

Previsão da produção de campos de petróleo utilizando redes neurais

Felipe Paes Ferreira¹, Ítalo de Oliveira Matias²

Universidade Candido Mendes - Campos^{1,2}
fellipecpf@yahoo.com.br¹, italo@ucam-campos.br²

Resumo – Estimar valores futuros, em função de valores passados, tem se tornado um assunto de especial interesse na academia e na indústria, com aplicações em planejamento de produção, matriz energética e mercado de ações, dentre outras. Este trabalho propõe a utilização de redes neurais artificiais *Perceptron* Multicamadas com o treinamento *backpropagation* em conjunto com a técnica de janela de tempo TDNN (*Time Delay Neural Network*) para previsão de séries temporais. Com o objetivo de estimar a produção de campos de petróleo, sobre os dados históricos de produção obtidos no *site* da ANP para os campos de petróleo explorados comercialmente. O modelo de previsão irá fornecer os volumes de produção necessário para o cálculo dos royalties e participações especiais, desta forma a complementar o sistema de distribuição das rendas petrolíferas.

Palavras-chave – rede neural, previsão de séries temporais, produção de petróleo.

Abstract – Estimate future values as a function of past values, has become a subject of special interest in academy and industry, with applications in planning production matrix energy and the stock market, among others. This paper proposes the using neural networks Multilayer Perceptron artificial with backpropagation in training together with the technique of time window TDNN (*Time Delay Neural Network*) for preview time series. To estimate the production of oil fields on the historical data production obtained at the site of ANP to the oil fields operated commercially. The forecasting model will provide the data necessary for the production calculation of royalties and appearances, thus serving as a complement to the distribution system of oil rents.

Keywords – neural networks, forecasting, oil production

1 Introdução

O petróleo é um dos recursos naturais mais valiosos que existe, hoje, no mundo. Sendo motivo de inúmeras crises e guerras entre países. Até o fim de 2011, o consumo mundial de petróleo atingirá a marca de 90 milhões de barris diários e o seu consumo seguirá crescendo e passará, em dez anos, de 100 milhões de barris de petróleo por dia segundo a Agência Internacional de Energia - AIE. O Brasil há pouco tempo se tornou um produtor auto-suficiente. Essa auto-suficiência foi grata a tecnologias empregadas na exploração em águas profundas, local onde está localizada a maioria das reservas de petróleo nacional.

Hoje o petróleo é a principal energia utilizada no mundo. Este recurso é um bem limitado e atualmente há uma grande dependência do seu uso. Seja uma dependência em relação aos seus derivados como combustíveis lubrificantes e matérias-primas para indústrias petroquímicas para a fabricação de plásticos, resinas, solventes e outros produtos presentes em nosso cotidiano. E a dependência financeira, onde é feita uma remuneração à sociedade pela exploração desses recursos, que são escassos e não renováveis, os *royalties* e as participações especiais também chamados de Participações Governamentais (PG).

Os municípios dos estados exploradores de petróleo estão cada vez mais dependentes do petróleo, ou seja, dos *royalties* gerados. Atualmente, as PGs têm sido uma grande fonte de renda para muitos estados e municípios. Os recursos provenientes das PGs não são investidos de forma a garantir uma economia diversificada com o objetivo de reduzir a dependência desses repasses. Vários estudos vêm sendo realizados em torno dessa distribuição de valores, para saber ao certo se estão, realmente, sendo bem investidos pelos beneficiários. Seja em função do volume de recursos envolvidos nestes repasses, seja em função da sua elevada concentração espacial, existe uma forte demanda reprimida por conhecimento histórico e atual sobre a distribuição destas receitas.

1.1 Objetivo

Este artigo visa estimar os volumes de produção de um campo de petróleo, utilizando Redes Neurais Artificiais aplicada a previsão de Séries Temporais. Esse modelo de previsão fornecerá volumes de produção necessários para o cálculo das PGs.

1.2 Motivação

Os volumes de produção estimados por este modelo de previsão irá complementar o sistema GEORoyalties [5] e [9]. Este sistema realiza o cálculo e a distribuição das participações governamentais para os beneficiários do estado do Rio de Janeiro. Para o cálculo das PGs é necessário o volume da produção do campo. Com o objetivo de facilitar o planejamento orçamentário dos beneficiários, para subsidiar o debate acerca de regras alternativas de rateio das rendas do petróleo e uma maior transparência facilitando o acompanhamento, pelos diversos organismos da sociedade, das rendas petrolíferas vindouras.

