



Business Intelligence

PUC
RIO

Roberto de Freitas Guimarães

*Redes Neurais Artificiais na Análise de
Séries Temporais de Produção de Petróleo*

Monografia de Final de Curso

29/12/2011

***Monografia apresentada ao Departamento de Engenharia
Elétrica da PUC/Rio como parte dos requisitos para a obtenção
do título de Especialização em Business Intelligence.***

Orientador: André Vargas Abs da Cruz, DSc.

Agradecimentos

Quero agradecer a todos aqueles que de alguma forma, direta ou indiretamente, contribuíram para a conclusão deste trabalho. Em especial a minha esposa, Tatiana Guimarães, pela paciência e incentivo, as minhas filhas, Isabella e Giuliana, pela inspiração na busca do conhecimento.

Ao, André Vargas, pela fundamental orientação e confiança durante o processo. Quero agradecer também, ao amigo Lúcio Botelho, pelo incentivo e dicas, que sem elas não seria possível sua conclusão.

RESUMO

O petróleo é hoje de imensurável importância e todo planejamento da nossa sociedade depende de sua disponibilidade no curto, médio e longo prazo. Estimar sua produção torna-se então de fundamental importância para o planejamento e tomada de decisão.

A previsão em séries temporais é o uso de um modelo para prever valores futuro baseado em valores observados previamente. Neste contexto o uso de RNA vem sendo empregadas com sucesso na previsão de séries temporais, em especial o uso de redes recorrentes aliadas ao algoritmo de retro-propagação (Backpropagation).

Atualmente é utilizado um conjunto de ferramentas estatísticas para estimar a produção. Esta monografia visa demonstrar a aplicabilidade das Redes Neurais Artificiais (RNA) na previsão de séries temporais, demonstrando o modelo utilizado para prever a produção de petróleo, num horizonte de curto prazo, principalmente para alocação de recursos e planejamento orçamentário. Fornecendo desta forma uma importante ferramenta para a tomada de decisão.

ABSTRACT

Oil is today of immeasurable importance, and all planning of our society depends on its availability in the short, medium and long term. Estimate production then, becomes extremely important for planning and decision making.

The time series prediction is the use of a model to predict future values based on previously observed values. In this context the use of ANN has been successfully employed in time series forecasting, particularly the use of recurrent networks combined with the back-propagation algorithm.

Nowadays is used a set of statistical tools to estimate production. This monograph aims to demonstrate the applicability of ANN in forecasting time series data, showing the model used to predict the oil production in the short-term, especially for resource allocation and budget planning. Thereby providing an important tool for a decision making.

Sumário

Sumário.....	4
1. Introdução.....	5
1.1. Motivação.....	5
1.2. Objetivos do Trabalho	5
1.3. Descrição do Trabalho	5
1.4. Organização da Monografia	6
2. Descrição do Problema	8
3. Metodologias	10
3.1. Introdução as Redes Neurais Artificiais (RNA)	10
3.2. A Arquitetura das Redes Neurais Artificiais	13
3.3. Processo de Aprendizados.....	15
3.4. Redes neurais na previsão de séries temporais	16
4. Estudo de caso.....	18
4.1. Definição do modelo da RNA	18
4.2. Pré-processamento dos dados.....	18
4.2.1. Limpeza dos dados	19
4.2.2. Transformação	20
4.3. Arquitetura da rede.....	21
5. Resultados.....	22
5.1. Experimentos realizados	22
5.1.1. Experimento 1	22
5.1.2. Experimento 2	24
5.1.3. Experimento 3	26
5.1.4. Experimento 4	28
5.1.5. Experimento 5	30
6. Conclusões e Trabalhos Futuros.....	32
Referências Bibliográficas	33

1. Introdução

1.1. Motivação

A qualidade do processo de previsão da produção torna-se relevante sob diversos aspectos. Inicialmente pela necessidade de planejamento de curto e médio prazo dos recursos físicos da empresa que dão suporte as atividades de Exploração e Produção (E&P), como navios de offloading, rebocadores e programação de carga das refinarias, bem como para embasar as negociações de compra e venda de petróleo. Em segundo lugar, as previsões de produção são utilizadas no planejamento de longo prazo da companhia, como uma variável de extremo impacto nos resultados.

Atualmente a previsão da produção é realizada utilizando-se de métodos estatísticos, como a extrapolação das curvas de produção realizadas com grau de incerteza definido por um especialista para determinar a produção futura. Além disso, são identificados fatos sabidamente relevantes que afetarão a produção futura dos poços da região avaliada, fazendo-se as devidas correções da produção prevista. Nesse processo tem-se um grau de incerteza muito grande e completamente dependente do conhecimento e experiência do especialista para avaliar o grau de incerteza.

1.2. Objetivos do Trabalho

O objetivo deste trabalho é reduzir o grau de incerteza com um modelo que considere fatores não lineares nas curvas previstas de produção. Portanto o modelo proposto deve aumentar a confiabilidade das previsões realizadas, possibilitando um melhor planejamento dos recursos e como uma importante ferramenta para a tomada de decisões.

Também é objetivo deste trabalho demonstrar como as redes neurais artificiais podem ser empregadas para prever séries temporais.

1.3. Descrição do Trabalho

O desenvolvimento dessa monografia envolveu cinco etapas: Pesquisa bibliográfica; Obtenção de dados históricos de produção de

petróleo; Modelagem e desenvolvimento do sistema proposto; Análise e pré-processamento das informações e; Avaliação do desempenho. Descritas a seguir:

Na Pesquisa Bibliográfica foi realizada uma pesquisa de material bibliográfico ligado a assuntos de previsão, principalmente os relacionados a séries temporais. Também a obtenção de material relacionado à RNA aplicado a séries temporais.

Enquanto que, na Obtenção de dados históricos, foi feito um levantamento completo de todos os dados de produção, e também todos os dados que poderiam influenciar a produção futura. Verificando a sua disponibilidade e confiabilidade.

Tendo disponíveis os dados e material bibliográfico passou-se para a fase modelagem e do sistema proposto foi desenvolvido um modelo para ser aplicado aos dados disponíveis. Nesta fase do trabalho buscou-se aplicar os conceitos apresentados por diversos autores ao problema de previsão.

Após a elaboração do modelo proposto passou-se para a aplicação deste modelo. Primeiramente realizando a análise e o pré-processamento das informações obtidas. Buscando eliminar dados ruidosos, faltantes ou inconsistentes.

Por fim o desempenho do sistema foi avaliado com dados históricos reais que não estavam presentes em nenhuma outra fase do sistema desenvolvido.

Apesar de descrito de forma seqüencial estas etapas foram sempre realizadas de forma interativa, sempre consultando e incrementando as etapas subseqüentes.

