

ANÁLISE DE REDES NEURAIAS EM VARIÁVEIS DE PERFILAGEM

SILVA, Mayara Laysa de Oliveira*; **LEITÃO, Suzana Russo**; **BARROS, Nilson Santos**

Departamento de Estatística, Universidade Federal de Sergipe

* email: laysamay@hotmail.com

Resumo: Pode-se citar a rede neural artificial (RNA) como uma das técnicas mais promissoras quando se trata de problemas com modelagens de banco de dados, este método conquistou um espaço relevante pela aplicabilidade em diversas áreas. A quantidade de derivados do petróleo expõe a importância dessa energia não renovável para a população mundial. Sabe-se que suas reservas ainda abastecerão o planeta por várias décadas, assim, podem-se entender as buscas incessantes para obter métodos que maximizem a extração do bem em questão. O presente estudo visa obter o melhor modelo, isto é, verificar qual o tipo de rede neural retornará os melhores valores para a perfilagem. No entanto para realizar o estudo é necessário categorizar os dados, excluir as variáveis que não se adequam ao modelo e a partir daí, pretende-se treinar a rede para que os valores da predição sejam utilizados na criação do novo perfil sônico.

Palavras-chave: Petróleo, Poço, Perfilagem, Rede.

1. INTRODUÇÃO

Sabe-se da imensa importância e atribuições do petróleo na sociedade, apesar de ser um produto finito, suas reservas ainda abastecerão o planeta por várias décadas. A indústria do petróleo representa 12% do PIB mundial. Tanta representatividade e a grande necessidade de capital para operações de alto risco fazem das empresas petrolíferas importantes personagens do mercado de capital, envolvendo elevados riscos bem como grandes retornos cobiçados pelos investidores (NASCIMENTO, 2009).

O presente estudo visa através de busca de informações, ou seja, pesquisa bibliográfica embasado no referencial teórico da proposta do assunto. Medidas estatísticas serão utilizadas para treinar uma série de neurônios inteligentes que resultará em uma rede neural, outras medidas descritivas farão parte do processo. Através de uma RN multicamadas (rede neural regressão) será observado o comportamento das variáveis de perfis de poços de petróleo através da perfilagem.

Com a utilização de método rede neural artificial pretende-se desenvolver um sistema que modele os dados de perfilagem para a geração do perfil de poço de petróleo, assim sendo, tem-se como objetivo identificar as séries não lineares nos dados e modelar as séries para que medidas ocorridas durante a perfuração de poços de petróleo resultem em um novo perfil sônico e ainda, analisar a sensibilidade dos modelos através de dados simulados,

A estatística como em outras áreas é de suma importância para verificação de erros e criar medidas providenciais para perfuração de poços de petróleo. Para obter melhores resultados utilizaremos as medidas descritivas, testes de comparação, perfilagem e análise completas do banco de dados buscando os melhores resultados possíveis.

2. REVISÃO TEÓRICA

2.1. Prospecções de Petróleo

É de suma importância o estudo prévio dos tipos de rochas e as ênfases nas bacias sedimentares são devido à sua importância para a origem do petróleo. Sabe-se que o petróleo é formado a partir da deposição de matéria orgânica junto com os sedimentos durante a formação das bacias sedimentares, após ser compreendido como ocorre à formação das acumulações de hidrocarbonetos, serão analisados quais métodos são aplicados para descobrir o petróleo (SILVA, 2012).

A busca pelo petróleo é algo que necessita de métodos e técnicas que permitam localizar uma área favorável à sua formação, pode-se definir estes métodos ou técnicas de prospecção. O conhecimento destas técnicas é fundamental, pois a fase de prospecção é caracterizada por riscos elevados. Podendo citar os riscos geológicos implícitos à atividade mineral e os riscos políticos, em função de possíveis mudanças desfavoráveis e inesperadas nas condições institucionais nos países hóspedes (ALMEIDA, 2008).

Levando em consideração que os minerais são elementos formadores das rochas, e estas constituem parte essencial da crosta terrestre é indispensável conhecer as classificações dessas rochas (SILVA, 2012):

- Rochas Ígneas: Formadas a partir da consolidação do magma.
- Rochas Sedimentares: São formadas através da erosão de qualquer tipo de rocha, devendo ser transportado e em seguida depositado ou precipitado em algum ambiente deposicional.
- Rochas Metamórficas: São rochas ígneas ou sedimentares que por algum processo geológico foram submetidas a condições de pressão e temperatura, predominantemente, diferentes das quais a rocha foi formada, dando origem assim a uma nova rocha adaptada a essas condições.