A organização do trabalho é como segue. A fundamentação teórica com os conceitos de RN e séries temporais é apresentada na Seção 2. A Seção 3 descreve a metodologia utilizada no desenvolvimento do modelo de previsão de série

temporal dos campos de petróleo. Na seção 4 apresenta o sistema desenvolvido e é feito um estudo de caso e finalizando na Seção 5, onde são apresentadas as considerações finais do trabalho.

2 Fundamentação Teórica

2.1 Rede Neural

Segundo [1], uma RNA é um processador paralelo e distribuído, constituído de unidades de processamento simples (neurônios), que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso.

Os neurônios que compõem uma rede neural executam cálculos matemáticos que simulam o comportamento dos neurônios biológicos, fazendo com que essa rede possa “aprender” e se adaptar de acordo com a necessidade. O neurônio artificial, como mostra a Figura 1, similarmente ao natural, recebe um ou mais sinais de entrada e devolve um único sinal de saída, que pode ser distribuído como sinal de saída da rede ou como sinal de entrada para outros neurônios. Os dendritos e axônios são representados apenas pelas sinapses e a intensidade da ligação é representada por uma grandeza denominada peso sináptico. Os valores de entrada são multiplicados pelo peso, ao final, o neurônio totaliza os produtos e o resultado é passado para uma função de ativação.

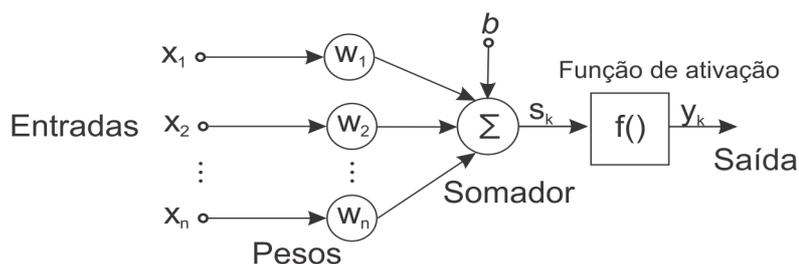


Figura 1 - Neurônio artificial

$$S_k = \sum_{i=1}^n X_i W_i \quad (1)$$

Em uma rede neural a primeira camada é a camada de entrada, a qual recebe os atributos de cada um dos padrões que serão processados pelas camadas intermediárias também chamadas de camadas ocultas. Nas camadas intermediárias é onde ocorre a maior parte do processamento de uma RNA. Os dados são recebidos através das sinapses e, depois de processados, são enviados a camada de saída. A camada de saída é responsável pela apresentação do resultado obtido pelo processamento da RNA. Os resultados obtidos pela rede são, então, comparados com os resultados e o erro é calculado. Com base no erro, os pesos entre os neurônios das três camadas são ajustados e o processo continua, até que uma regra de parada seja atendida.

2.1 Série Temporal

Uma série temporal é uma representação de valores numéricos no tempo, onde as observações estão igualmente espaçadas, em intervalos horários, diários, mensais, trimestrais ou anuais com o objetivo de prever valores futuros de uma série temporal a partir do conhecimento de seus valores passados.

Segundo [2] uma característica importante das séries temporais é que as observações vizinhas são, em geral, dependentes. Enquanto em modelos de regressão, por exemplo, a ordem das observações é irrelevante para a análise, em séries temporais a ordem dos dados é crucial. Portanto, um modo simples de se estudar o comportamento destas séries é a partir da análise e da modelagem destas dependências.

O estudo de séries temporais requer o uso de técnicas específicas. Algumas características das séries temporais: observações correlacionadas são mais difíceis de analisar e requerem técnicas específicas;

- a ordem temporal das observações deve ser considerada;
- é difícil de lidar com observações perdidas e com dados discrepantes devido à natureza seqüencial;
- fatores complicadores, tais como a presença de tendências e a variação sazonal ou cíclica podem ser difíceis de estimar ou remover.

Deste modo, a aplicação de séries temporais utiliza a avaliação dos dados históricos para obter modelos de previsão. O objetivo da análise de séries temporais pode ser realizar previsões de valores futuros enquanto em outras a estrutura da série ou sua relação com outras séries pode ser o interesse principal.