1.4. Organização da Monografia

Esta dissertação esta dividida em mais 6 capítulos, descritos a seguir:

O capítulo 2 trata dos conceitos envolvidos na previsão da produção de petróleo. Conceitos de potencial base, perda base, produção realizada e não realizada também estão descritas neste capítulo.

O capítulo 3 descreve conceitos básicos das Redes Neurais Artificiais, apresentando definições, conceitos e modelo para aplicação na previsão de séries temporais nesta monografia.

O capítulo 4 descreve um estudo de caso real, detalhando a metodologia utilizada para a previsão da produção de petróleo.

O capítulo 5 mostra os resultados do estudo de caso.

Finalmente, o capítulo 6 descreve as conclusões do trabalho e identifica possíveis trabalhos futuros.

2. Descrição do Problema

Na última década as reservas provadas de petróleo no Brasil saltaram de 8,5 bilhões de barris para 14,25 bilhões de barris [ANP anuário estatístico, 2011]. Para explorar todas estas reservas são necessários investimentos extraordinários. Aliam-se a isto um aumento na demanda mundial, a elevação dos preços e a diminuição no ritmo de descobertas de novas reservas a nível mundial.




Figura 1 - Reservas provadas de petróleo 2001-2010 [fonte ANP, anuário estatístico, 2011]

Este cenário cria um ambiente de grandes oportunidades para as empresas petrolíferas. Mas para que esta oportunidade seja explorada, investimentos, principalmente na área de pesquisa, são necessários.

No Brasil este aumento tem-se dado devido as descobertas gigantes de campos em águas ultra-profundas abaixo da camada de sal, conhecido como pré-sal. Esta camada de sal apresenta um novo desafio, pois ela tende a se movimentar, podendo danificar os equipamentos dos poços. Além disso, estes campos estão situados a uma distância superior a 200km da costa o que eleva também os custos de transporte de

equipamentos, suprimentos e pessoas. Todo este conjunto de dificuldades é compensado pelo tamanho da reserva e pelo óleo de melhor qualidade.

Com essas novas descobertas, há a necessidade de direcionar os recursos existentes para as melhores oportunidades de negócio. Apesar da existência de novas técnicas de recuperação, que aprimoram a produção de poços já existentes, investimentos são necessários para disponibilizar essas técnicas.

Neste contexto cresce a importância do planejamento dos investimentos e alocação de equipamentos de Exploração e Produção (E&P).

Assim, a previsão da produção de campos existentes exerce fundamental importância para melhorar a alocação de equipamentos e melhor direcionamento dos recursos financeiros existentes.

Para prever a produção dos campos existentes, a maioria das técnicas utilizadas hoje é baseada em modelos lineares que nem sempre atendem as previsões, que constantemente sofrem redução do volume devido à parada para manutenção ou por falhas em equipamentos.

Nos últimos anos observa-se uma maior atenção ao emprego de RNAs devido à capacidade de lidar com a não-linearidade das informações.

As redes neurais apresentam uma propriedade importante, segundo a qual qualquer função não-linear contínua pode ser aproximada com exatidão arbitrária por uma rede neural com uma camada escondida e até funções não contínuas com duas camadas, com uma arquitetura adequada e seus parâmetros ajustados corretamente (NELSON, 2004).

3. Metodologias

Neste trabalho serão utilizadas as redes neurais artificiais com realimentação a frente. Abaixo será descrito conceitos básicos de redes neurais seguido do modelo para previsão de séries temporais que será utilizado neste trabalho

3.1. Introdução as Redes Neurais Artificiais (RNA)

Este capítulo apresenta uma descrição da teoria de Redes Neurais Artificiais.

O trabalho de redes neurais artificiais tem sido motivado desde o começo pelo reconhecimento de que o cérebro humano processa informações de uma forma inteiramente diferente do computador digital convencional. O cérebro é um computador (sistema de processamento de informação) altamente complexo, não-linear e paralelo. Ele tem a capacidade de organizar seus constituintes estruturais, conhecidos por neurônios, de forma muito mais rapidamente que o mais rápido computador digital hoje existente (HAYKIN, 2001).

As redes neurais artificiais são ferramentas de Inteligência Artificial que possuem a capacidade de se adaptar e de aprender a realizar certa tarefa, ou comportamento, a partir de um conjunto de exemplos dados [OSÓRIO & BITTENCOURT, 2000].

Uma Rede Neural Artificial (RNA) possui uma estrutura distribuída, totalmente paralela, constituído de unidades de processamento simples, chamadas de neurônios. Estas características trazem algumas vantagens para solução de problemas complexos, devido à capacidade de:

Aprendizagem: A habilidade de aprender, através de um processo iterativo de ajuste dos aplicado aos seus parâmetros livres (pesos sinápticos).

Generalização: Habilidade de responder adequadamente para uma entrada não apresentada no processo de aprendizagem;

Adaptabilidade: As redes neurais têm a capacidade de adaptar seus pesos sinápticos a modificações do meio ambiente, possibilitando a aquisição de conhecimento pela experimentação.

Tolerância a falhas: Devido à natureza distribuída da informação, a perda de um elemento processador não causa grande degradação do desempenho.

Essas características trazem as redes neurais à capacidade de resolver problemas complexos cuja solução da forma tradicional é extremamente custosa ou impossível.

O esforço para entender o cérebro humano se tornou mais fácil pelo trabalho pioneiro de Ramón y Cajál (1911), que introduziu a idéia dos neurônios como constituintes estruturais do cérebro. Estima-se que haja aproximadamente 10 bilhões de neurônios no córtex humano e 60 trilhões de sinapses ou conexões (HAYKIN, 2001).

O sistema nervoso humano é formado por células nervosas extremamente especializadas: os neurônios. Os neurônios possuem, além das estruturas comuns nas demais células do corpo, extensões elementares que se desenvolvem a partir do corpo celular. Estas extensões são conhecidas como dendritos e axônios. Os dendritos são responsáveis por receber os impulsos nervosos e os conduzir até o corpo celular, enquanto os axônios são responsáveis por transmitir o sinal para os dendritos de neurônios adjacentes. A figura abaixo ilustra um neurônio típico e suas estruturas principais.

As terminações dos axônios são conectadas com os dendritos de outros neurônios através de sinapses. Desta forma, axônios e dendritos não chegam a entrar em contato direto. Existe uma substância química neurotransmissora que, em quantidade suficiente, permite que o impulso nervoso atravesse a separação. As conexões sinápticas têm papel fundamental na memorização da informação no cérebro humano. Acredita-se que, em cada sinapse, a quantidade de neurotransmissores que podem ser liberados para uma mesma freqüência de pulsos representa a informação armazenada pela sinapse [Barreto, 2002].