Porém o interesse maior se dá as rochas sedimentares por serem as rochas formadas a partir da deposição e litificação de fragmentos de rochas pré-existentes, que são transportados em geral pela água, vento ou gravidade e originados através dos processos de intemperismo (SILVA, 2012).

Antes da perfuração de um poço, que é a etapa que exige a maior parte dos investimentos no processo prospectivo, geológicos e geofísicos estudam detalhadamente os dados de diversas camadas de subsolo, visando os parâmetros que indicam a condição de acumulação de petróleo e os locais mais prováveis de sua ocorrência, ou seja, não se trabalha com certeza absoluta, mas com parâmetros bastante confiáveis quanto à existência, que posteriormente terá relação custo-benefício avaliada pela exploração (ALMEIDA, 2006).

2.2. Perfilagem

As primeiras aplicações da perfilagem de poços foram realizadas na década de 20 para correlação de padrões similares de condutividade elétrica de um poço a outro, algumas vezes sobre grandes distâncias. Com o aperfeiçoamento e aumento das técnicas de aquisição, as aplicações começaram a ser direcionadas para avaliações quantitativas de reservatórios de hidrocarbonetos (LIMA, 2005)

A perfilagem é uma ferramenta fundamental na moderna operação de obtenção de variáveis de perfis em poços de petróleo.

As etapas de perfilagem geram um grande volume de informações sobre a espessura, profundidade e comportamento das camadas de rochas existentes nas vizinhanças do poço. (SILVA, 2006)

2.3. Perfil Sônico

O perfil sônico é utilizado na construção de sismogramas sintéticos, que são obtidos usando-se um algoritmo próprio e tem por finalidade auxiliar na interpretação dos horizontes sísmicos, permitindo correlacionar esses horizontes com os níveis estratigráficos atravessados pelo poço perfurado, além de propiciar a criação de tabelas de conversão tempo versus profundidade, o que permite migrar toda uma interpretação sísmica, que está no domínio do tempo, para o domínio do espaço (profundidade). Como não é viável economicamente fazer uma aquisição do perfil sônico, na grande maioria dos poços antigos, principalmente em decorrência da parada da produção do óleo, para contornar a falta de informação, deve-se recorrer a outros meios para solucionar o problema. Uma das maneiras é utilizar métodos estatísticos que gerem um perfil sônico, dito sintético, para estabelecer estimativas das velocidades sísmicas das rochas ao longo dos poços (RUSSO *et al.*, 2010).

Na atividade de perfuração, durante as fases de projeto e execução, o perfil sônico (DT) é uma informação fundamental para a tomada de decisões. Assim, ao lado dos critérios para a escolha de brocas e parâmetros de perfuração, como peso sobre broca (PSB) e rotação da coluna (N), existem a análise mecânica das litológicas a serem atravessadas, propriedades estas que podem ser conhecidas a partir do perfil DT (LIMA, 2005).

Infelizmente, o perfil DT não está disponível em todos os poços de correlação escolhidos para se planejar um programa de perfuração, sendo necessário, em muitos casos, realizar tais projetos sem esta informação (SILVA, 2006).

O tempo de trânsito (DT) guarda uma relação direta com a porosidade da rocha. Quanto maior o DT, maior a separação entre os grãos, portanto, maior a porosidade, sendo a recíproca verdadeira. Conseqüentemente, a maior vantagem do perfil sônico provém da relação direta que existe entre o tempo de trânsito de uma onda sonora em uma rocha e a sua porosidade (WYLLIE, 1956). Em sua tese, Lima (2005) afirma que elevados tempos do DT podem representar fraturas, desmoronamentos ou até mesmo presença de gás no poço.

2.4. Redes Neurais

O cérebro humano é considerado o mais fascinante processador baseado em carbono existente, sendo composto por aproximadamente 10 bilhões de neurônios. Todas as funções e movimentos do organismo estão relacionados ao funcionamento destas pequenas células. Os

neurônios estão conectados uns aos outros através de sinapses, e juntos formam uma grande rede, chamada Rede Neural (NEURAL, 2014).

No último século, graças aos grandes avanços na neurobiologia e nas áreas multidisciplinares atreladas as redes neurais, a ciência começou a compreender os princípios básicos que governam o funcionamento do sistema nervoso e, num passo ainda mais audacioso, modelar e construir sistemas artificiais capazes de reproduzir algumas funções próprias do cérebro (VIEIRA, 2007).

Redes neurais necessitam de longos tempos de treinamento e são, conseqüentemente, mais apropriadas para as aplicações onde este tempo é aceitável. A técnica requer um número de parâmetros que normalmente são determinados empiricamente, como a topologia ou “estrutura” da rede (VIEIRA, 2007).

