na camada oculta no desempenho da rede. Com a rede 7-12-2PlinPlin e com a rede 7-20-2PlinPlin o erro de generalização caiu respectivamente para 26.7% e 2.09%.

Dentre as redes 7-10-10-2 testadas, a que apresentou o melhor desempenho foi a 7-10-10-2PlinPlinPlin, apresentando um erro de generalização de 2.09% após 2150 ciclos de treinamento. No entanto, ela

chegou a apresentar um erro mínimo de generalização de 0.56% após 1850 ciclos de treinamento. Cabe dizer também que todas as redes 7-10-10-2 testadas anularam o erro de aprendizado.

Assim, de acordo com os critérios estabelecidos, a rede escolhida como de melhor desempenho na segunda etapa foi a rede 7-10-10-2PlinPlinPlin, quando submetida entre 1850 e 1950 ciclos de treinamento.

No geral, observou-se que as redes com função de ativação puramente linear foram as que apresentaram o melhor desempenho. O leitor mais atento pode indagar que isso vai contra as observações iniciais de que os modelos de desgaste de brocas não são lineares, pois se assim fosse as redes que supostamente teriam melhor desempenho seriam as com função de ativação não linear como *Lsig* e *Tsig*.

No entanto, cabe lembrar que o trabalho foi todo feito em cima de um simulador cujo modelo de desgaste da broca não é dos mais complexos. Maiores informações sobre o modelo utilizado no simulador podem ser encontrados em [40]. Maiores informações sobre os modelos utilizados em outros trabalhos podem ser conseguidas em [29], [33], [34], [35], [36], [37], [38], [39].

5.4 Litologia Composta

Nesta seção será mostrado o resultado dos testes feitos aonde a rede neuronal tenta prever o desgaste da broca em uma litologia composta por uma seção de litologia do tipo *Shale* e uma seção de litologia do tipo *Hard Sand*.

Foi utilizada uma rede do tipo 8-20-2PlinPlin (vinte neurônios na camada oculta e função de ativação Plin tanto na camada oculta quanto na camada de saída). Cabe lembrar aqui que a rede utilizada nesta etapa possui oito nós de entrada pois como foram utilizados dois tipos de litologia diferentes na formação rochosa criada, e em cada tipo o desgaste da broca se dá de maneira diferente, a rede precisa saber qual litologia está sendo perfurada

As variáveis de perfuração obtidas durante a perfuração da formação criada foram apresentadas à entrada da rede, que por sua vez inferiu um desgaste bastante próximo ao obtido no simulador. Pode-se ver na figura 5.11, em azul, o desgaste do dente da broca obtido no simulador e, em vermelho, o desgaste obtido na saída da rede. O erro médio quadrático obtido para o desgaste de dente foi de 0.41%.

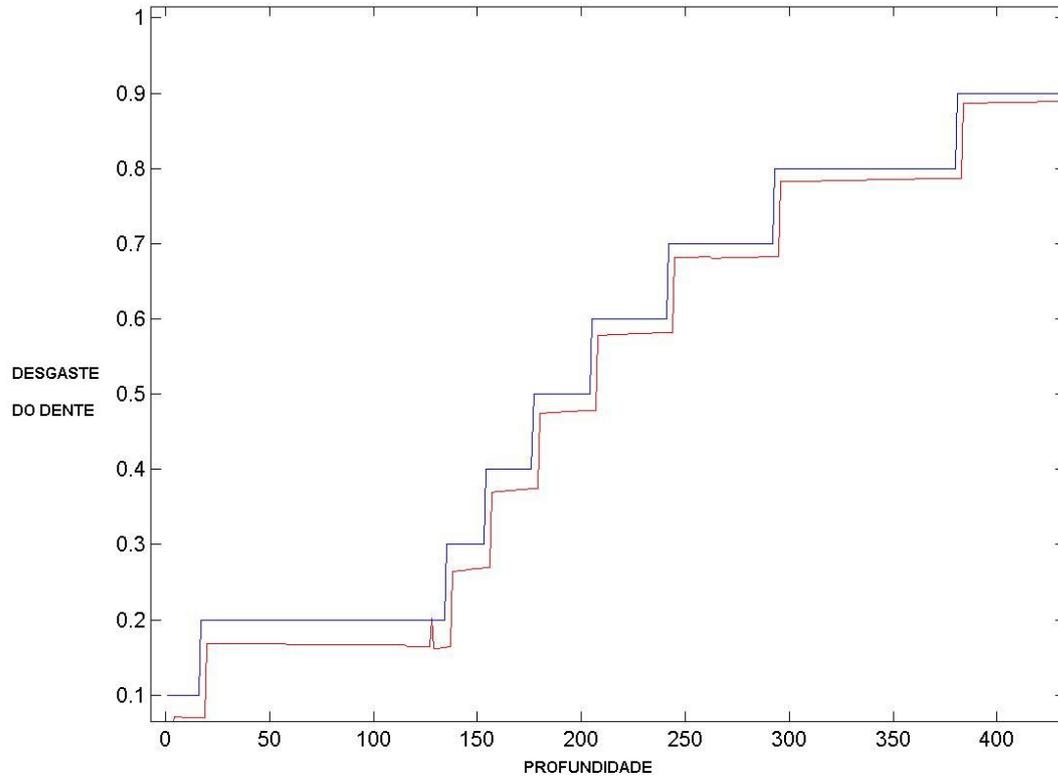


Figura 5.11: Comparação entre o desgaste do dente da broca obtido pela Rede8-20-2PlinPlin e obtido diretamente no simulador

Na figura 5.12 pode-se ver em azul o desgaste do rolamento da broca obtido no simulador e, em vermelho, o desgaste obtido na saída da rede. O erro médio quadrático obtido para o desgaste de rolamento foi de 0.56%.

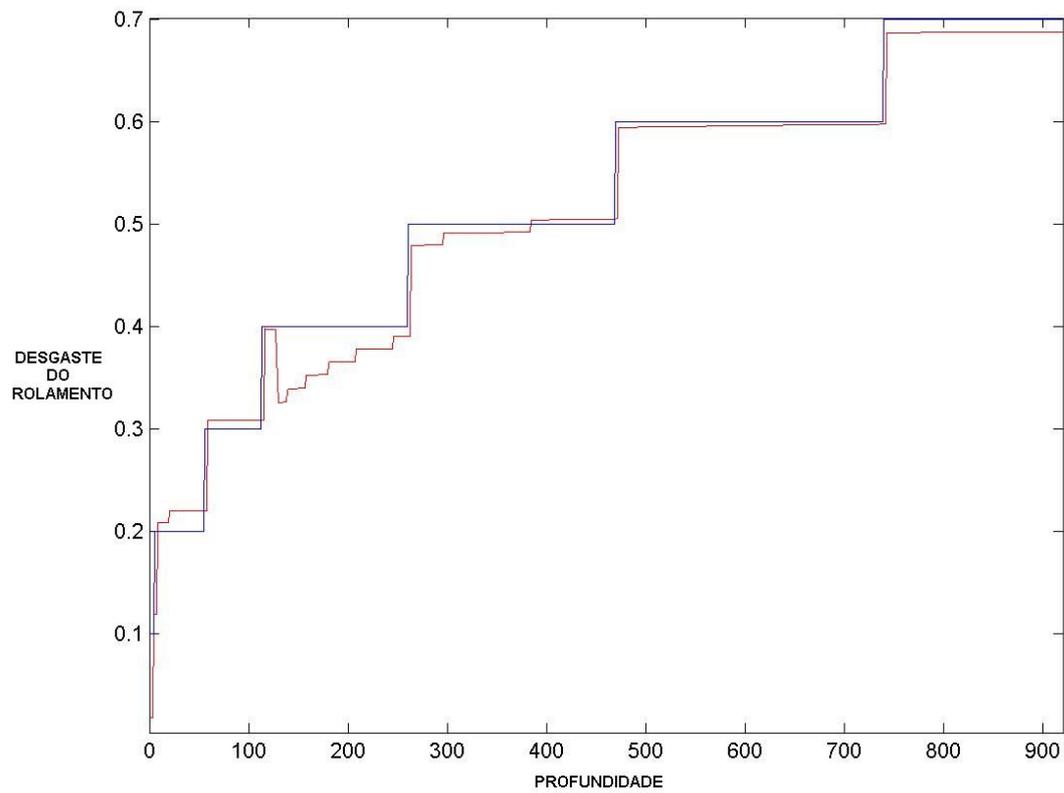


Figura 5.12: Comparação entre o desgaste do rolamento da broca obtido pela Rede8-20-2PlinPlin e obtido diretamente no simulador

Capítulo 6

Conclusões

Neste capítulo apresenta-se a conclusão do trabalho a partir dos resultados obtidos, demonstrando sua validade e fazendo sugestões para trabalhos futuros.