Figura 2 - (mecatrônica fácil ano 6 nº47)

O primeiro modelo de neurônio artificial foi proposto por Warren McCulloch e Walter Pitts em 1943 (MCCULLOCH e PITTS, 1943). O modelo de McCulloch-Pitts (M-P) interpreta o funcionamento do neurônio como sendo um circuito binário simples que combina várias entradas e gera um sinal de saída.

Na construção do neurônio M-P é modelado o processamento da informação em um neurônio biológico, isto é, os caminhos e etapas pelas quais passam os impulsos elétricos que trafegam (i) entre neurônios, (ii) de um neurônio a músculo (atuador) ou (iii) de um neurônio a um órgão sensorial. Dessa maneira, McCulloch e Pitts desenvolveram modelos matemáticos de cada parte de um neurônio biológico: dendritos, sinapses, corpo celular e axônio. Cada ramo dos terminais de recepção (dendritos) é modelado como um canal de transmissão por onde flui a informação de entrada (x_i , $i=1, \dots, n$). A relevância das conexões sinápticas é modelada como um peso (w_{ji} , $i=1, \dots, n$), cujo papel é modelar o fluxo de informação passando por um certo canal de transmissão. A função do corpo celular (realizar o balanço energético) é modelada por uma função de soma das entradas moduladas pelos pesos sinápticos da forma:

$$u = w_1x_1 + w_2x_2 + \dots + w_nx_n - \text{limiar}$$

em que 'u' é a ativação do neurônio. O último componente do neurônio artificial é a função de transferência, que é análoga ao axônio biológico. A saída de um neurônio artificial corresponde à frequência de

descarga do neurônio biológico (NEVES). A figura abaixo apresenta o modelo lógico de um neurônio artificial.




Figura 3 - (mecatrônica fácil ano 6 nº47)

3.2. A Arquitetura das Redes Neurais Artificiais

As redes neurais artificiais podem ainda ser divididas de acordo com sua arquitetura. Que constituem a forma como os neurônios estão organizados. Esta está intrinsecamente ligada ao problema que se deseja solucionar.

Basicamente utiliza-se 3 arquiteturas para as redes neurais artificiais: Feed-forward de uma única camada; Feed-forward de múltiplas camadas e; Redes recorrentes.

Nas redes Feed-forward de uma ou mais camadas temos o fluxo de dados em uma única direção. Quando há mais de uma camada, há a presença de neurônios na camada oculta. As figuras abaixo ilustram a propagação dos dados da camada de entrada até a camada de saída. Note que apesar de possuir duas camadas, entrada e saída, a arquitetura da primeira figura é considerada com uma camada somente, pois na camada de entrada não há processamento.




Figura 4 - Modelo com uma única camada




Figura 5 - Modelo com múltiplas camadas

Ao contrário das redes feed-forward as redes recorrentes possuem laços de realimentação, ou seja, a saída de um neurônio pode ser entrada para outro de uma camada precedente ou, no caso de auto-realimentação, para o próprio neurônio. As redes recorrentes, chamadas de redes com memória, não possuem organização rígida e seus neurônios têm liberdade para se ligar a qualquer outro neurônio (ABELÉM, 1994) (HAYKIN, 2001)

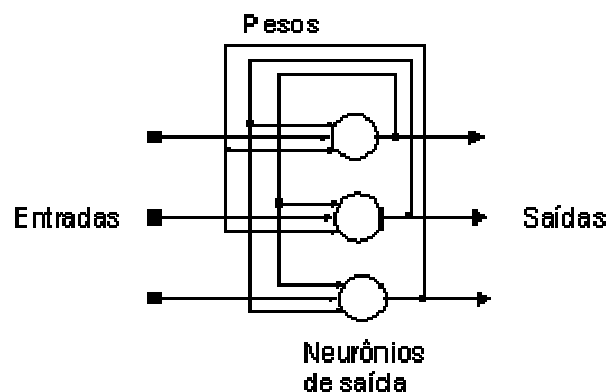


Figura 6 – Modelo recorrente

3.3. Processo de Aprendizados

O processo de aprendizagem ocorre através de um processo interativo de ajuste dos parâmetros livres, pesos sinápticos, por estimulação do ambiente (HAYKIN, 2001).

Os paradigmas de aprendizado são divididos em aprendizado supervisionado e aprendizado não supervisionado, descritos a seguir:

Aprendizado Supervisionado, também chamado de aprendizado com professor. Esta forma de aprendizado se baseia em um conjunto de exemplos de entrada-saída que é apresentada a rede. A partir da entrada a rede realiza seu processamento e a saída obtida é comparada com a saída esperada. Caso não sejam iguais, um processo de ajuste de pesos é aplicado buscando-se um erro mínimo ou aceitável. O algoritmo de aprendizado supervisionado mais comum é o Back-propagation (HAYKIN, 2001).

Aprendizado não supervisionado: é caracterizado pela ausência de algum elemento externo supervisor, ou seja, um padrão de entrada fornecido permite que a rede livremente escolha o padrão de saída a partir das regras de aprendizado adotadas. Possui duas divisões: aprendizado por reforço que consiste no mapeamento entrada-saída através da interação com o ambiente, e aprendizagem não-supervisionada ou auto-organizada onde, a partir de métricas de qualidade do aprendizado ocorre a otimização dos parâmetros livres da rede. Pode, por exemplo, ser utilizada a regra de aprendizagem competitiva. Os algoritmos de aprendizado não supervisionado mais importantes são: Algoritmo de Hopfield e Mapas de Kohonen (HAYKIN, 2001).

Para o aprendizado supervisionado temos o algoritmo Back-propagation, que é um algoritmo de aprendizado supervisionado baseado na correção de erros. Foi publicado por Rumelhart em 1986 no livro *Parallel Distributed Processing*, embora tenha sido proposto por pesquisadores como Bryson e Ho em 1969, Werbos em 1974, Parker em

1985 e Minsky e Papert em 1988 para diversos propósitos (BRAGA, CARVALHO e LUDEMIR, 1998).

Como objetivo o Backpropagation busca encontrar na superfície de erro o menor mínimo global, ou seja, ajustando os pesos sinápticos de forma a minimizarem o erro da rede.

Como um algoritmo de aprendizado supervisionado, o Backpropagation utiliza pares entrada-saída para ajustar os pesos da rede. A frequência, com que estes ajustes são feitos, depende do tipo de treinamento, que pode ser: por padrão (on-line) onde a atualização é realizada após cada exemplo apresentado; por ciclo (batch ou lote) onde a atualização é realizada após todos os exemplos do conjunto de treinamento serem apresentados a rede (HAYKIN, 2001).

Os critérios de parada, embora ainda não existam critérios bem sucedidos para terminar o processo de aprendizado, podem ser: quando, percorrendo-se a superfície de erro, for encontrado um mínimo; a variação do erro for infinitamente pequena sendo insuficiente para melhorar a desempenho da rede; e ao aplicar o conjunto de treinamento um número determinado de vezes, ou seja, baseado no número de épocas. É comum se observar na prática a combinação dos critérios acima (BRAGA, CARVALHO e LUDEMIR, 1998).