São imensas as aplicações que contém as redes neurais, as mais usuais são as redes de reconhecimento de faces e voz, autenticação de usuários, predição no mercado financeiro, controle de navegação autônoma de veículos e exploração de petróleo. Para o devido estudo a aplicabilidade será realizada em exploração de petróleo, onde a técnica se encaixa por ser útil quando há necessidade de reconhecer padrões a partir do acúmulo de experiência ou de exemplos cuja representação é complexa. A abordagem da rede neural nesse tipo de problema é de suma importância pela quantidade de informações e complexidade que geralmente contém em bancos de dados relacionados a petróleo.

2.5. Redes Neurais Artificiais

As redes neurais artificiais (RNA's) são estruturas que possuem como modelo o sistema neural biológico. Onde o neurônio artificial se torna responsável pelo processamento da RNA, estes possuem características similares ao neurônio biológico e é formado por entradas tanto positiva (excitação) e negativa (inibição), assim gerando uma única saída (PEREIRA, 1998).

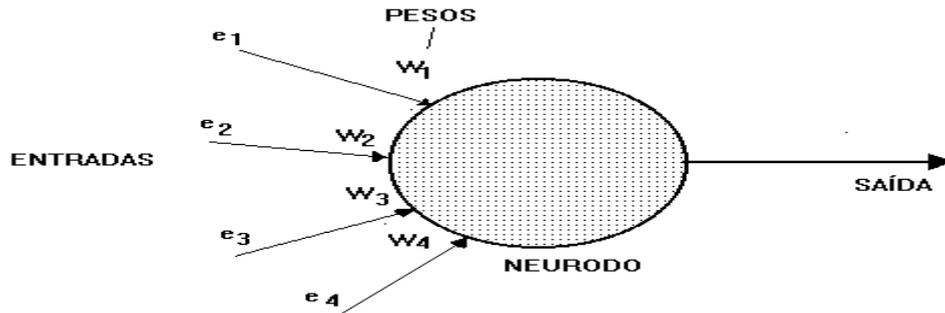


Figura 1 – Comportamento dos neurônios artificiais

Fonte: Revista Informédica - 1994

Existem três pontos que podem apontar um neurônio artificial (ICMC, 2008):

Conjunto de Sinapses: Cada sinapse é caracterizada por uma ponderação ou pesos. Um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado ao peso sináptico w_{jk} .

Somatório: Para somar os sinais de entrada, ponderado pelas respectivas sinapses.

Função de Ativação: Limita a amplitude da saída do neurônio.

Quando se trata de função de ativação a mais usual é a função limiar que propõe a teoria do tudo ou nada e é representada pela seguinte equação (ICMC, 2008):

$$f(v) = \begin{cases} 1, & \text{se } v \geq 0; \\ 0, & \text{se } v \leq 0; \end{cases}$$

Nos neurônios construídos com essa função, a saída y será igual a 0, caso o valor de ativação v seja negativo e 1 nos casos em que o valor de ativação seja positivo.

O modelo proposto para a problemática se trata de uma rede neural simples que é equivalente a técnica estatística, regressão logística. Os dois modelos possuem a vantagem de detectar implicitamente qualquer relação não-linear entre a variável resposta e as variáveis explicativas. Porém o modelo de regressão logística precisa que esta relação não-linear seja explicitada pelo desenvolvedor do modelo (CORRAR, 2007).

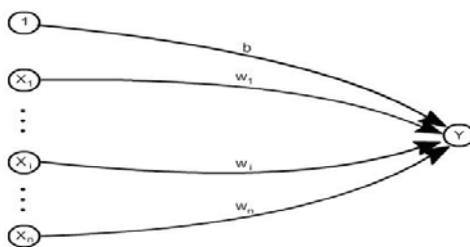


Figura 2 – Representação da rede neural simples

Fonte: Gira Mundo Computação - 2009

Esta rede como se pode observar na Figura 2 contém quatro entradas e produz uma saída, porém ela não suporta uma camada intermediária e isto é que diferencia esse tipo de rede das mais complexas.

A arquitetura de uma rede neural é importante por restringir o tipo de problema que pode ser tratado pela rede, ou seja, redes mais simples são responsáveis por separações lineares e não-lineares, as multicamadas, são apropriadas para todos os tipos, dos mais simples até os complexos (CORRAR, 2007).

A arquitetura de rede neural define a quantidade de camadas, quantos neurônios são dispostos em cada camada e se há, ou não, conexões de realimentação. A força de conexão entre os neurônios é representada pelos pesos sinápticos (BRAGA, 2000).