Neste trabalho procurou-se demonstrar a viabilidade da utilização de inteligência artificial, mais particularmente redes neurais artificiais, para prever o desgaste de brocas de perfuração de poços de petróleo.

Para tanto, foi desenvolvida uma metodologia específica para o problema de interesse. Seguindo esta metodologia foi possível obter resultados bastante satisfatórios, como indicado no capítulo 5, que viabilizam o prosseguimento de estudos nesta linha a fim de se obter um equipamento de instrumentação de auxílio ao sondador.

Como já foi dito na introdução, uma das motivações para centrar esforços no desenvolvimento de tal equipamento é que as técnicas mais utilizadas hoje em dia para inferir o desgaste de brocas, baseiam-se em modelos matemáticos muito complexos, imprecisos e de difícil solução. Por outro lado, sabe-se que toda perfuração de poço é completamente monitorada, e a evolução dos dados de perfuração fica armazenada. Assim, como ficou demonstrado pelos resultados do presente trabalho, juntando as informações de um grande número de perfurações de poços em um grande banco de dados, é possível treinar redes para que sejam capazes de inferir o desgaste de brocas. Esta nova abordagem se mostrou razoavelmente precisa e muito mais simples, com exceção da carga de trabalho exigida pelo tratamento dos dados, do que as abordagens tradicionais.

Apesar dos resultados obtidos, não há subsídios suficientes para afirmar que o equipamento a ser desenvolvido atingirá os objetivos propostos, visto que há ainda uma etapa de validação das redes neurais com dados obtidos de perfurações reais que precisa ser feita. Entretanto, o presente trabalho

indicou que existe uma forte probabilidade de que isso ocorra e ainda desenvolveu uma metodologia possível de ser empregada caso este equipamento venha a ser desenvolvido no futuro.

Como consequência dos resultados aqui obtidos, este trabalho foi publicado no “*2o. Congresso Brasileiro de Petróleo & Gás*”, ocorrido no ano de 2003 na cidade do Rio de Janeiro, e também foi apresentado no “*SPE - South American and Caribbean Student Paper Contest*”, que aconteceu em 2003 na cidade de Macaé.

Para trabalhos futuros, seria interessante estudar o desempenho de outros algoritmos de treinamento dentro da metodologia proposta, bem como fazer apresentação aleatória dos pares de entrada/saída durante o treinamento. Um estudo mais aprofundado, utilizando outras litologias também seria interessante para dar mais consistência aos resultados obtidos.

Apêndice A

Tabelas

Litologia Hard Sand

Tabela A.1: Evolução do erro de aprendizado e erro de generalização da Rede 7-2TSig

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 18.86% | 65.89% |
| 100 | 19.36% | 65.89% |
| 150 | 18.86% | 65.89% |
| 200 | 18.03% | 64.48% |
| 250 | 17.03% | 64.48% |
| 300 | 14.95% | 63.38% |
| 350 | 13.77% | 63.38% |
| 400 | 13.51% | 53.65% |
| 450 | 12.60% | 53.65% |
| 500 | 10.55% | 53.18% |
| 550 | 10.46% | 52.41% |
| 600 | 10.38% | 49.18% |
| 650 | 9.63% | 49.18% |
| 700 | 8.35% | 49.18% |
| 750 | 7.66% | 43.52% |
| 800 | 7.20% | 41.79% |
| 850 | 6.92% | 41.79% |
| 900 | 6.90% | 42.26% |
| 950 | 6.68% | 41.14% |
| 1000 | 6.12% | 41.14% |
| 1050 | 5.98% | 41.14% |
| 1100 | 5.69% | 39.39% |
| 1150 | 5.15% | 31.84% |
| 1200 | 4.53% | 31.84% |
| 1250 | 4.31% | 31.84% |
| 1300 | 4.09% | 31.84% |
| 1350 | 3.86% | 31.84% |
| 1400 | 3.62% | 30.60% |
| 1450 | 3.58% | 29.54% |
| 1500 | 3.58% | 24.79% |
| 1550 | 3.58% | 24.79% |
| 1600 | 3.58% | 23.54% |
| 1650 | 3.58% | 21.44% |
| 1700 | 3.31% | 21.44% |
| 1750 | 3.09% | 21.44% |
| 1800 | 3.07% | 21.44% |
| 1850 | 3.04% | 19.66% |
| 1900 | 3.02% | 18.09% |
| 1950 | 2.97% | 18.09% |
| 2000 | 2.93% | 18.09% |
| 2050 | 2.81% | 17.91% |
| 2100 | 2.69% | 17.21% |
| 2150 | 2.61% | 16.16% |

Tabela A.2: Evolução do erro de aprendizado e erro de generalização da Rede 7-2LSig

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 67.50% | 35.57% |
| 100 | 35.62% | 5.00% |
| 150 | 10.40% | 10.93% |
| 200 | 6.80% | 34.55% |
| 250 | 8.58% | 47.96% |
| 300 | 10.86% | 50.59% |
| 350 | 12.95% | 54.00% |
| 400 | 13.05% | 55.53% |
| 450 | 13.11% | 61.67% |
| 500 | 13.27% | 63.71% |
| 550 | 13.36% | 64.48% |
| 600 | 13.44% | 64.48% |
| 650 | 13.42% | 63.71% |
| 700 | 13.43% | 59.62% |
| 750 | 13.40% | 57.58% |
| 800 | 13.37% | 55.53% |
| 850 | 12.75% | 54.43% |
| 900 | 12.69% | 54.43% |
| 950 | 12.65% | 54.43% |
| 1000 | 11.93% | 52.90% |
| 1050 | 11.63% | 50.59% |
| 1100 | 11.14% | 50.59% |
| 1150 | 10.43% | 50.59% |
| 1200 | 10.18% | 50.59% |
| 1250 | 9.41% | 49.80% |
| 1300 | 9.05% | 49.80% |
| 1350 | 8.99% | 49.80% |
| 1400 | 8.98% | 47.45% |
| 1450 | 8.83% | 42.26% |
| 1500 | 8.12% | 41.14% |
| 1550 | 6.94% | 41.14% |
| 1600 | 6.76% | 41.14% |
| 1650 | 6.40% | 40.66% |
| 1700 | 6.40% | 40.66% |
| 1750 | 6.37% | 38.15% |
| 1800 | 6.07% | 37.52% |
| 1850 | 5.65% | 36.99% |
| 1900 | 5.43% | 35.22% |
| 1950 | 5.36% | 29.07% |
| 2000 | 4.09% | 29.07% |
| 2050 | 4.09% | 29.07% |
| 2100 | 3.83% | 28.91% |
| 2150 | 3.83% | 28.91% |