3.4. Redes neurais na previsão de séries temporais

Análise de séries temporais é o processo de utilização de técnicas estatísticas para modelar e explicar uma série que é dependente cronológica dos dados. Previsão de séries temporais é o processo de utilização de um modelo para gerar previsões para os eventos futuros com base no conhecido eventos passados. Dados de séries temporais têm uma ordenação natural no tempo - isto difere da típica de mineração de dados / aplicações de máquina de aprendizagem, onde cada ponto de dados é um exemplo independente do conceito a ser aprendido, e a ordenação dos pontos de dados dentro de um conjunto de dados não importa. Exemplos de aplicações de séries temporais incluem:

planejamento de capacidade, reposição de estoques, previsão de vendas e os níveis de pessoal futuro (PENTAHO COMMUNITY, 2011).

A metodologia utilizada nesta monografia visa remover a componente temporal dos exemplos individuais, codificando o tempo com novos atributos de entrada. Desta forma é possível utilizar, inclusive qualquer algoritmo de classificação, já que com os novos atributos, não há mais a necessidade de recorrência. Este modelo utiliza buffers temporários para armazenar as saídas do modelo e disponibilizá-los num passo seguinte. Estes buffers são chamados de variáveis de atraso (lagged, do inglês).

4. Estudo de caso

Neste capítulo será demonstrada a aplicação da metodologia proposta no capítulo 3 em um campo petrolífero de uma empresa de petróleo Brasileira. A previsão estudada aqui tem um horizonte de predição de 18 meses a frente. Atendendo ao requisito de planejamento orçamentário e também o do planejamento de alocação de equipamentos.

Para este estudo foi selecionado um campo com início de operação em outubro de 1996. A Base de dados é composta de 183 linhas com os valores da produção do campo mês a mês. Foi utilizado para todas as avaliações 10% da base de dados para compor o conjunto de avaliação da rede e 18 instâncias para compor o conjunto de validação.

Abaixo será descrito os passos utilizados neste estudo.

4.1. Definição do modelo da RNA

Para este estudo de caso o modelo de rede neural aplicado foi uma rede recorrente de Jordan, onde os atributos de recorrência propagam seus valores da saída para a entrada.

4.2. Pré-processamento dos dados

Na etapa de pré-processamento dos dados avalia-se a disponibilidade de informações e a qualidade das mesmas. Essas técnicas visam aumentar a qualidade dos dados e o poder de expressão destes. Está dividida em 4 outras sub-etapas:

- Na Limpeza busca-se verificar e tratar a existência de dados: incompletos ou indisponíveis, preenchendo os valores faltantes; dados ruidosos, ou seja, que contenham erro em seus valores ou estejam fora de domínio possível, suavizando sua interferência ou; dados inconsistentes, sem valores para informação ou até a inexistência desta, identificando e removendo sua existência
- Integração busca juntar dados de diversas origens
- Enquanto que na Redução objetivo é reduzir o volume de dados sem que isto interfira na qualidade do resultado ou que esta redução de qualidade seja mínima. Se junta a esta última sub-

etapa a Discretização que objetiva melhorar a desempenho do modelo transformando-se valores contínuos em categóricos ou agrupando os valores categóricos já existentes.

- Já a Transformação visa criar, através dos dados existentes, outros derivados destes, com o objetivo de melhor explicá-lo

Neste estudo de caso não foram necessárias as tarefas de Integração, que possui uma única origem, e Redução, pois os dados desta série temporal só possuem 3 (dois) atributos: mês de referência, volume produzido e volume não realizado (perda). Os processos de Limpeza e Transformação estão detalhados abaixo.

4.2.1. Limpeza dos dados

Neste estudo de caso os dados não apresentaram problemas quanto a inconsistências. Esta base é muito bem controlada e confiável. Apesar de no gráfico (figura abaixo) de volumes históricos percebermos vales que fogem dos volumes observados estes representam uma parada completa da operação do campo. Desta forma estes vales não foram preenchidos com nenhum outro valor, o que poderia representar uma descaracterização da verdade.

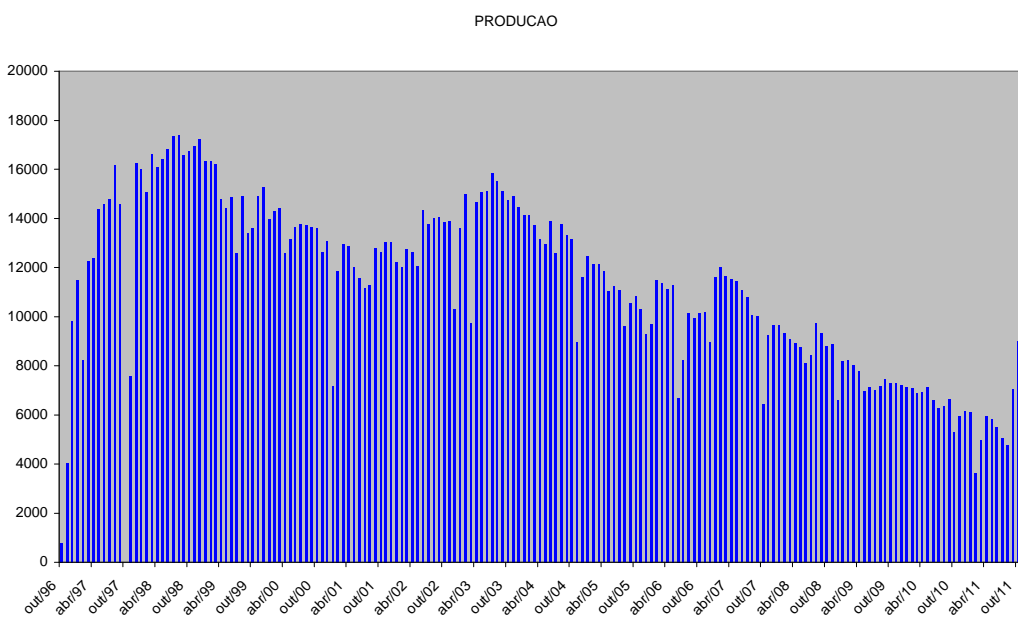


Figura 7 – Gráfico da produção do campo

4.2.2. Transformação

Nesta fase diversas transformações foram avaliadas para garantir o melhor desempenho da rede. A seguir, são descritos os tipos de transformações utilizados. Estas serão detalhadas na seção “Parametrização do modelo”.

1. Criação de atributos com as médias móveis – O objetivo da criação de médias móveis foi verificar se o modelo responderia melhor com uma variável que suavizasse as curvas de produção. Abaixo é exibido um gráfico com as médias móveis de 3, 9, 15 meses (MMx, onde x é o número de períodos na média).