Os modelos estatísticos auto-regressivos que tem como base a análise de série temporal, estes visam encontrar o melhor modelo para aquela série e estimar os parâmetros. Como consequência da busca o modelo deve fazer diversas iterações objetivando-se encontrar o melhor valor, isto é aquele valor que é mais próximo do valor real (CASTRO, 1995).

Já as redes neurais artificiais preditoras superam em partes os modelos de séries temporais, pois a mesma vai aprender através de exemplos, ou seja, um preditor baseado em rede neural estimar o valor futuro de um sinal apenas a partir de suas amostras passadas (CORRAR *et al.*, 2007).

2.6. Caracterização das Variáveis de Perfis:

2.6.1. Caliper – CALI: Perfil que fornece o diâmetro medido ponto a ponto em toda a extensão de um poço. É um indicativo da qualidade da leitura dos perfis.

2.6.2. Diâmetro da Broca – DB: é a variável que define o diâmetro nominal da broca que perfurou determinado intervalo de poço, sendo que um poço geralmente tem diferentes intervalos perfurados com brocas de diferentes diâmetros. O DB é medido em polegadas.

2.6.3. Arrombamento de Poço – Dcali: é uma variável calculada (CALI – DB), mede o quanto o diâmetro do poço se afasta do diâmetro nominal da broca que perfurou determinado trecho. Quando essa variável tem alta frequência provoca “rugosidades” nas paredes dos poços sendo que essas irregularidades afetam a qualidade das leituras dos perfis. Essa variável é medida em polegadas

2.6.4. Profundidade – Prof: é a profundidade do ponto de leitura dentro do poço. Sua escala de medida é em metros. Seu referencial de medida, isto é, o zero, é a Mesa Rotativa (MR) da sonda de perfuração. Para ser corrigido ao Nível Topográfico basta subtrair a MR. A sua correlação com outras variáveis de perfis requer uma interpretação geológica. De forma geral a velocidade sônica das rochas (DT) e a densidade (RHOB) crescem com a profundidade em função do soterramento e conseqüente compactação das rochas.

2.6.5. Raios Gama – GR: É a medida da radioatividade total presente nas rochas. Este perfil é utilizado, principalmente, para separar tipos diferentes de rochas, já que as argilas apresentam elevados teores de elementos radioativos e os arenitos e carbonatos têm baixa radioatividade. Esse perfil, apesar de correr centralizado é pouco afetado pelo arrombamento do poço. Sua unidade de medida é em graus API.

2.6.6. Indução – ILD: Curva de resistividade do perfil Eletro-indução. Mede a resistividade das rochas. É aplicado para cálculo de saturação e identificação dos fluidos e correlação entre os poços. Essa variável é afetada principalmente pela variação dos fluidos presentes nos poros da rocha. É medido em ohm. Metro.

2.6.7. Densidade – RHOB: Mede a densidade das rochas. É o principal perfil para a estimativa da porosidade. Normalmente é medido em g/cm³ (grama por centímetro cúbico).

2.6.8. Sônico – DT: Mede o tempo de trânsito necessário para uma onda sonora percorrer um pé de rocha. Esse tempo é inversamente proporcional à velocidade sônica da rocha. É utilizado para a estimativa da porosidade, do grau de compactação das rochas, das constantes elásticas da rocha, correlação entre poços, detecção de fraturas e apoio à sísmica (sismograma sintético). É medido em microssegundos por pé.

3. MATERIAIS E MÉTODOS

Existem diversos tipos de redes neurais a utilizada para o devido estudo é a RN preditora, ou seja, redes perceptron e multicamadas (MLP), onde a rede neural MLP consiste de uma

camada de entrada, através da qual os sinais de entrada são recebidos pela rede, uma ou mais camadas ocultas e uma camada de saída.

Para realização do estudo será analisado o banco de uma base oriunda de perfurações de poços de petróleo das unidades geológicas da Bacia Sergipe-Alagoas cedido pela Petrobras S/A.

O presente estudo visa aplicar a técnica de rede neural para prever o comportamento da série, verificar o comportamento das variáveis já definidas do perfil do poço de petróleo, analisar a sensibilidade dos modelos através de dados simulados e gerar um novo perfil sônico.

Os modelos ajustados aos dados brutos e filtrados serão comparados por meio da validação cruzada, utilizando-se a correlação linear como medida qualitativa do ajuste.

Para detectar qual o melhor tipo de rede para o banco de dados, é necessário realizar treinos, assim é possível descobrir com precisão qual o tipo de rede inteligente se adequa melhor ao banco. Foram realizados três treinos e como critério de melhor modelo observou-se o menor erro. O software utilizado para o treino da rede é o software Statistica versão 11.