Tabela A.3: Evolução do erro de aprendizado e erro de generalização da Rede 7-10-2TsigPlin

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 5.58% | 29.36% |
| 100 | 1.59% | 9.98% |
| 150 | 0.98% | 5.88% |
| 200 | 0.51% | 4.86% |
| 250 | 0.53% | 4.17% |
| 300 | 0.49% | 3.66% |
| 350 | 0.46% | 3.10% |
| 400 | 0.44% | 3.14% |
| 450 | 0.42% | 3.15% |
| 500 | 0.41% | 2.67% |
| 550 | 0.39% | 2.60% |
| 600 | 0.38% | 2.59% |
| 650 | 0.38% | 2.59% |
| 700 | 0.38% | 2.52% |
| 750 | 0.36% | 2.51% |
| 800 | 0.36% | 2.51% |
| 850 | 0.36% | 2.30% |
| 900 | 0.35% | 2.30% |
| 950 | 0.35% | 2.30% |
| 1000 | 0.35% | 2.29% |
| 1050 | 0.35% | 2.29% |
| 1100 | 0.34% | 2.29% |
| 1150 | 0.34% | 2.29% |
| 1200 | 0.34% | 2.28% |
| 1250 | 0.32% | 2.28% |
| 1300 | 0.32% | 2.24% |
| 1350 | 0.31% | 2.24% |
| 1400 | 0.30% | 2.24% |
| 1450 | 0.30% | 2.24% |
| 1500 | 0.28% | 2.24% |
| 1550 | 0.28% | 2.24% |
| 1600 | 0.28% | 2.24% |
| 1650 | 0.26% | 2.17% |
| 1700 | 0.26% | 2.17% |
| 1750 | 0.26% | 2.18% |
| 1800 | 0.25% | 2.18% |
| 1850 | 0.25% | 2.18% |
| 1900 | 0.23% | 2.16% |
| 1950 | 0.23% | 2.16% |
| 2000 | 0.23% | 2.16% |
| 2050 | 0.22% | 2.17% |
| 2100 | 0.21% | 2.17% |
| 2150 | 0.21% | 2.17% |

Tabela A.4: Evolução do erro de aprendizado e erro de generalização da Rede 7-10-2LsigPlin

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 3.62% | 8.78% |
| 100 | 2.11% | 7.30% |
| 150 | 1.59% | 4.87% |
| 200 | 1.21% | 4.91% |
| 250 | 0.83% | 4.30% |
| 300 | 0.68% | 3.04% |
| 350 | 0.61% | 2.79% |
| 400 | 0.55% | 2.59% |
| 450 | 0.51% | 2.54% |
| 500 | 0.45% | 2.46% |
| 550 | 0.43% | 2.41% |
| 600 | 0.41% | 2.40% |
| 650 | 0.40% | 2.34% |
| 700 | 0.39% | 2.30% |
| 750 | 0.37% | 2.28% |
| 800 | 0.38% | 2.21% |
| 850 | 0.38% | 2.16% |
| 900 | 0.38% | 2.13% |
| 950 | 0.38% | 2.12% |
| 1000 | 0.39% | 2.10% |
| 1050 | 0.38% | 2.08% |
| 1100 | 0.38% | 2.07% |
| 1150 | 0.37% | 2.08% |
| 1200 | 0.37% | 1.93% |
| 1250 | 0.38% | 1.98% |
| 1300 | 0.37% | 1.97% |
| 1350 | 0.37% | 1.97% |
| 1400 | 0.37% | 1.96% |
| 1450 | 0.36% | 1.96% |
| 1500 | 0.36% | 1.95% |
| 1550 | 0.36% | 1.94% |
| 1600 | 0.35% | 1.93% |
| 1650 | 0.35% | 1.94% |
| 1700 | 0.35% | 1.94% |
| 1750 | 0.35% | 1.92% |
| 1800 | 0.32% | 1.92% |
| 1850 | 0.32% | 1.91% |
| 1900 | 0.32% | 1.91% |
| 1950 | 0.31% | 1.90% |
| 2000 | 0.30% | 1.90% |
| 2050 | 0.30% | 1.90% |
| 2100 | 0.30% | 1.88% |
| 2150 | 0.28% | 1.88% |

Tabela A.5: Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2TsigPlinPlin

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 2.22% | 14.58% |
| 100 | 1.71% | 7.86% |
| 150 | 1.14% | 4.07% |
| 200 | 0.88% | 2.34% |
| 250 | 0.65% | 1.76% |
| 300 | 0.57% | 1.44% |
| 350 | 0.54% | 1.17% |
| 400 | 0.51% | 0.90% |
| 450 | 0.50% | 0.73% |
| 500 | 0.33% | 0.63% |
| 550 | 0.32% | 0.67% |
| 600 | 0.32% | 0.58% |
| 650 | 0.32% | 0.59% |
| 700 | 0.32% | 0.62% |
| 750 | 0.32% | 0.65% |
| 800 | 0.32% | 0.66% |
| 850 | 0.32% | 0.72% |
| 900 | 0.32% | 0.66% |
| 950 | 0.32% | 0.66% |
| 1000 | 0.32% | 0.68% |
| 1050 | 0.32% | 0.68% |
| 1100 | 0.32% | 0.69% |
| 1150 | 0.32% | 0.71% |
| 1200 | 0.32% | 0.71% |
| 1250 | 0.32% | 0.71% |
| 1300 | 0.33% | 0.71% |
| 1350 | 0.33% | 0.71% |
| 1400 | 0.33% | 0.71% |
| 1450 | 0.33% | 0.64% |
| 1500 | 0.48% | 0.65% |
| 1550 | 0.49% | 0.65% |
| 1600 | 0.49% | 0.65% |
| 1650 | 0.49% | 0.65% |
| 1700 | 0.49% | 0.65% |
| 1750 | 0.49% | 0.64% |
| 1800 | 0.49% | 0.64% |
| 1850 | 0.49% | 0.64% |
| 1900 | 0.49% | 0.64% |
| 1950 | 0.49% | 0.64% |
| 2000 | 0.49% | 0.64% |
| 2050 | 0.49% | 0.64% |
| 2100 | 0.49% | 0.64% |
| 2150 | 0.49% | 0.64% |

Tabela A.6: Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2PlinTsigPlin

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 0.90% | 2.63% |
| 100 | 0.88% | 5.08% |
| 150 | 0.69% | 5.76% |
| 200 | 0.38% | 5.81% |
| 250 | 0.27% | 5.85% |
| 300 | 0.17% | 5.85% |
| 350 | 0.13% | 5.29% |
| 400 | 0.07% | 4.82% |
| 450 | 0.03% | 4.82% |
| 500 | 0.01% | 4.14% |
| 550 | 0.01% | 4.13% |
| 600 | 0.00% | 3.66% |
| 650 | 0.00% | 3.45% |
| 700 | 0.00% | 3.45% |
| 750 | 0.00% | 2.98% |
| 800 | 0.00% | 2.86% |
| 850 | 0.00% | 2.86% |
| 900 | 0.00% | 2.86% |
| 950 | 0.00% | 2.82% |
| 1000 | 0.00% | 2.82% |
| 1050 | 0.00% | 2.82% |
| 1100 | 0.00% | 2.82% |
| 1150 | 0.00% | 2.82% |
| 1200 | 0.00% | 2.75% |
| 1250 | 0.00% | 2.75% |
| 1300 | 0.00% | 2.75% |
| 1350 | 0.00% | 2.75% |
| 1400 | 0.00% | 2.71% |
| 1450 | 0.00% | 2.71% |
| 1500 | 0.00% | 2.71% |
| 1550 | 0.00% | 2.71% |
| 1600 | 0.00% | 2.71% |
| 1650 | 0.00% | 2.71% |
| 1700 | 0.00% | 2.71% |
| 1750 | 0.00% | 2.71% |
| 1800 | 0.00% | 2.71% |
| 1850 | 0.00% | 2.71% |
| 1900 | 0.00% | 2.67% |
| 1950 | 0.00% | 2.67% |
| 2000 | 0.00% | 2.67% |
| 2050 | 0.00% | 2.67% |
| 2100 | 0.00% | 2.67% |
| 2150 | 0.00% | 2.67% |