Figura 8 - Gráfico de produção com MM3-9-15

2. Atributos de atraso da rede – O modelo empregado neste caso de uso utiliza uma rede recorrente de Jordan onde a recorrência é feita da saída para entrada. Estes atributos possuem o valor da produção n meses atrás. Nestes atributos foram testados diversos valores com várias quantidades (LagN, onde é o tamanho do atraso, também N pode ser um intervalo): Lag1-18; Lag1-12; Lag1-6 + Lag9 + Lag12 + Lag18 + Lag24;

3. Quantidade de dias no mês – Como o valor da produção representa o volume produzido em um mês e os meses possuem diferentes quantidades de dias este atributo tenta representar esta diferença entre os meses.

4.3. Arquitetura da rede

As arquiteturas avaliadas utilizou o algoritmo Multi Layer Perceptron (MPL) com 1 ou duas camadas escondidas (hidden) variando-se o número de neurônios desta.

Também foram utilizadas as taxas de aprendizado e momentum, valores 0,3 e 0,2 respectivamente. Um indicador com o decaimento da taxa de aprendizado na razão do valor pelo número da época.

Para o número de épocas manteve o valor para todas as avaliações em 5000.

A quantidade de dados para validação foi deixada em 20%.

Para todos os atributos, esses são os valores padrão e serão usados nos experimentos, a menos quando especificado de outra forma.

No próximo capítulo serão analisados os experimentos, bem como avaliados os resultados.

5. Resultados

Neste capítulo serão aplicados diversos experimentos bem como a análise dos resultados obtidos. Ressalto ainda que, diversas outras configurações foram avaliadas sem grandes mudanças nos resultados, sendo então abandonadas por não terem representatividade.

5.1. Experimentos realizados

Descrição de cada experimento e resultados. Todos os experimentos foram realizados utilizando o software Weka 3.7.5, que conta com um módulo para previsão multi-passos. Este modo possibilita a criação das variáveis de atraso podendo apresentá-las para qualquer algoritmo.

5.1.1. Experimento 1

O experimento 1 contou com os valores padrões atribuídos pelo software. Este atribui 22 neurônios para a camada oculta utilizando uma métrica segundo o valor é: (o número de entradas + o número de classes) / 2. Este experimento inicial visa observar como o desempenho da rede pode ser melhorado com as técnicas descritas acima. O programa também atribui automaticamente as variáveis de atraso (LagN) de 1 a 12.

Neurônios na camada escondida	22
Decaimento da taxa de aprendizado	Não decair
Atributos de atraso	Lag1-12

Tabela 1 – Parâmetros do experimento 1

A tabela abaixo mostra o desempenho segundo as métricas de avaliação de erro.

Nº de Passos à frente	Erro na validação			Erro no teste		
	MAE	RMSE	MAPE	MAE	RMSE	MAPE
1	1246,404	1816,625	10,37%	1252,077	1733,822	20,97%
2	1258,606	1632,937	11,08%	1378,004	1912,311	23,11%
3	1252,646	1612,289	10,87%	1411,195	1957,82	23,75%
4	1257,233	1622,823	10,93%	1476,653	2009,224	24,95%
5	1267,129	1641,709	11,01%	1568,847	2076,666	26,67%
6	1270,566	1650,19	11,05%	1613,814	2138,592	27,26%
7	1275,5	1661,099	11,12%	1747,178	2228,268	29,58%
8	1276,42	1667,01	11,17%	1889,236	2319,904	32,10%
9	1287,125	1677,517	11,29%	1922,882	2329,739	33,13%
10	1288,128	1681,034	11,35%	1761,979	2139,334	26,99%
11	1293,624	1686,275	11,45%	1675,105	2058,732	24,22%
12	1285,806	1677,481	11,43%	1860,787	2203,395	26,82%
13	1297,101	1680,74	11,55%	1992,478	2333,003	28,37%
14	1288,441	1661,924	11,54%	2217,88	2520,875	30,99%
15	1273,901	1637,314	11,49%	2363,109	2694,956	30,73%
16	1260,115	1620,053	11,44%	2716,715	3011,62	32,00%
17	1257,832	1616,764	11,47%	3609,199	3613,361	41,46%
18	1248,254	1605,9	11,44%	3424,179	3424,179	40,65%

Tabela 2 – Avaliação de erro do experimento 1

O gráfico abaixo demonstra que o erro no conjunto de dados de validação foi muito grande para cada valor individual. O valor do Mean Absolute Percentage Error (MAPE) de 40,65%, após o 18º passo previsto, demonstra esse comportamento. Caso fosse avaliado também o erro de volume total produzido no período previsto, ou seja, a soma do volume acumulado dos 18 passos à frente (meses), verificar-se-ia que este apresentou um erro de apenas 2,51%. Porém não tendo nenhum compromisso com a previsão mensal.