Segundo [3] o objetivo fundamental da análise de uma série temporal é determinar suas componentes básicas buscando identificar um padrão de comportamento da série que possibilite fazer previsões.

2.1.2 Avaliação da precisão

Em problemas de previsão de séries temporais, uma importante tarefa é a de quantificar a qualidade da predição obtida. Isso permite, por exemplo, comparar diversos algoritmos e diversas estruturas de modelos utilizando índices de desempenho. Um dos critérios muito utilizados para se escolher o melhor modelo é o critério do Erro Percentual Absoluto Médio de Previsão (*Mean Absolute Percentile Error* - MAPE). O MAPE indica o valor médio do erro percentual das previsões sobre todo o conjunto de teste. Esta medida é o critério mais utilizado nas engenharias e administração, devido a sua fácil interpretação. Através deste índice é possível saber quanto está errando em termos percentuais. Quanto menor o MAPE, mais próximo do valor real estará nossa previsão. Pela equação (2), onde y_i valor atual da série, \hat{y}_i valor previsto e n quantidade de amostras utilizadas na previsão.

$$\text{MAPE (\%)} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (2)$$

3 Metodologia

Os dados de produção dos campos de petróleo utilizados são fornecidos pela ANP através do *site* (<http://www.anp.gov.br/>), no período agosto de 1998 a dezembro de 2009 para os campos de petróleo explorados comercialmente. Os dados são fornecidos em períodos mensais e corresponde a produção de petróleo e gás natural em metros cúbicos. O sistema possui em seu banco de dados, informações de produções de 84 campos de petróleo. Para cada campo possui dados de produção de petróleo e gás.

Para o conjunto de dados de cada campo, são divididos em duas partes, uma parte corresponde ao treinamento da rede e a segunda metade corresponde ao teste da rede. Para que possa ser realizado o treinamento, os dados passam por um pré-processamento sendo normalizados no intervalo de [0,1]. Para a normalização foi utilizado a equação (3).

$$x_n = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (3)$$

Os volumes de produção sofrem alterações em seus valores devido às paradas de produção nas plataformas de petróleo que podem ser por motivo de greve, manutenção, dentre outros. Esses eventos são difíceis de serem previstos e geram oscilações nos valores da série e interferem no treinamento. Segundo [4], os *outliers* são observações aberrantes que estão distantes do resto de uma série de dados, ou seja, são pontos discrepantes ao longo de uma série temporal.

As séries históricas dos campos possuem diferentes comportamentos, alguns campos no início de sua produção apresentam uma produção crescente, atingem uma produção máxima um pico, em seguida um declínio de produção depois no início de sua produção como é o caso do campo Marlim Figura 2. Há campos que possui uma produção mais regular e outros que já atingiram o pico no início de sua produção e vêm apresentando uma queda ao longo dos anos, como ocorre no campo Albacora Figura 3.