Tabela A.7: Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2PlinPlinTsig

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 3.57% | 15.72% |
| 100 | 2.11% | 7.52% |
| 150 | 1.70% | 4.55% |
| 200 | 1.09% | 1.24% |
| 250 | 0.89% | 0.92% |
| 300 | 0.78% | 1.00% |
| 350 | 0.69% | 0.99% |
| 400 | 0.54% | 0.93% |
| 450 | 0.58% | 0.93% |
| 500 | 0.52% | 0.93% |
| 550 | 0.46% | 0.94% |
| 600 | 0.45% | 0.92% |
| 650 | 0.40% | 0.89% |
| 700 | 0.34% | 0.73% |
| 750 | 0.33% | 0.73% |
| 800 | 0.29% | 0.66% |
| 850 | 0.28% | 0.65% |
| 900 | 0.27% | 0.65% |
| 950 | 0.27% | 0.61% |
| 1000 | 0.26% | 0.60% |
| 1050 | 0.25% | 0.60% |
| 1100 | 0.25% | 0.59% |
| 1150 | 0.24% | 0.59% |
| 1200 | 0.24% | 0.55% |
| 1250 | 0.23% | 0.54% |
| 1300 | 0.23% | 0.54% |
| 1350 | 0.22% | 0.54% |
| 1400 | 0.22% | 0.56% |
| 1450 | 0.21% | 0.58% |
| 1500 | 0.21% | 0.57% |
| 1550 | 0.21% | 0.57% |
| 1600 | 0.20% | 0.57% |
| 1650 | 0.20% | 0.50% |
| 1700 | 0.20% | 0.49% |
| 1750 | 0.20% | 0.49% |
| 1800 | 0.20% | 0.49% |
| 1850 | 0.20% | 0.49% |
| 1900 | 0.20% | 0.48% |
| 1950 | 0.20% | 0.48% |
| 2000 | 0.20% | 0.41% |
| 2050 | 0.20% | 0.41% |
| 2100 | 0.20% | 0.40% |
| 2150 | 0.20% | 0.40% |

Litologia *Shale*

Tabela A.8: Evolução do erro de aprendizado e erro de generalização da Rede 7-2Tsig

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 90.12% | 713.08% |
| 100 | 80.11% | 612.69% |
| 150 | 69.92% | 566.92% |
| 200 | 61.31% | 509.27% |
| 250 | 55.08% | 464.79% |
| 300 | 46.49% | 414.79% |
| 350 | 39.95% | 339.40% |
| 400 | 34.92% | 333.63% |
| 450 | 30.71% | 288.63% |
| 500 | 28.05% | 259.79% |
| 550 | 25.28% | 235.56% |
| 600 | 23.22% | 225.51% |
| 650 | 21.77% | 210.13% |
| 700 | 19.73% | 194.36% |
| 750 | 17.72% | 160.13% |
| 800 | 15.72% | 149.36% |
| 850 | 13.08% | 145.77% |
| 900 | 11.31% | 141.15% |
| 950 | 10.19% | 126.68% |
| 1000 | 9.02% | 119.53% |
| 1050 | 8.22% | 119.15% |
| 1100 | 7.91% | 113.38% |
| 1150 | 7.61% | 101.84% |
| 1200 | 7.31% | 91.07% |
| 1250 | 7.02% | 77.99% |
| 1300 | 6.72% | 73.76% |
| 1350 | 6.41% | 71.45% |
| 1400 | 6.13% | 71.45% |
| 1450 | 5.86% | 69.02% |
| 1500 | 5.59% | 66.45% |
| 1550 | 5.40% | 66.45% |
| 1600 | 4.97% | 66.45% |
| 1650 | 4.77% | 64.15% |
| 1700 | 4.56% | 61.84% |
| 1750 | 4.28% | 59.53% |
| 1800 | 3.89% | 57.22% |
| 1850 | 3.56% | 52.61% |
| 1900 | 3.26% | 47.99% |
| 1950 | 2.92% | 45.68% |
| 2000 | 2.64% | 43.38% |
| 2050 | 2.47% | 41.07% |
| 2100 | 2.19% | 38.76% |
| 2150 | 2.04% | 36.45% |

Tabela A.9: Evolução do erro de aprendizado e erro de generalização da Rede 7-2Lsig

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 525.79% | 1572.31% |
| 100 | 503.51% | 1566.70% |
| 150 | 455.23% | 1321.20% |
| 200 | 348.10% | 921.58% |
| 250 | 239.99% | 574.62% |
| 300 | 169.83% | 365.30% |
| 350 | 121.83% | 259.66% |
| 400 | 105.25% | 177.35% |
| 450 | 88.58% | 169.27% |
| 500 | 83.26% | 130.43% |
| 550 | 73.62% | 111.58% |
| 600 | 79.43% | 113.50% |
| 650 | 71.26% | 113.50% |
| 700 | 71.26% | 113.50% |
| 750 | 71.26% | 113.50% |
| 800 | 70.42% | 112.35% |
| 850 | 67.84% | 112.35% |
| 900 | 66.18% | 67.74% |
| 950 | 64.87% | 67.74% |
| 1000 | 62.85% | 67.74% |
| 1050 | 62.96% | 67.74% |
| 1100 | 63.14% | 67.74% |
| 1150 | 63.40% | 67.74% |
| 1200 | 63.57% | 67.74% |
| 1250 | 62.61% | 67.74% |
| 1300 | 61.72% | 67.74% |
| 1350 | 60.84% | 67.74% |
| 1400 | 57.30% | 67.74% |
| 1450 | 57.30% | 67.74% |
| 1500 | 57.30% | 67.74% |
| 1550 | 57.30% | 67.74% |
| 1600 | 57.30% | 67.74% |
| 1650 | 57.30% | 67.74% |
| 1700 | 57.30% | 67.74% |
| 1750 | 57.30% | 67.74% |
| 1800 | 56.25% | 67.74% |
| 1850 | 56.22% | 67.74% |
| 1900 | 56.22% | 56.97% |
| 1950 | 56.22% | 56.97% |
| 2000 | 56.22% | 56.97% |
| 2050 | 56.22% | 56.97% |
| 2100 | 56.22% | 56.97% |
| 2150 | 54.80% | 56.97% |

Tabela A.10: Evolução do erro de aprendizado e erro de generalização da Rede 7-10-2TsigPlin