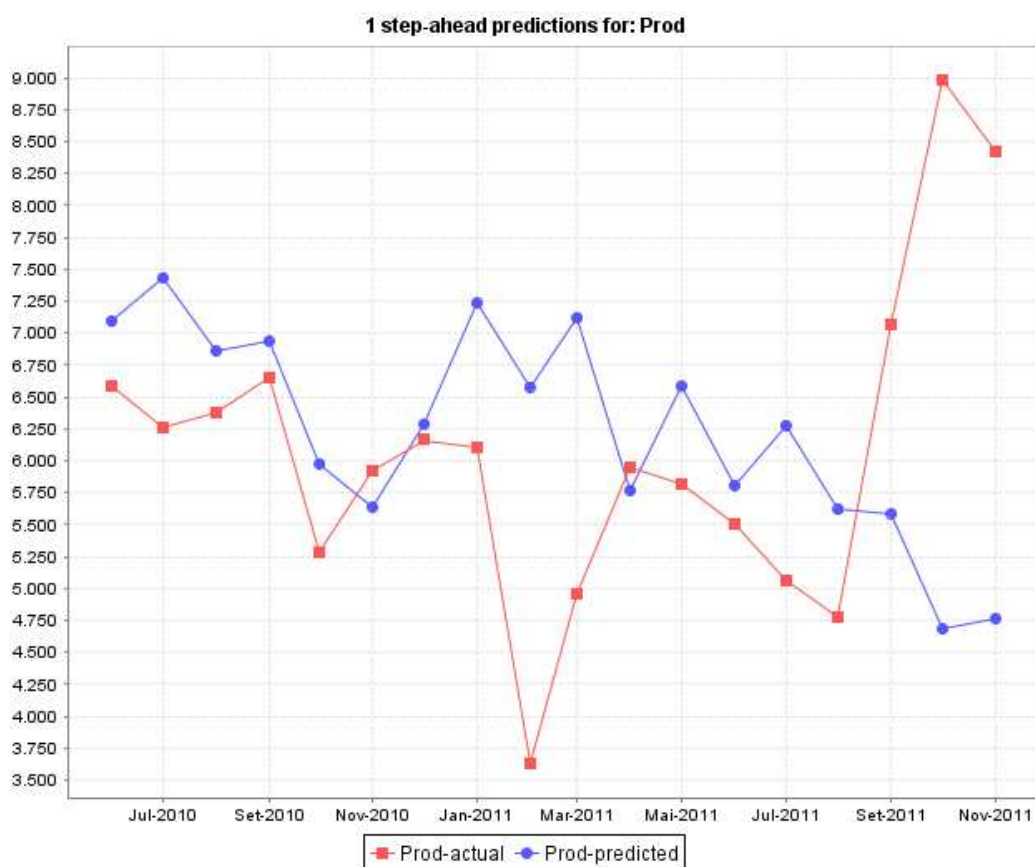


Figura 9 – Previsão experimento 1

5.1.2. Experimento 2

O segundo experimento teve como objetivo verificar o uso de variáveis que suavizassem os picos e vales no gráfico de produção. Dessa forma foi acrescentada as médias móveis de 3, 9 e 15 períodos. Acrescentou-se o decaimento da taxa de aprendizado.

Neurônios na camada escondida	22
Decaimento da taxa de aprendizado	Sim
Número de épocas	5000
Atributos adicionados	MM3-9-15

Tabela 3 – Parâmetros do experimento 2

A tabela abaixo mostra os resultados das métricas de erros. Observa-se aqui que o MAPE ficou em 98,11% após o 18º passo previsto. O que demonstra claramente o efeito das médias móveis influenciou os resultados negativamente.

Nº de Passos à frente	Erro na validação			Erro no teste		
	MAE	RMSE	MAPE	MAE	RMSE	MAPE
1	1246,404	1816,625	7,87%	1252,077	1733,822	22,90%
2	1258,606	1632,937	8,80%	1378,004	1912,311	28,47%
3	1252,646	1612,289	8,94%	1411,195	1957,82	30,07%
4	1257,233	1622,823	9,07%	1476,653	2009,224	31,92%
5	1267,129	1641,709	9,20%	1568,847	2076,666	33,61%
6	1270,566	1650,19	9,32%	1613,814	2138,592	33,70%
7	1275,5	1661,099	9,61%	1747,178	2228,268	34,46%
8	1276,42	1667,01	9,81%	1889,236	2319,904	36,98%
9	1287,125	1677,517	9,97%	1922,882	2329,739	40,35%
10	1288,128	1681,034	9,95%	1761,979	2139,334	38,83%
11	1293,624	1686,275	9,93%	1675,105	2058,732	42,96%
12	1285,806	1677,481	9,96%	1860,787	2203,395	50,38%
13	1297,101	1680,74	10,17%	1992,478	2333,003	61,61%
14	1288,441	1661,924	10,32%	2217,88	2520,875	69,37%
15	1273,901	1637,314	10,42%	2363,109	2694,956	77,56%
16	1260,115	1620,053	10,58%	2716,715	3011,62	91,23%
17	1257,832	1616,764	10,92%	3609,199	3613,361	110,18%
18	1248,254	1605,9	11,03%	3424,179	3424,179	98,11%

Tabela 4 – Avaliação de erro do experimento 2

Além disso, o gráfico abaixo demonstra também que a rede não conseguiu prever nem a inclinação das curvas de produção. Caso fosse avaliado também o erro de volume total produzido no período previsto, ou seja, a soma do volume acumulado dos 18 passos à frente (meses), verificar-se-ia que este apresentou um erro de 16,87%.

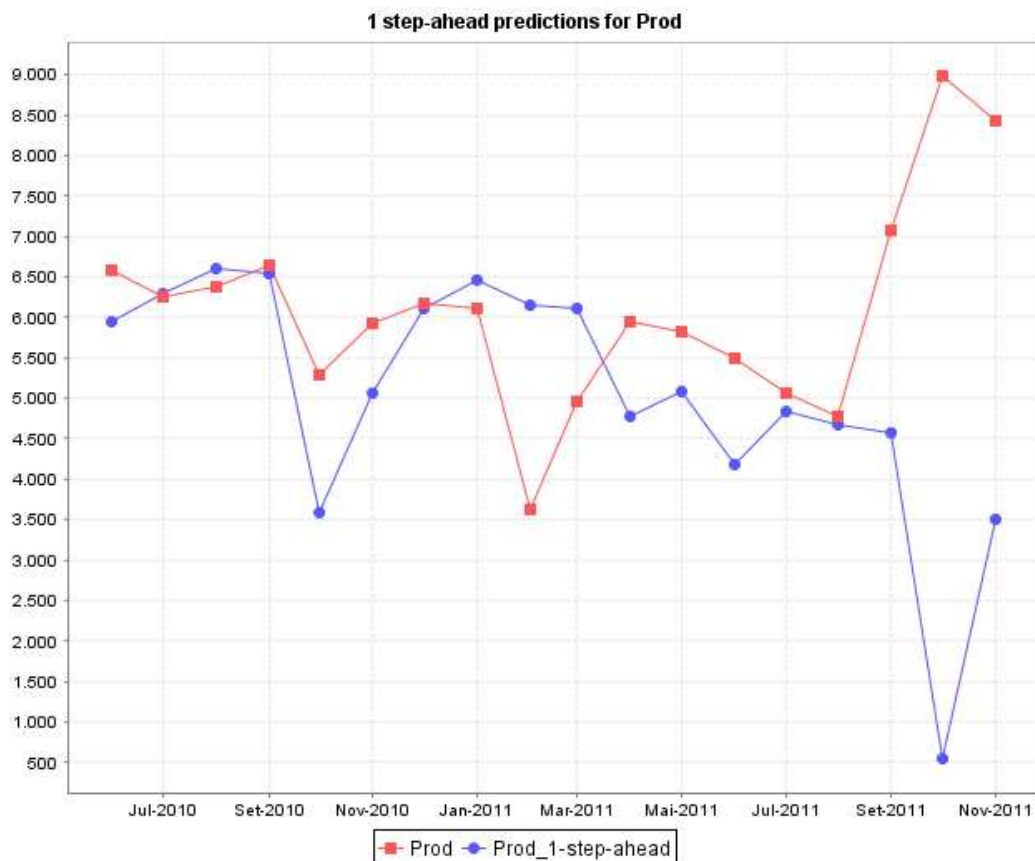


Figura 10 – Previsão experimento 2

5.1.3. Experimento 3

O terceiro experimento deseja verificar o efeito do acréscimo de uma variável para explicar alguns dos picos e vales devido o número de dias de produção diferem nos meses, já que o gráfico representa a produção acumulada do mês. Dessa forma foi acrescentado um atributo com o número de dias no mês. Também foi acrescentada uma camada oculta. A taxa de aprendizado também passou de 0.3 para 0.5. Outros parâmetros foram mantidos conforme experimento anterior.