4. RESULTADOS E DISCUSSÕES

No poço B, Dcali e Vsh apresentam alto nível de desconcentração ($CV > 25\%$) enquanto que DT se identifica como uma variável bastante concentrada ($CV = 19,743\%$) (Tabela 1).

Tabela 1 – Medidas de Tendência Central e Dispersão para Dcali, Vsh e DT sem filtragem.

	Média	DP	EP	CV(%)
Dcali	83,098	17,389	0,218	20.926
Vsh	1,059	0,834	0,010	78.737
DT	0,479	0,309	0,004	64.563

A média de Dcali e Vsh encontra-se abaixo da mediana o que demonstra que as observações influentes estão na metade inferior dos dados. Contudo DT apresenta a situação inversa (média > mediana), o que demonstra que as observações influentes estão na metade superior dos dados (Tabela 2). Os casos de DT e Dcali que estão entre o mínimo e o 1º quartil e a região entre o 3º quartil e o máximo apresentam maior amplitude, enquanto que a região entre o 1º e o 3º quartil apresenta menor amplitude. Isso demonstra que as leituras de DT internas estão mais concentradas que as regiões externas. Quanto a Vsh (que é uma variável percentual) 75% encontram-se até 86,3%.

Realizou-se o treino da RNA no software STASTISCA, a opção escolhida para treinar a rede foi a formato inteligente que através desse método é possível definir o número de neurônios a serem utilizados. O método em questão é automático e é o utilizador que determina os passos e os parâmetros. Segundo Santos 2009 normalmente as variáveis previstas são contínuas, sendo então a predição do problema de tipo análise temporal uma forma especializada de regressão.

Optou-se por realizar três treinos na rede, onde se buscou a modificação do próprio erro devido à capacidade de aprendizagem da rede. O primeiro treino resultou nas tabelas abaixo:

Tabela 2 – Resultado do Primeiro Treino da Rede.

PERFIL	PERFEIÇÃO DO TREINO	PERFEIÇÃO DE SELEÇÃO	TESTE DE PERFEIÇÃO	ERRO DE SELEÇÃO
LINEAR s2 3:6-1:1	0.6779	0.6784	0.6819	0.1130
MLP s5 3:15-6-1:1	0.6069	0.6221	0.6112	0.1043
MLP s5 3:15-6-1:1	0.5734	0.5948	0.5763	0.0997
RBF s5 3:15-56-1:1	0.5654	0.6008	0.5829	0.0367
RBF s5 3:15-112-1:1	0.5420	0.5927	0.5669	0.0362

Como se observa a variável perfil contém uma gama de informações sobre a RNA, esta variável determina o tipo de rede atribuindo nome, número de entradas (input) e saídas (output) e o número de neurônios em cada camada. As seguintes variáveis perfeições de treino, perfeição da seleção, teste de perfeição são utilizados para verificar a desempenho da rede em relação ao treino. O erro de seleção é uma opção para critério de escolha do melhor modelo, porém é preciso olhar conjuntamente a variável perfeição de seleção.

Na tabela pode-se observar que para o primeiro treino da rede, o melhor modelo foi o Linear com perfeição de seleção de 0.6784 e erro de seleção 0.1130. A descrição da rede é que o tipo de rede é Linear com três variáveis de input e uma variável de output, com duas camadas com seis e uma unidade, respectivamente.

O sumário estatístico descreve abaixo as previsões da rede neurais para a variável DT. A predição gerou novas medidas descritiva para a variável dependente, segue a tabela abaixo com os devidos valores.

Tabela 3 – Sumário Estatístico do Primeiro Treino da Rede.

VARIÁVEL	MÉDIA	DESVIO PADRÃO	ERRO DA MÉDIA	ERRO DO D. P	CORRELAÇÃO
DT-1	84.03	16.49	-0,1233	11.16	0.7357
DT-2	84.03	16.49	0.0156	11.08	0.7465
DT-3	84.03	19.49	-0,0542	9.544	0.8155
DT-4	84.03	16.49	-0,0332	9.599	0.8131
DT-5	84.03	16.49	-0,0192	9.265	0.8273

Conforme citado acima será observado o MAPE e pode-se observar que o menor erro absoluto é 6.73 relacionado ao DT-5, ou seja, isso indica que a cada previsão o erro foi diminuindo. A média e o desvio padrão possuem os mesmos valores para as futuras previsões pelo fato que a variável analisada continua.

Tabela 4 – Resultado do Segundo Treino da Rede.