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 25.51% | 20.13% |
| 100 | 23.48% | 8.38% |
| 150 | 11.21% | 9.15% |
| 200 | 9.08% | 13.38% |
| 250 | 8.82% | 14.15% |
| 300 | 7.30% | 12.61% |
| 350 | 6.54% | 12.61% |
| 400 | 5.94% | 12.61% |
| 450 | 5.56% | 12.61% |
| 500 | 5.50% | 12.22% |
| 550 | 5.50% | 10.30% |
| 600 | 5.50% | 9.91% |
| 650 | 5.16% | 9.91% |
| 700 | 4.35% | 8.76% |
| 750 | 3.59% | 7.61% |
| 800 | 2.71% | 6.84% |
| 850 | 2.15% | 6.84% |
| 900 | 1.92% | 6.84% |
| 950 | 1.61% | 6.32% |
| 1000 | 1.09% | 0.17% |
| 1050 | 0.57% | 0.56% |
| 1100 | 0.46% | 0.56% |
| 1150 | 0.00% | 2.09% |
| 1200 | 0.00% | 2.09% |
| 1250 | 0.00% | 2.09% |
| 1300 | 0.00% | 2.09% |
| 1350 | 0.00% | 2.09% |
| 1400 | 0.00% | 2.09% |
| 1450 | 0.00% | 2.09% |
| 1500 | 0.00% | 2.09% |
| 1550 | 0.00% | 2.09% |
| 1600 | 0.00% | 2.09% |
| 1650 | 0.00% | 2.09% |
| 1700 | 0.00% | 2.09% |
| 1750 | 0.00% | 2.09% |
| 1800 | 0.00% | 2.09% |
| 1850 | 0.00% | 2.09% |
| 1900 | 0.00% | 2.09% |
| 1950 | 0.00% | 2.09% |
| 2000 | 0.00% | 2.09% |
| 2050 | 0.00% | 2.09% |
| 2100 | 0.00% | 2.09% |
| 2150 | 0.00% | 2.09% |

Tabela A.11: Evolução do erro de aprendizado e erro de generalização da Rede 7-10-2LsigPlin

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 17.05% | 146.20% |
| 100 | 9.73% | 74.53% |
| 150 | 6.13% | 27.69% |
| 200 | 6.71% | 26.15% |
| 250 | 6.49% | 26.15% |
| 300 | 6.41% | 25.17% |
| 350 | 6.61% | 11.84% |
| 400 | 6.61% | 6.84% |
| 450 | 6.61% | 6.84% |
| 500 | 6.61% | 6.84% |
| 550 | 6.61% | 6.84% |
| 600 | 6.59% | 6.84% |
| 650 | 6.53% | 6.84% |
| 700 | 6.51% | 6.84% |
| 750 | 6.49% | 6.84% |
| 800 | 6.46% | 6.84% |
| 850 | 6.19% | 6.84% |
| 900 | 5.87% | 6.84% |
| 950 | 5.61% | 6.84% |
| 1000 | 5.32% | 6.84% |
| 1050 | 5.07% | 6.84% |
| 1100 | 4.83% | 6.84% |
| 1150 | 4.33% | 6.84% |
| 1200 | 3.87% | 6.84% |
| 1250 | 3.64% | 6.84% |
| 1300 | 3.41% | 6.84% |
| 1350 | 3.22% | 6.84% |
| 1400 | 3.00% | 6.84% |
| 1450 | 2.81% | 6.84% |
| 1500 | 2.62% | 6.84% |
| 1550 | 2.48% | 6.84% |
| 1600 | 2.36% | 6.84% |
| 1650 | 2.22% | 6.84% |
| 1700 | 2.19% | 6.84% |
| 1750 | 2.16% | 6.84% |
| 1800 | 2.12% | 6.84% |
| 1850 | 2.08% | 6.84% |
| 1900 | 2.05% | 6.84% |
| 1950 | 2.02% | 6.84% |
| 2000 | 1.98% | 6.84% |
| 2050 | 1.94% | 6.84% |
| 2100 | 1.92% | 6.84% |
| 2150 | 1.88% | 6.84% |

Tabela A.12: Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2TsigPlinPlin

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 7.49% | 435.30% |
| 100 | 2.76% | 274.02% |
| 150 | 1.86% | 176.71% |
| 200 | 1.86% | 115.00% |
| 250 | 1.86% | 101.54% |
| 300 | 0.00% | 92.31% |
| 350 | 0.00% | 61.54% |
| 400 | 0.00% | 62.05% |
| 450 | 0.00% | 56.28% |
| 500 | 0.00% | 56.28% |
| 550 | 0.00% | 52.82% |
| 600 | 0.00% | 52.82% |
| 650 | 0.00% | 52.82% |
| 700 | 0.00% | 52.82% |
| 750 | 0.00% | 52.82% |
| 800 | 0.00% | 52.82% |
| 850 | 0.00% | 52.82% |
| 900 | 0.00% | 52.82% |
| 950 | 0.00% | 52.82% |
| 1000 | 0.00% | 52.82% |
| 1050 | 0.00% | 52.82% |
| 1100 | 0.00% | 48.21% |
| 1150 | 0.00% | 48.21% |
| 1200 | 0.00% | 48.21% |
| 1250 | 0.00% | 48.21% |
| 1300 | 0.00% | 48.21% |
| 1350 | 0.00% | 48.21% |
| 1400 | 0.00% | 48.21% |
| 1450 | 0.00% | 48.21% |
| 1500 | 0.00% | 48.21% |
| 1550 | 0.00% | 47.82% |
| 1600 | 0.00% | 47.82% |
| 1650 | 0.00% | 47.82% |
| 1700 | 0.00% | 47.82% |
| 1750 | 0.00% | 47.82% |
| 1800 | 0.00% | 47.82% |
| 1850 | 0.00% | 47.82% |
| 1900 | 0.00% | 47.82% |
| 1950 | 0.00% | 47.82% |
| 2000 | 0.00% | 47.82% |
| 2050 | 0.00% | 47.82% |
| 2100 | 0.00% | 47.82% |
| 2150 | 0.00% | 47.82% |

Tabela A.13: Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2PlinTsigPlin

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 2.54% | 9.62% |
| 100 | 2.22% | 3.46% |
| 150 | 2.22% | 6.54% |
| 200 | 1.73% | 6.54% |
| 250 | 1.44% | 6.54% |
| 300 | 1.39% | 6.54% |
| 350 | 0.35% | 14.23% |
| 400 | 0.00% | 14.23% |
| 450 | 0.00% | 14.23% |
| 500 | 0.00% | 14.23% |
| 550 | 0.00% | 18.46% |
| 600 | 0.00% | 19.62% |
| 650 | 0.00% | 19.62% |
| 700 | 0.00% | 22.31% |
| 750 | 0.00% | 24.62% |
| 800 | 0.00% | 27.31% |
| 850 | 0.00% | 27.31% |
| 900 | 0.00% | 27.31% |
| 950 | 0.00% | 27.31% |
| 1000 | 0.00% | 27.31% |
| 1050 | 0.00% | 27.31% |
| 1100 | 0.00% | 27.31% |
| 1150 | 0.00% | 27.31% |
| 1200 | 0.00% | 27.31% |
| 1250 | 0.00% | 27.31% |
| 1300 | 0.00% | 27.65% |
| 1350 | 0.00% | 27.82% |
| 1400 | 0.00% | 27.82% |
| 1450 | 0.00% | 27.82% |
| 1500 | 0.00% | 27.82% |
| 1550 | 0.00% | 27.82% |
| 1600 | 0.00% | 27.82% |
| 1650 | 0.00% | 27.82% |
| 1700 | 0.00% | 27.82% |
| 1750 | 0.00% | 27.82% |
| 1800 | 0.00% | 27.82% |
| 1850 | 0.00% | 27.82% |
| 1900 | 0.00% | 27.82% |
| 1950 | 0.00% | 27.82% |
| 2000 | 0.00% | 27.82% |
| 2050 | 0.00% | 27.82% |
| 2100 | 0.00% | 27.82% |
| 2150 | 0.00% | 27.82% |