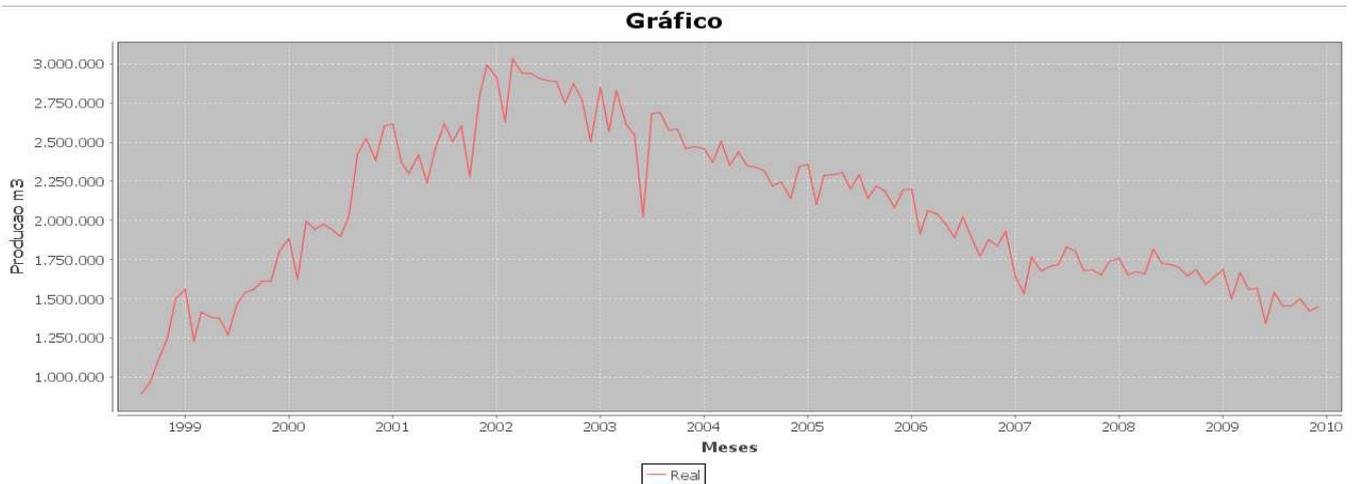


Figura 2 – Série histórica do campo Marlim.

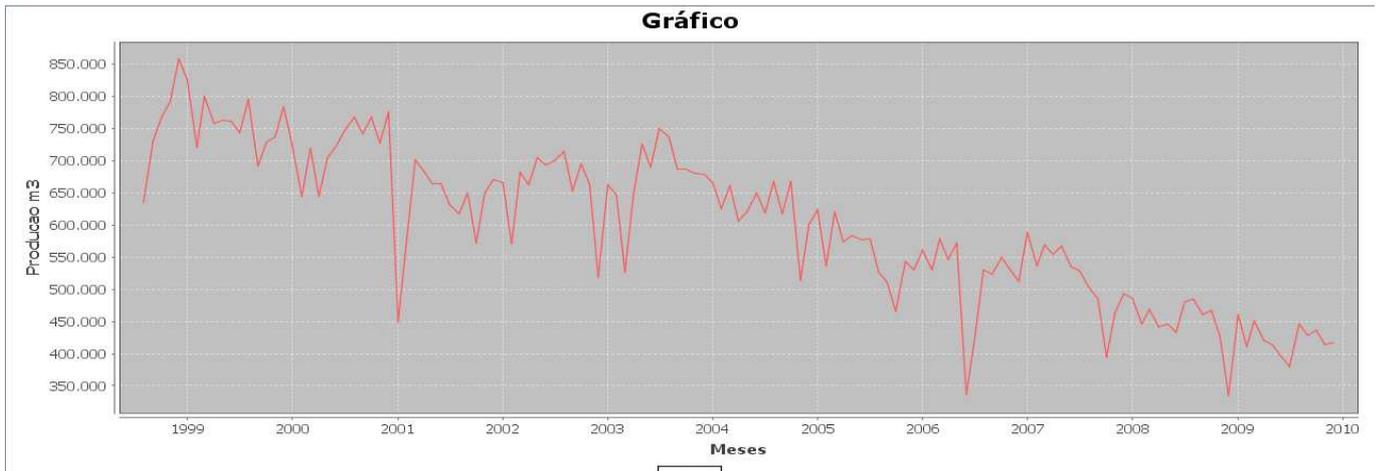


Figura 3 - Série histórica do campo Albacora.

3.1 Redes Neurais em Séries Temporais

As RNAs, dentre as muitas técnicas que surgiram, ganharam especial atenção pela sua habilidade de aprendizado e sua capacidade de generalização, associação e busca paralela. Estas qualidades as tornam capazes de identificar e assimilar as características mais marcantes das séries e extrair conhecimento.

As redes MLP foram originalmente concebidas para executar tarefas de natureza estática, não foram, portanto, idealizadas para tratar problemas temporais, ou seja, não possuem a estrutura adequada para lidar com padrões dinâmicos, portanto, são necessários alguns ajustes em seu treinamento. O método de janela de tempo foi a primeira adaptação da rede MLP treinada com *backpropagation* (ou algoritmos derivados deste) para processamento dinâmico. Para adaptar o treinamento das redes MLP à tarefas dinâmicas, já que estas não apresentam uma arquitetura específica para lidar com esse tipo de problema, é necessário introduzir o atraso no tempo através dos padrões de entrada, para isso foi utilizada uma TDNNs (*Time Delay Neural Networks*). A esta técnica que introduz atraso nos padrões de entrada chamamos janela de tempo. Quando queremos usar redes neurais MLP para previsão de séries temporais, definimos como entrada um conjunto de valores passados ordenados no tempo e como saída o valor posterior a esta seqüência [1]. Tomemos como base a série $X(1), X(2), X(3), X(4), \dots, X(n)$, com o tempo variando de 1 a n . Durante o treinamento, a idéia é fornecer como entradas valores sucessivos da série, por exemplo, os valores de $X(1), X(2)$ e $X(3)$, e definir que a saída desejada é o valor $X(4)$. Na segunda iteração, os valores das entradas seriam $X(2), X(3)$ e $X(4)$ e a saída desejada $X(5)$ e assim sucessivamente para o restante dos pontos da série, conforme a Tabela 1.