PERFIL	PERFEIÇÃO DO TREINO	PERFEIÇÃO DE SELEÇÃO	TESTE DE PERFEIÇÃO	ERRO DE SELEÇÃO
LINEAR s3 3:9.1:1	0,6809	0,6512	0,7034	0,1087
MLP s5 3:15.6.1:1	0,6124	0,5998	0,6523	0,1004
MLP s5 3:15.7.1:1	0,5632	0,5639	0,5999	0,0945
RBF s5 3:15.55.1:1	0,5741	0,5731	0,5972	0,0341
RBF s5 3:15.111.1:1	0,5510	0,5693	0,5883	0,0328

A tabela 4 demonstra o segundo treino da RNA, pode-se notar que o melhor modelo ainda permanece sendo linear, mas modificou os números de camadas, logo o modelo consiste com três variáveis de input e uma variável de output, com três camadas com nove e uma unidades, respectivamente. Os valores de perfeição de seleção e erro de seleção são 0,6512 e 0,1087 respectivamente assim demonstrando um melhor resultado dos valores do 1º treino.

Tabela 5 – Sumário Estatístico do 2º treino da RNA.

VARIÁVEL	MÉDIA	DESVIO PADRÃO	ERRO ABS. DA MÉDIA	ERRO DO D. P	CORRELAÇÃO
DT.1	84,56	16,70	8,90	11,52	0,7238
DT.2	84,56	16,70	8,27	11,31	0,7359
DT.3	84,56	19,70	7,76	10,62	0,7720
DT.4	84,56	16,70	7,03	9,688	0,8147
DT.5	84,56	16,70	6,80	9,319	0,8300

Analisando novamente o MAPE observa-se que o menor erro absoluto da média foi o da variável DT.5 com 6,80 que difere do treino passado.

Tabela 6 – Resultado do Terceiro Treino da Rede.

PERFIL	PERFEIÇÃO DO TREINO	PERFEIÇÃO DE SELEÇÃO	TESTE DE PERFEIÇÃO	ERRO DE SELEÇÃO
LINEAR s2 3:6.1:1	0,6856	0,6589	0,6847	0,1161
MLP s5 1:5.4.1:1	0,7060	0,6387	0,6387	0,1119
MLP s5 3:15.5.1:1	0,5849	0,5525	0,5525	0,0968
RBF s5 3:15.55.1:1	0,5691	0,5549	0,5718	0,0345
RBF s5 3:15.111.1:1	0,5634	0,5527	0,5758	0,5758

O resultado do terceiro treino da rede retorna o mesmo comportamento do primeiro treino da RNA, porém os valores de perfeição de seleção e erro de seleção apresentam valores distintos, 0,6589 e 0,1161 respectivamente.

Tabela 7 – Sumário Estatístico do Terceiro Treino da Rede.

VARIÁVEL	MÉDIA	DESVIO PADRÃO	ERRO ABS. DA MÉDIA	ERRO DO D. P	CORRELAÇÃO
DT.1	84,51	16,51	8,76	11,42	0,7227
DT.2	84,51	16,51	7,53	10,30	0,7814
DT.3	84,51	19,51	6,91	9,519	0,8171
DT.4	84,51	16,51	6,61	9,120	0,8336
DT.5	84,51	16,51	6,48	8,909	0,8420

Os valores do MAPE a cada treino foram oscilando, mas conforme o esperado no último treino da rede resultou no menor MAPE possível 6,48.

O melhor modelo para o banco de dados, através da metodologia de RNA foi o linear com três entradas, com uma saída e duas camadas com seis e uma unidade, apresentando os devidos valores de 0,6589 de perfeição de seleção e erros de seleção de 0,1161 e o menor MAPE de 6,48. Os gráficos abaixo demonstram o comportamento da rede a cada treino.

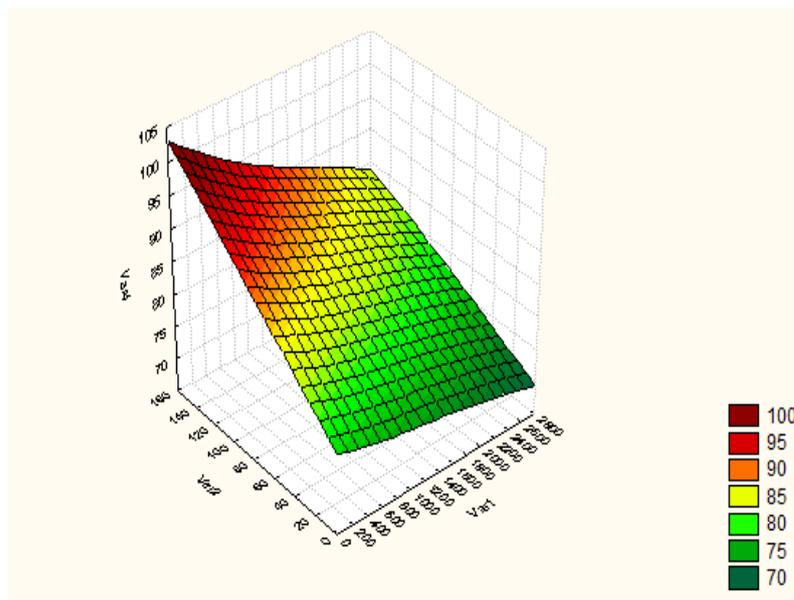


Figura 3 – Representação Gráfica do 1º Treino da RNA

Demonstra a superfície do primeiro treino da rede, assim com 100% de aprendizagem através de um exemplo anterior.