Tabela A.14: Evolução do erro de aprendizado e erro de generalização da Rede 7-10-10-2PlinPlinTsig

| Ciclo | Aprendizado | Generalização |
|-------|-------------|---------------|
| 50 | 0.00% | 145.90% |
| 100 | 0.00% | 27.31% |
| 150 | 0.00% | 21.54% |
| 200 | 0.00% | 21.54% |
| 250 | 0.00% | 12.31% |
| 300 | 0.00% | 12.31% |
| 350 | 0.00% | 12.31% |
| 400 | 0.00% | 12.31% |
| 450 | 0.00% | 12.31% |
| 500 | 0.00% | 12.31% |
| 550 | 0.00% | 12.31% |
| 600 | 0.00% | 12.31% |
| 650 | 0.00% | 12.31% |
| 700 | 0.00% | 11.54% |
| 750 | 0.00% | 11.15% |
| 800 | 0.00% | 10.77% |
| 850 | 0.00% | 10.38% |
| 900 | 0.00% | 10.00% |
| 950 | 0.00% | 9.62% |
| 1000 | 0.00% | 8.85% |
| 1050 | 0.00% | 8.46% |
| 1100 | 0.00% | 8.08% |
| 1150 | 0.00% | 8.08% |
| 1200 | 0.00% | 8.08% |
| 1250 | 0.00% | 8.08% |
| 1300 | 0.00% | 8.08% |
| 1350 | 0.00% | 8.46% |
| 1400 | 0.00% | 8.46% |
| 1450 | 0.00% | 8.46% |
| 1500 | 0.00% | 8.46% |
| 1550 | 0.00% | 8.46% |
| 1600 | 0.00% | 8.46% |
| 1650 | 0.00% | 7.69% |
| 1700 | 0.00% | 6.54% |
| 1750 | 0.00% | 5.77% |
| 1800 | 0.00% | 4.62% |
| 1850 | 0.00% | 3.85% |
| 1900 | 0.00% | 2.69% |
| 1950 | 0.00% | 1.92% |
| 2000 | 0.00% | 0.77% |
| 2050 | 0.00% | 0.77% |
| 2100 | 0.00% | 0.77% |
| 2150 | 0.00% | 0.77% |

Apêndice B

Gráficos

Litologia *Hard Sand*

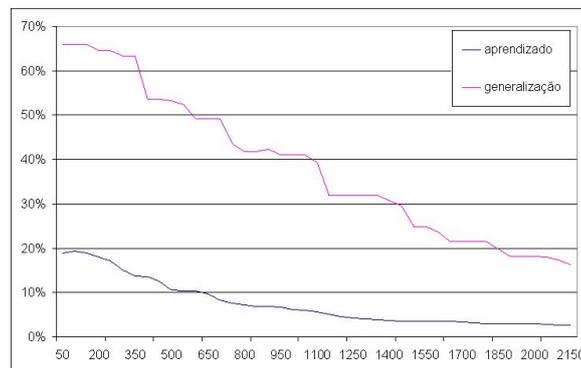


Figura B.1: Evolução do erro de aprendizado e de generalização da Rede7-2Tsig

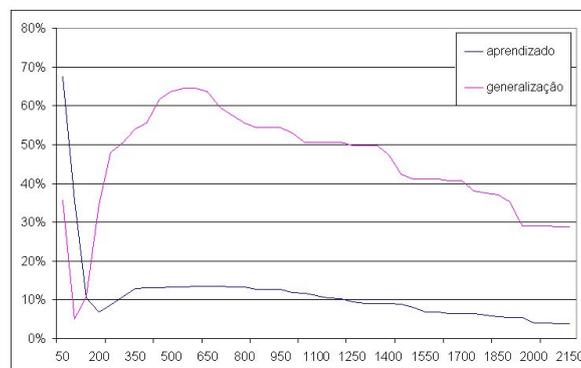


Figura B.2: Evolução do erro de aprendizado e de generalização da Rede7-2Lsig

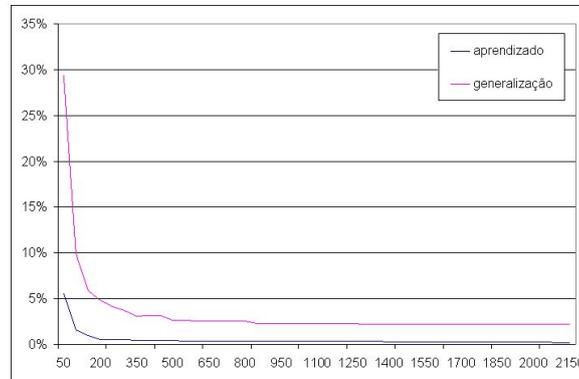


Figura B.3: Evolução do erro de aprendizado e de generalização da Rede7-10-2TsigPlin

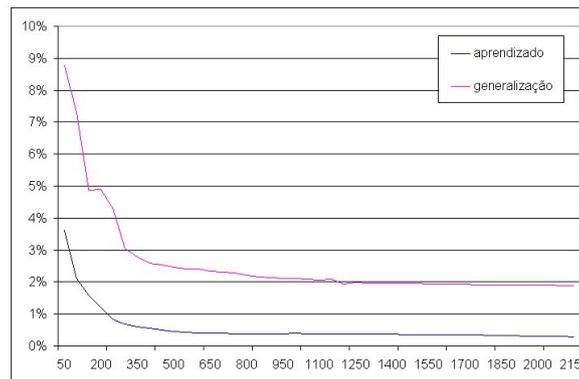


Figura B.4: Evolução do erro de aprendizado e de generalização da Rede7-10-2LsigPlin

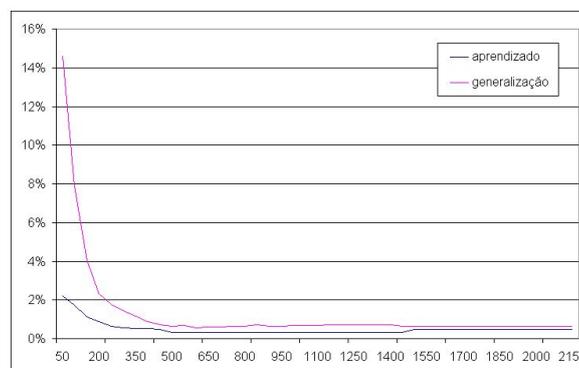


Figura B.5: Evolução do erro de aprendizado e de generalização da Rede7-10-10-2TsigPlinPlin

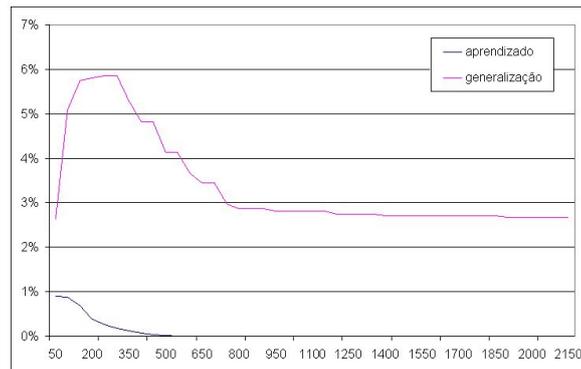


Figura B.6: Evolução do erro de aprendizagem e de generalização da Rede7-10-10-2PlinTsigPlin

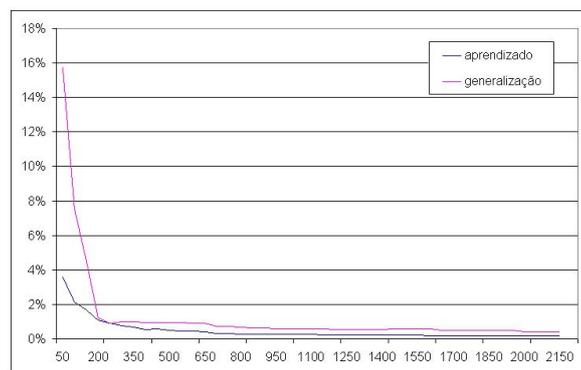


Figura B.7: Evolução do erro de aprendizagem e de generalização da Rede7-10-10-2PlinPlinTsig