Tabela 1 -

Entrada	Saída desejada
$X(1), X(2), X(3)$	$X(4)$
$X(2), X(3), X(4)$	$X(5)$
$X(3), X(4), X(5)$	$X(6)$
...	...
$X(n-3), X(n-2), X(n-1)$	$X(n)$

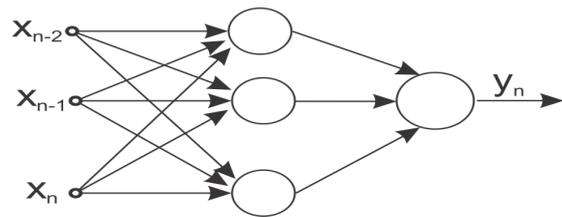


Figura 4 – Topologia de rede com janela de tempo

O número de valores passados usados como entradas é chamado de ordem de linha atraso ou janela. No exemplo citado, usamos 3 valores para prever o próximo, logo, a janela foi de ordem 3. A arquitetura mostrada na Figura 4 é um exemplo de MLP que poderia ser aplicado a esse problema. A quantidade de unidades de entrada varia de acordo com o tamanho da janela adotado. Como acontece em redes MLP convencionais, os nós da camada de entrada não realizam nenhum processamento sobre os padrões de entrada.

A RNA escolhida para representar o modelo de previsão foi a MLP, com quatro entradas na primeira camada, correspondente aos quatro meses sucessivos, representando as produções. Uma camada intermediária com 9 neurônios. Um neurônio na camada de saída (n), representando a produção estimada no tempo n , a ser comparado com o valor real $y(n)$ no mesmo tempo n . A utilização do conjunto de treinamento, permitirá a rede neural extrair o conhecimento necessário para prever os valores futuros, cuja capacidade poderá ser testada em um conjunto de teste.

A apresentação dos valores de entrada da rede se deu através da metodologia de janela de tempo, com uma janela de tamanho 4, onde são relacionados as entradas com as saídas desejadas para a etapa de aprendizado supervisionado. Para previsão de um valor em $x(t+1)$, o valor desejado, relacionará valores passados até $x(t)$, inclusive. De forma análoga, um valor

alvo em $x(t+2)$ utilizará dados históricos até $x(t+1)$, seguindo assim sucessivamente para os demais pares de valores, conforme a Figura 5.

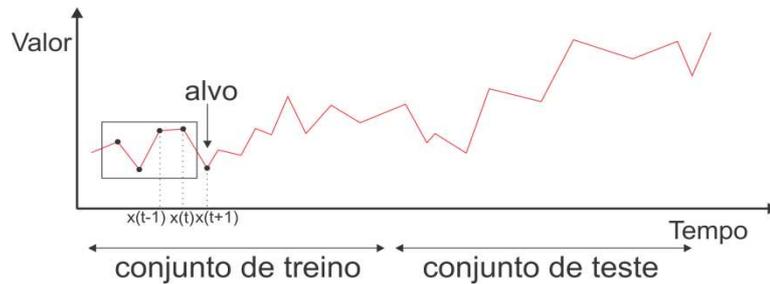


Figura 5 – Janela de tempo na série temporal

Redes com atraso no tempo ou TDNNs são estruturas bem conhecidas para realizar processamento temporal. Trata-se de redes de múltiplas camadas cujos neurônios das camadas intermediária e de saída são replicados ao longo do tempo. A topologia da rede TDNN, mostrado na Figura 4, é basicamente a de uma rede MLP onde cada conexão possui uma memória associada. O treinamento dessa rede cria, a cada iteração, uma rede estática equivalente através do desdobramento da rede no tempo. Essa etapa do treinamento introduz a característica temporal à rede neural, pois, a cada iteração, os sinais fornecidos na iteração anterior como entrada para as camadas oculta e de saída são considerados. Ao replicar as camadas, um modelo dinâmico de RNA é criado. Para treinar esse novo modelo, usa-se um algoritmo de aprendizagem supervisionado em que a cada instante de tempo a saída desejada é comparada com a resposta da rede. Um algoritmo destinado ao treinamento dessas redes é o *backpropagation* temporal [7].