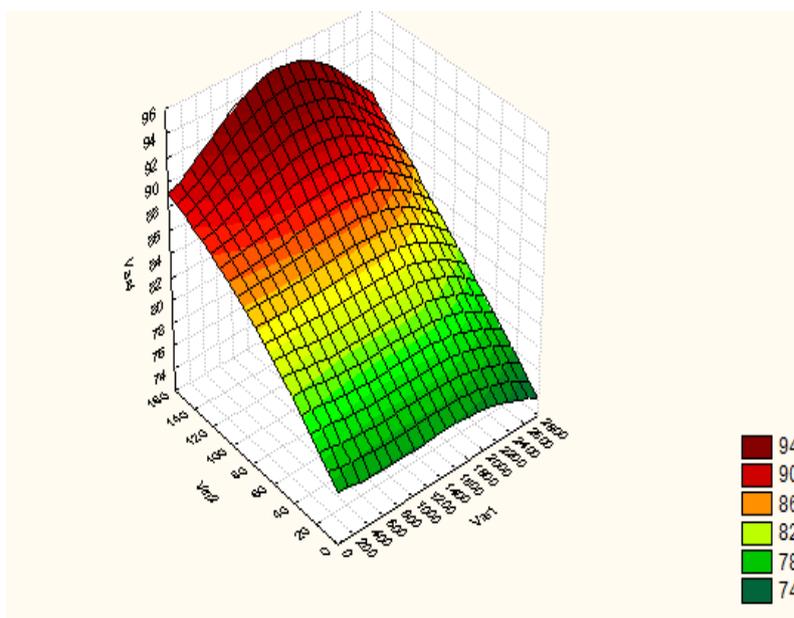


Figura 4 – Representação Gráfica do 2º treino da RNA.

A superfície do segundo treino da rede, porém para esse gráfico os pesos sinápticos já são lançamentos da RNA inteligente modificando a interface do gráfico.

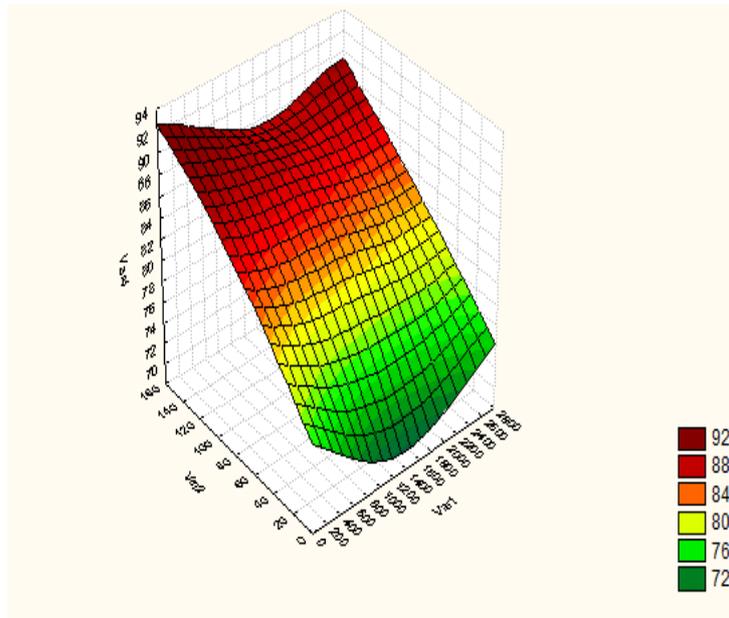


Figura 5 – Representação Gráfica do 3º Treino da RNA.

Superfície do terceiro treino da RNA, o melhor modelo para o banco de dados, nota-se a inversão de cores e como a rede se modificou a cada treino.

5. CONSIDERAÇÕES FINAIS

O treinamento da Rede Neural nas variáveis de perfilagem, demonstrou a eficiência dessa técnica na modelagem dos dados e predição de novo perfil sônico.