Litologia *Shale*

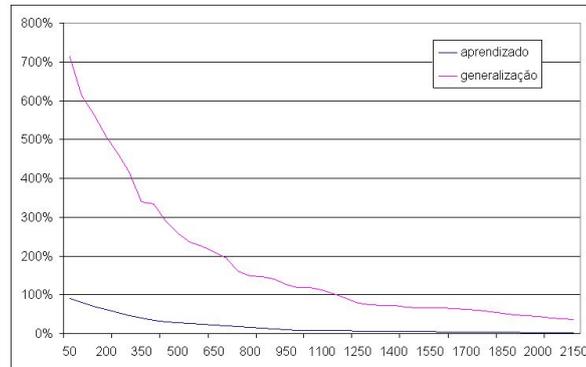


Figura B.8: Evolução do erro de aprendizagem e de generalização da Rede7-2Tsig

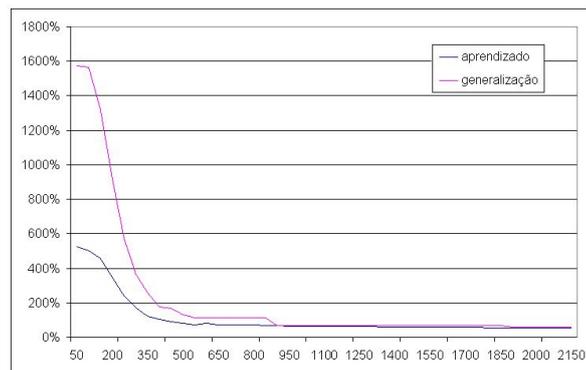


Figura B.9: Evolução do erro de aprendizagem e de generalização da Rede7-2Lsig

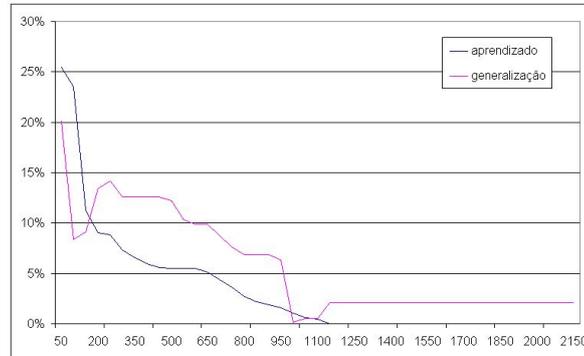


Figura B.10: Evolução do erro de aprendizado e de generalização da Rede7-10-2TsigPlin

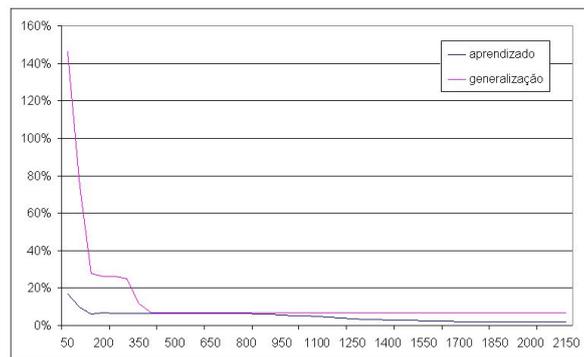


Figura B.11: Evolução do erro de aprendizado e de generalização da Rede7-10-2LsigPlin

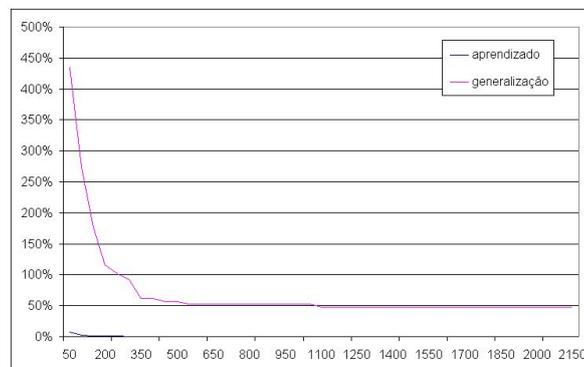


Figura B.12: Evolução do erro de aprendizado e de generalização da Rede7-10-10-2TsigPlinPlin

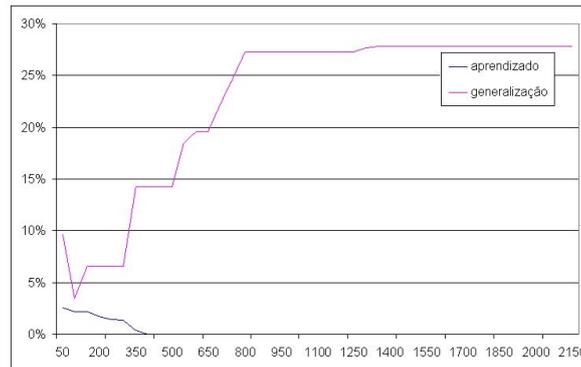


Figura B.13: Evolução do erro de aprendizado e de generalização da Rede7-10-10-2PlinTsigPlin

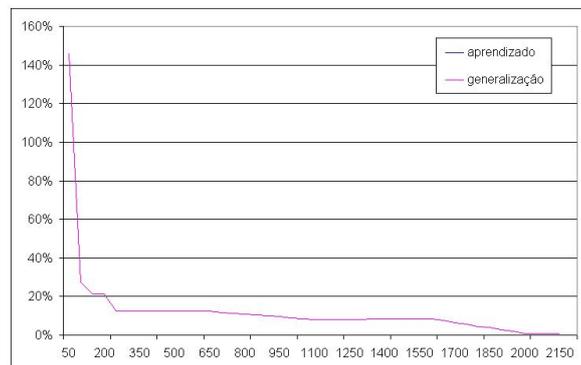


Figura B.14: Evolução do erro de aprendizado e de generalização da Rede7-10-10-2PlinPlinTsig

Referências Bibliográficas

- [1] AZEVEDO, F.M. de *Contribution to the study of neural networks in dynamical expert systems*. 1993. 208p. Tese(Doutorado) - Facultes Universitaires Notre-Dame de La Paix.
- [2] AZEVEDO, F.M. de; BRASIL, L.M. e OLIVEIRA, R.C.L. de *Redes Neurais com aplicações em controle e em Sistemas Especialistas*. Florianópolis: Visual Books, 2000. 401p.
- [3] CICHOCKI, A. e UNBEHAUEN, R. *Neural networks for optimization and signal processing*. Stuttgart: B.G.Teubner; Chichester: J.Wiley, c1993. 526p.
- [4] RAITTZ, R.T. e GAUTHIER, F.A.O. *Free Associative Neurons - FAN: uma abordagem para reconhecimento de padrões*. Florianópolis, 1997. 67f. Dissertação (Mestrado) - Universidade Federal de Santa Catarina.
- [5] SCHNEIDER, M.L. e WESTPHALL, C.B. *Gerência de segurança para detecção de intrusão em telecomunicações através de redes neurais..* Florianópolis, 1999. 87f. Dissertação (Mestrado) - Universidade Federal de Santa Catarina.
- [6] OLIVEIRA, C.M. de; WAZLAWICK, R.S. e MACHADO, L.J.B. *Um modelo de rede neural artificial para previsão automática da carga ativa nodal de curto prazo em sistemas de transmissão e distribuição de energia elétrica com supervisão e controle automatizados*. Florianópolis, 1999. 103f. Dissertação (Mestrado) - Universidade Federal de Santa Catarina.
- [7] ARGOUD, F.I.M.; AZEVEDO, F.M. de e PIERI, E.R. de *Contribuição à automatização da detecção e análise de eventos epileptiformes em eletroencefalograma*. Florianópolis, 2001. 185f. Tese (Doutorado) - Universidade Federal de Santa Catarina.
- [8] MUELLER, A. e FRIES, C.E. *Uma aplicação de redes neurais artificiais na previsão do mercado acionário*. Florianópolis, 1996. 103f. Dissertação (Mestrado) - Universidade Federal de Santa Catarina.
- [9] ZHONG, H.; YANG, L.; YEN, J. e WU, C. *Neural-Network approach to predict well performance using available field data*. Texas, 2001. SPE Western Regional Meeting, Março 2001.