4 Sistema Desenvolvido

Para realizar da previsão da produção dos campos de petróleo, foi desenvolvido um sistema utilizando a linguagem de programação Java para a implementação da RNA. Para isso, possui como entrada o campo de petróleo, a taxa de erro da RNA, quantidade de passos à frente (meses), tamanho do conjunto de treinamento e o tipo de produção do campo de petróleo óleo ou gás. O resultado da previsão apresentado de forma gráfica, a produção real do campo e a produção prevista e também de forma tabular e o cálculo do MAPE.

4.1 Estudo de Caso

Nesta seção será apresentado o funcionamento do sistema e a previsão da produção de óleo e gás para o campo Vermelho. A utilização do programa se inicia com a escolha do campo de petróleo. Para cada campo, é gerado o gráfico com a sua produção que pode ser: de óleo ou de gás, a seguir é informado a taxa de erro 0.09, a quantidade de passos a frente: 24 meses, o tamanho do conjunto de treinamento: 50%. O sistema utiliza uma taxa de aprendizado de 0.1.

Após o preenchimento dos parâmetros de entrada, o sistema realiza a previsão. A Figura 6 mostra o resultado da previsão para a série de óleo.



Figura 6 – Resultado da previsão para a série de óleo.

O resultado do treinamento da RN para o campo Vermelho, obteve um MAPE de 4,69%. Em comparação com o conjunto de dados reais, os dados do conjunto de teste ficaram bem próximo ao desejado. Para o conjunto de dados futuros, foram estimados um conjunto de 24 passos à frente (2 anos).

A seguir, é apresentado a previsão da produção de gás para o campo Vermelho. A Figura 7 mostra o resultado do treinamento para a série de gás. Utilizando uma taxa de erro de 0.09, tamanho do conjunto de treinamento 50%.



Figura 7 – Resultado da previsão para a série de gás.

O período destinado ao treinamento compreende agosto de 1998 a abril de 2004. Neste período a série apresentou diversas oscilações, que foi minimizado com o ajuste de *outliers*. No período de teste o comportamento da série se apresentou de forma mais regular. Os padrões extraídos da série de treinamento foram então testados com a série de testes, resultando em um MAPE 4,60%. Os valores estimados em comparação com valores reais apresentaram uma diferença maior do desejado.

O campo Vermelho apresenta algumas oscilações de comportamento em sua série, ou seja, em determinados meses apresenta uma queda considerável em sua produção. Ao realizar a previsão para o conjunto de testes, esse comportamento influencia no resultado gerado. Os padrões extraídos do conjunto de treinamento são testados com o conjunto de validação, como este conjunto apresenta uma oscilação menor a rede tem um erro maior.

A Tabela 1 apresenta os valores reais (com os *outliers* removidos) e os valores previstos para o conjunto de teste, no período de maio de 2004 e dezembro de 2009 do campo analisado anteriormente.

Tabela 1 – Valores reais e valores previstos.

Data	Valor Real (m3)	Valor Previsto(m3)	Data	Valor Real(m3)	Valor Previsto(m3)
Mai 2004	57.484,00	55.492,50	Março 2007	58.388,23	54.409,63
Junho 2004	56.630,00	57.901,76	Abril 2007	55.534,93	59.291,84
Julho 2004	57.813,00	56.982,48	Mai 2007	52.681,63	55.847,37
Agosto 2004	59.763,00	58.033,18	Junho 2007	52.393,72	52.976,64
Setembro 2004	56.375,00	60.072,41	Julho 2007	55.381,12	53.710,55
Outubro 2004	57.577,00	55.998,80	Agosto 2007	54.322,04	56.802,87
Novembro 2004	55.206,50	57.743,06	Setembro 2007	51.295,67	55.034,69
Dezembro 2004	52.836,00	55.574,18	Outubro 2007	48.269,29	52.037,66
Janeiro 2005	55.288,00	53.366,34	Novembro 2007	51.341,53	50.098,60
Fevereiro 2005	51.120,00	56.508,13	Dezembro 2007	52.579,76	53.635,64