Os melhores resultados foram obtidos após três treinos e verifica-se que o Erro Médio (MAPE) tende a diminuir a medida que aumentamos a base de treinamento. No terceiro treino, a Rede Neural alcançou cem por cento de taxa de aprendizado, sendo que o melhor modelo para o banco de dados em questão foi o linear com três entradas, uma saída e duas camadas com seis e uma unidade, tendo apresentado o menor erro médio, sendo, portanto, um preditor linear adequado.

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, E. L. F. **Dinâmica Tecnológica das Indústrias Energéticas (Apostila Didática)**. Instituto de Economia /UFRJ. Rio de Janeiro: Mimeo, 2002. Disponível em:

<http://www.ie.ufrj.br/hpp/intranet/pdfs/apost_petroleo.pdf> Acesso em: 10 de dezembro de 2014.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC, 2000. Disponível em: <<http://www.cpdee.ufmg.br/~apbraga/MeusArtigos/Prof%20Braga/Livros.pdf>> Acesso em: 15 de janeiro de 2015.

CASTRO, F. C. C. **Estudo de séries temporais aplicado a perfis de poços de petróleo**, Campinas, SP, 1995.

CORRAR, L. J.; EDILSON, P.; FILHO, D.; MARIA, J. **Análise Multivariada: Para os cursos de administração, ciências atuariais e economia/ FIPECAFI -1**. Ed, - 2 reimpr –São Paulo, SP, 2009.

DRUMMOND, A. A. R. **Química de fluidos de perfuração para poços de petróleo**, UFRJ, RJ, 2009 Disponível em: <<http://pt.slideshare.net/sydman/introduo-perfilagem-de-poos-5043021>> Acesso em: 10 de dezembro de 2014.

LIMA, K.T. P. **Utilização de métodos sísmicos, perfilagem e testemunhos de poços para caracterização dos turbiditos da formação urucutuca na bacia de almada (BA)**, Macaé, RJ: 2005 Disponível em: <<http://pt.scribd.com/doc/58924500/Tese-Perfilagem-Kledson-Tomasso-Pereira>> Acesso em: 10 de dezembro de 2014.

NASCIMENTO, I. A. **Análise do comportamento das ações das empresas integradas de petróleo**. Brasília, DF, 2009. Disponível em:

RUSSO, S. L. **Estimativa da Perfilagem em Poços de Pétroleo Utilizando a Estatística Multivariada**. São Cristovão, SE: 2010. Disponível em: <http://www.ime.unicamp.br/sinape/sites/default/files/resumo%20expandido%5B2%5D_0.pdf> Acesso em: 27 de novembro de 2012.

SILVA, J. D. S. **Uma Plataforma para Sistemas Embarcados: Desenvolvimento e Avaliação de Desempenho de um Processador RTL e uma Cache L1 usando SystemC**. Natal, RN. 2006 Disponível em: <http://www.ccet.ufrn.br/prh22/trabalhos/graduacao/2006/Jose_Diego_Silva_PRH22_UFRN_G.pdf> Acesso em: 12 de dezembro de 2014.

SILVA, A. M. F. R. **Diretrizes Para O Resgate Do Esquema Conceitual E Seu Compromisso Ontológico A Partir De Um Banco De Dados: Um Estudo De Caso No Domínio Da Litoestratigrafia**. Rio de Janeiro, RJ, 2012. Disponível em: <http://www.comp.ime.eb.br/dissertacoes/2012-Alda_Silva.pdf> Acesso em: 15 de Janeiro de 2015.

ANÁLISE DE REDES NEURAIIS EM VARIÁVEIS DE PERFILAGEM

SILVA, Mayara Laysa de Oliveira*; **LEITÃO, Suzana Russo**; **BARROS, Nilson Santos**

Departamento de Estatística, Universidade Federal de Sergipe

* email: laysamay@hotmail.com

Resumo: Pode-se citar a rede neural artificial (RNA) como uma das técnicas mais promissoras quando se trata de problemas com modelagens de banco de dados, este método conquistou um espaço relevante pela aplicabilidade em diversas áreas. A quantidade de derivados do petróleo expõe a importância dessa energia não renovável para a população mundial. Sabe-se que suas reservas ainda abastecerão o planeta por várias décadas, assim, podem-se entender as buscas incessantes para obter métodos que maximizem a extração do bem em questão. O presente estudo visa obter o melhor modelo, isto é, verificar qual o tipo de rede neural retornará os melhores valores para a perfilagem. No entanto para realizar o estudo é necessário categorizar os dados, excluir as variáveis que não se adequam ao modelo e a partir daí, pretende-se treinar a rede para que os valores da predição sejam utilizados na criação do novo perfil sônico.

Palavras-chave: Petróleo, Poço, Perfilagem, Rede.