- [10] WANG, L.; WONG, P.M. e SHIBILI, S.A.R. *Modeling Porosity Distribution in A'nan Oilfield: Use of geological quantification, neural networks and geostatistics*. SPE International Oil and Gas Conference and Exhibition, Novembro, 1998. Beijing, China.
- [11] BILGESU, H.I.; ALTMIS, U.; AMERI, S.; MOHAGHEGH, S. e AMINIAN, K. *A new approach to predict bit life based on bit tooth or bearing failures*. SPE Eastern Regional Meeting, Novembro, 1998. Pittsburgh, EUA.
- [12] HAYKIN, S. *Neural Networks: A comprehensive foundation*. Prentice Hall, Inc. NJ. 2nd. Ed., 1999.
- [13] ZEIDENBERG, M. *Neural Network models in artificial intelligence*. Elis Horwood, NY. 1990. 268p.
- [14] KOVÁČKS, Z.L. *Redes Neurais artificiais: fundamentos e aplicações*. Ed. Academica. 1990. SP. 164p.
- [15] LOESCH, C. e SARI, S.T. *Redes Neurais artificiais: fundamentos e modelos*. Ed. da FURB. 1996. Blumenau, SC. 166p.
- [16] TAFNER, M.A. e XEREZ, M. de *Redes Neurais artificiais: introdução e princípios de neurocomputação*. Ed. da FURB. 1996. Blumenau, SC. 199p.
- [17] BRADY, M.; GERHARDT, L.A. e DAVIDSON, H.F. *Robotics and artificial intelligence*. Ed. Springer. 1984. Berlim, Alemanha. 693p.
- [18] SCHANK, R.C. e CHILDERS, P.G. *The cognitive computer: on language, learning, and artificial intelligence*. Reading Addison-Wesley. 1984. 268p.
- [19] ARBIB, M.A. *The handbook of brain theory and neural networks*. MIT Press, 1988. Cambridge, EUA. 1118p.
- [20] AUBIN, J.P. *Neural networks and qualitative physics*. Cambridge Univ. Press, 1996. Nova York, EUA. 283p.
- [21] CARVALHO, P.G.; MOROOKA, C.; BORDALO, S. e GUILHERME I. *Control:PCP - An Intelligent System for Progressing Cavity Pumps*. SPE Annual Technical Conference and Exhibition, Outubro, 2000. Dallas, EUA.
- [22] DASHEVSKIY, D.; DUBINSKY, V. e MACPHERSON, J.D. *Application of Neural Networks for Predictive Control in Drilling Dynamics*. SPE Annual Technical Conference and Exhibition, Outubro, 1999. Houston, EUA.
- [23] BILGESU, H.I.; TETRICK, L.T.; ALTMIS, U.; MOHAGHEGH, S. e AMERI, S. *A new approach for the prediction of Rate of Penetration (ROP) Values*. SPE Eastern Regional Meeting, Outubro, 1997. Lexington, EUA.

- [24] PATRICIO, A.R.; DA ROCHA, A.F. e MOROOKA, C.K. *Seplant: An Expert System for Process Plant and Gas Lift Well*. SPE Petroleum Computer Conference, Agosto, 1994. Dallas, EUA.
- [25] CAMINHAS, W.M. e TAKAHASHI, R.H.C. *Dynamic System Failure Detection and Diagnosis Employing Sliding Mode Observers and Fuzzy Neural Networks*. IEEE. 2001.
- [26] PATAN, K. e PARISINI, T. *Stochastic learning methods for dynamic neural networks: simulated and real-data comparisons*. Proceedings of the American Control Conference. Maio, 2002. Anchorage, EUA.
- [27] TRIGGIA, A.A.; CORREIA, C.A.; FILHO, C.V.; XAVIER, J.A.D.; MACHADO, J.C.V.; THOMAS, J.E.; FILHO, J.E.S.; DE PAULA, J.L.; DE ROSSI, N.C.M.; PITOMBO, N.E.S.; GOUVEA, P.C.V.M.; CARVALHO, R.S. e BARRAGAN, R.V. *Fundamentos de Engenharia de Petróleo*, Ed. Interciência, Rio de Janeiro, 2001.
- [28] MOURITZ, A.P. e HUTCHINGS, I.M. *The abrasive wear of rock drill bit materials*, University of Cambridge, SPE Technical Publication, 1991.
- [29] PELTIER, B.P.; COOPER, G.A. e CURRY, D.A. *Use of torque analysis to determine tricone bit bearing failure*. Annual Technical Conference and Exhibition of the SPE, Setembro, 1987. Dallas, USA.
- [30] SNEDDON, M.V.; MEGADIAMOND, S. e HALL, D.R. *Polycrystalline Diamond: Manufacture, wear mechanisms and implications for bit design*. Annual Technical Conference and Exhibition of the SPE, Setembro, 1987. Dallas, USA.
- [31] MACINI, P. e MESINI, E. *Rock-bit wear in ultra-hot holes*. SPE/ISRM Rock Mechanics in Petroleum Engineering Conference, Agosto, 1994. Delft, Holanda.
- [32] CHEATHAM, C.A. e LOEB, D.A. *Effects of field wear on PDC bit performance*. SPE/IADC Drilling Conference, Março, 1985. New Orleans, EUA.
- [33] GLOWKA, D.A. *Implications of Thermal Phenomena for PDC Bit Design and Operation*. Annual Technical Conference and Exhibition of the SPE, Setembro, 1985. Las Vegas, EUA.
- [34] JARDLNE, S.I.; LESAGE, M.L. e MCCANN, D.P. *Estimating tooth wear from roller cone bit vibration*. SPE/IADC Drilling Conference, Março, 1990. Houston, EUA.
- [35] FAÿ, H. *Practical evaluation of rock-bit wear while drilling*. SPE/IADC Drilling Conference, Março, 1991. Amsterdam
- [36] BURGESS, T.M. e LESSO JR., W.G. *Measuring the wear of milled teeth using MWD torque and Weight-on-Bit*. SPE/IADC Drilling Conference, Março, 1985. New Orleans, EUA.
- [37] HARELAND, G. e RAMPERSAD, P.R. *Drag-Bit model including Wear*. Latin American/Caribbean Petroleum Engineering Conference, Abril, 1994. Buenos Aires, Argentina.

- [38] GEOFFROY, H.; MINH, D.N.; BERGUES, J. e PUTOT, C. *Frictional contact on cutters wear flat and evaluation of drilling parameters of a PC bit*. SPE/ISRM Eurock, Julho, 1998. Trondheim, Noruega.
- [39] SINOR, L.A. e WARREN, T.M. *Drag bit wear model*. Annual Technical Conference and Exhibition of the SPE, Setembro, 1987. Dallas, EUA.
- [40] COOPER, G.A. e ABOUZEID, A.A. *Experimental verification of a drilling simulator*. 8th. International Conference on Mining, Petroleum and Metallurgical Engineering, Março, 2003. Egito.
- [41] COOPER, G.A.; COOPER, A.G. e BIHN, G. *An interactive drilling simulator for teaching and research*. Petroleum Computer Conference, Junho, 1995. Houston, EUA.