Neurônios na camada escondida	22, 11
Número de épocas	5000
Taxa de aprendizado	0,5
Decaimento da taxa de aprendizado	Sim
Atributos adicionados	- MM3-9-15 - N° dias no mês

Tabela 5 – Parâmetros do experimento 3

A tabela abaixo mostra os resultados das métricas de erros. Observa-se aqui que o MAPE ficou em 26,24% após o 18º passo previsto. O que demonstra uma melhora no desempenho da rede em relação ao anterior. Como mais de um parâmetro foi alterado não está claro qual provocou esta melhora. Também o erro total do período ficou em 5,35%, o que o torna mais significativo agora já que houve também uma melhora na previsão mensal.

Nº de Passos à frente	Erro na validação			Erro no teste		
	MAE	RMSE	MAPE	MAE	RMSE	MAPE
1	1246,404	1816,625	8,05%	1252,077	1733,822	16,43%
2	1258,606	1632,937	9,53%	1378,004	1912,311	20,64%
3	1252,646	1612,289	9,56%	1411,195	1957,82	21,72%
4	1257,233	1622,823	9,80%	1476,653	2009,224	22,92%
5	1267,129	1641,709	9,96%	1568,847	2076,666	24,75%
6	1270,566	1650,19	10,11%	1613,814	2138,592	24,22%
7	1275,5	1661,099	10,37%	1747,178	2228,268	24,74%
8	1276,42	1667,01	10,55%	1889,236	2319,904	25,84%
9	1287,125	1677,517	10,72%	1922,882	2329,739	27,38%
10	1288,128	1681,034	10,91%	1761,979	2139,334	20,99%
11	1293,624	1686,275	11,04%	1675,105	2058,732	19,74%
12	1285,806	1677,481	11,16%	1860,787	2203,395	21,38%
13	1297,101	1680,74	11,23%	1992,478	2333,003	23,23%
14	1288,441	1661,924	11,39%	2217,88	2520,875	24,32%
15	1273,901	1637,314	11,61%	2363,109	2694,956	24,11%
16	1260,115	1620,053	11,62%	2716,715	3011,62	21,93%
17	1257,832	1616,764	11,72%	3609,199	3613,361	28,02%
18	1248,254	1605,9	11,71%	3424,179	3424,179	26,24%

Tabela 6 – Avaliação de erro do experimento 3

O gráfico abaixo demonstra que o modelo respondeu melhor a curva prevista que neste caso acompanha melhor a silueta da curva real.

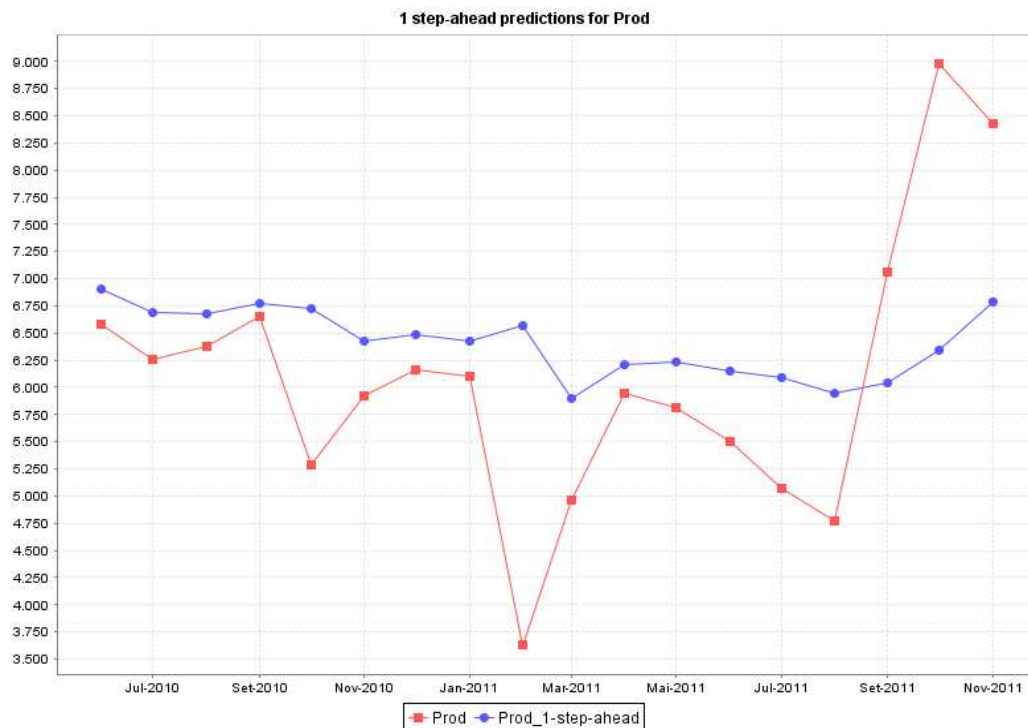


Figura 11 – Previsão experimento 3

5.1.4. Experimento 4

O quarto experimento deseja verificar o ajuste maior das variáveis de atraso. Para isso foram criados os atrasos conforme tabela abaixo.

Neurônios na camada escondida	22, 11
Número de épocas	5000
Atributos adicionados	- MM3-9-15 - N° dias no mês - Lag1-18

Tabela 7 – Parâmetros do experimento 4

A tabela abaixo mostra os resultados das métricas de erros. Observa-se aqui que o MAPE ficou em 25,82% após o 18º passo previsto.

Também o erro total do período ficou em 4,54%, acompanhando também a melhora da previsão mensal.

Nº de Passos à frente	Erro na validação			Erro no teste		
	MAE	RMSE	MAPE	MAE	RMSE	MAPE
1	1246,404	1816,625	7,79%	1252,077	1733,822	15,79%
2	1258,606	1632,937	8,80%	1378,004	1912,311	19,96%
3	1252,646	1612,289	8,78%	1411,195	1957,82	20,82%
4	1257,233	1622,823	8,82%	1476,653	2009,224	21,92%
5	1267,129	1641,709	8,86%	1568,847	2076,666	23,73%
6	1270,566	1650,19	9,03%	1613,814	2138,592	23,09%
7	1275,5	1661,099	9,32%	1747,178	2228,268	23,84%
8	1276,42	1667,01	9,42%	1889,236	2319,904	25,16%
9	1287,125	1677,517	9,48%	1922,882	2329,739	26,87%
10	1288,128	1681,034	9,50%	1761,979	2139,334	20,85%
11	1293,624	1686,275	9,51%	1675,105	2058,732	19,83%
12	1285,806	1677,481	9,54%	1860,787	2203,395	21,57%
13	1297,101	1680,74	9,34%	1992,478	2333,003	23,39%
14	1288,441	1661,924	9,44%	2217,88	2520,875	24,32%
15	1273,901	1637,314	9,53%	2363,109	2694,956	24,08%
16	1260,115	1620,053	9,52%	2716,715	3011,62	21,35%
17	1257,832	1616,764	9,75%	3609,199	3613,361	27,54%
18	1248,254	1605,9	9,71%	3424,179	3424,179	25,82%

Tabela 8 – Avaliação de erro do experimento 4

O gráfico abaixo demonstra que não houve grande avanço neste caso.




Figura 12 – Previsão experimento 4

5.1.5. Experimento 5

O quinto experimento deseja verificar ainda um ajuste das variáveis de atraso. Para isso foram criados os atrasos conforme tabela abaixo.

Neurônios na camada escondida	22, 11
Decaimento da taxa de aprendizado	Sim
Número de épocas	5000
Atributos adicionados	- MM3-9-15 - Nº dias no mês - Lag1-6 - Lag9 - Lag12 - Lag18 - Lag24

Tabela 9 – Parâmetros do experimento 5

A tabela abaixo mostra os resultados das métricas de erros. Observa-se aqui que o MAPE ficou em 22,26% representando mais uma vez uma ligeira melhora em relação ao valor anterior de 25,82% após o 18º passo previsto. Já o erro total do período ficou em 7,84% ante 4,54% da anterior.

Nº de Passos à frente	Erro na validação			Erro no teste		
	MAE	RMSE	MAPE	MAE	RMSE	MAPE
1	1246,404	1816,625	7,77%	1252,077	1733,822	18,61%
2	1258,606	1632,937	8,84%	1378,004	1912,311	23,24%
3	1252,646	1612,289	8,98%	1411,195	1957,82	24,03%
4	1257,233	1622,823	9,29%	1476,653	2009,224	25,31%
5	1267,129	1641,709	9,56%	1568,847	2076,666	27,29%
6	1270,566	1650,19	9,89%	1613,814	2138,592	26,63%
7	1275,5	1661,099	10,28%	1747,178	2228,268	27,17%
8	1276,42	1667,01	10,49%	1889,236	2319,904	28,34%
9	1287,125	1677,517	10,54%	1922,882	2329,739	29,76%
10	1288,128	1681,034	10,67%	1761,979	2139,334	22,98%
11	1293,624	1686,275	10,73%	1675,105	2058,732	21,51%
12	1285,806	1677,481	10,75%	1860,787	2203,395	23,02%
13	1297,101	1680,74	10,88%	1992,478	2333,003	24,92%

14	1288,441	1661,924	10,86%	2217,88	2520,875	25,54%
15	1273,901	1637,314	11,08%	2363,109	2694,956	24,06%
16	1260,115	1620,053	10,97%	2716,715	3011,62	18,76%
17	1257,832	1616,764	11,09%	3609,199	3613,361	24,70%
18	1248,254	1605,9	10,93%	3424,179	3424,179	22,26%

Tabela 10 – Avaliação de erro do experimento 5

O gráfico abaixo demonstra que não houve grande avanço neste caso também.




Figura 13 – Previsão experimento 5

O experimento 5 verificou-se o melhor resultado na previsão da produção de petróleo. No entanto, a mudança que causou o menor MAPE, foram as realizadas no experimento 3 onde um novo atributo foi criado para tentar explicar algumas diferenças existentes de um mês para outro.

Outros ganhos foram observados nos experimentos 4 e 5. Nestes experimentos procuraram-se ajustar melhor as variáveis que transmitem as informações temporais para a rede, os atrasos (variáveis lag). Ambos os modelos trouxeram algum ganho de desempenho.

6. Conclusões e Trabalhos Futuros

Os resultados mostraram que o uso de redes neurais é uma alternativa viável na previsão da produção de petróleo num campo. As redes neurais conseguem capturar a não linearidade das informações possibilitando a análise de movimentos antes desconhecidos.

Ainda há necessidade de diminuir o erro médio nas previsões mês a mês, que se encontra num nível elevado (MAPE ~25%). Mas se considerarmos o erro absoluto de todo o período avaliado verificaremos que este está em 4,54%. O que pode ser baixo para uma previsão de 18 meses à frente. Demonstrando ainda, nesta previsão as curvas na produção mensal, fornecendo mais uma ferramenta para a tomada de decisão, como exemplo o momento para realização de um novo investimento ou manutenção de equipamentos.

Com o objetivo de melhorar o desempenho da rede, trabalhos futuros devem tentar identificar outras variáveis que afetam sua produção. Dessa forma a rede poderia prever melhor os aumentos repentinos de um mês para outro, e principalmente vales, que são mais freqüentes nos dados analisados.

Variáveis que afetam muito a produção são as falhas em equipamentos, as manutenções deste e os projetos de melhoria. Um modelo que identifique estas falhas antes de sua ocorrência pode fornecer uma importante variável na previsão. A inclusão de um atributo para rede neural que forneça a expectativa de aumento da produção desses projetos é outro que certamente diminuiria o erro.

O estudo mostrou que é viável sua aplicação, fornecendo subsídios para elaboração Há a existência de diversos trabalhos para identificar a ocorrência de falhas em equipamentos

Referências Bibliográficas

ABELÉM, A. J. G. **Redes Neurais Artificiais Na Previsão De Séries Temporais**. Rio de Janeiro: Tese Mestrado pela Universidade Católica, 1994.

BRAGA, A. D. P.; CARVALHO, A. P. D. L. F.; LUDEMIR, T. B. **Fundamentos de Redes Neurais Artificiais**. Rio de Janeiro: 11ª Escola de Computação, 1998.

HAYKIN, S. **Redes Neurais Princípios e prática**. Tradução de Paulo Martins Engel. 2ª. ed. Porto Alegre: Bookman, 2001. ISBN 85-7307-718-2.

MCCULLOCH, W. S.; PITTS, W. H. **A logical calculus of the ideas immanent in nervous activity**. [S.l.]: Bulletin of Mathematical Biophysics, v. 5, 1943. 115-133 p.

NELSON, W. B. **Applied Life Data Analysis**. New Jersey: Wiley-Interscience, 2004.

NEVES, M. V. Uma (Breve) Introdução as Redes Neurais Artificiais. **Site da Universidade Federal do Rio Grande do Sul**. Disponível em: <http://www.inf.ufrgs.br/gppd/disc/cmp135/trabs/mvneves/RedesNeurais_relatorio.pdf>. Acesso em: 10 Dezembro 2011.

PENTAHO COMMUNITY. Time Series Analysis and Forecasting with Weka, 2011. Disponível em: <<http://wiki.pentaho.com/display/DATAMINING/Time+Series+Analysis+and+Forecasting+with+Weka>>. Acesso em: 15 dez. 2011.