Março 2005	49.828,00	52.113,74	Janeiro 2008	50.000,00	54.371,99
Abril 2005	48.536,00	51.275,78	Fevereiro 2008	50.300,75	51.267,96
Mai 2005	51.171,00	50.856,20	Março 2008	50.601,49	52.052,37
Junho 2005	53.563,50	53.362,12	Abril 2008	50.036,01	52.593,48
Julho 2005	55.956,00	55.245,55	Mai 2008	53.495,44	51.833,12
Agosto 2005	57.107,00	56.862,95	Junho 2008	50.828,04	55.215,04
Setembro 2005	54.796,00	57.526,31	Julho 2008	50.441,17	52.127,64
Outubro 2005	58.344,00	54.900,70	Agosto 2008	49.887,03	51.876,99
Novembro 2005	59.652,00	58.996,84	Setembro 2008	45.562,34	51.889,81
Dezembro 2005	62.080,00	60.013,97	Outubro 2008	46.589,77	48.089,54
Janeiro 2006	59.541,00	61.874,55	Novembro 2008	46.323,23	49.669,16
Fevereiro 2006	59.745,50	58.751,67	Dezembro 2008	46.056,69	49.617,54
Março 2006	59.950,00	59.297,37	Janeiro 2009	46.758,88	49.089,04
Abril 2006	58.116,00	59.899,70	Fevereiro 2009	44.067,43	49.818,60
Mai 2006	61.496,18	57.736,78	Março 2009	42.986,30	47.457,71
Junho 2006	64.876,35	61.702,84	Abril 2009	46.156,70	46.924,76
Julho 2006	69.804,30	65.021,48	Mai 2009	46.992,00	50.005,10
Agosto 2006	67.884,35	69.580,59	Junho 2009	48.673,59	50.149,17
Setembro 2006	64.554,56	66.135,10	Julho 2009	50.180,13	51.157,72
Outubro 2006	64.668,08	62.430,94	Agosto 2009	46.308,22	52.364,96
Novembro 2006	61.100,47	63.772,97	Setembro 2009	48.186,69	48.596,18
Dezembro 2006	61.167,69	60.036,71	Outubro 2009	47.029,37	50.816,33
Janeiro 2007	58.508,23	60.577,95	Novembro 2009	46.234,53	49.920,93
Fevereiro 2007	54.578,69	58.111,99	Dezembro 2009	49.670,32	49.034,03

A Tabela 2 apresenta os valores previstos para 24 passos (meses) a frente, representando um período de 2 anos. Esses valores foram comparados com os valores reais para o ano de 2010, disponíveis no sítio da ANP.

Tabela 2 – Valores previstos para 24 passos (meses) a frente.

Data	Valor Real (m3)	Valor Previsto (m3)	Data	Valor Real (m3)	Valor Previsto (m3)
Janeiro 2010	52.680,81	52.435,57	Janeiro 2011	n/d	58.146,45
Fevereiro 2010	43.687,00	54.456,67	Fevereiro 2011	n/d	58.192,12
Março 2010	46.347,12	55.560,49	Março 2011	n/d	58.227,29
Abril 2010	46.297,71	56.243,09	Abril 2011	n/d	58.254,36
Mai 2010	48.747,46	56.707,42	Mai 2011	n/d	58.275,20
Junho 2010	44.560,97	57.074,46	Junho 2011	n/d	58.291,24
Julho 2010	43.822,03	57.367,36	Julho 2011	n/d	58.303,59
Agosto 2010	47.192,94	57.597,95	Agosto 2011	n/d	58.313,10
Setembro 2010	46.609,50	57.774,46	Setembro 2011	n/d	58.320,43
Outubro 2010	46.572,25	57.908,27	Outubro 2011	n/d	58.326,08
Novembro 2010	43.667,04	58.009,70	Novembro 2011	n/d	58.330,43
Dezembro 2010	45.290,24	58.087,09	Dezembro 2011	n/d	58.333,79

Como forma de avaliar o desempenho do modelo de previsão desenvolvido, foram testados para outros campos utilizando a série óleo, mostrado na Tabela 3.

Tabela 3 – Resultado MAPE para os outros campos.

Campo	Tamanho treinamento: 50%		Tamanho treinamento: 70%	
	erro	MAPE	erro	MAPE
Marlim	0.09	4,69%	0.15	3,55%
Vermelho	0.09	4,70%	0.11	4,89%
Cherne	0.09	5,91%	0.13	4,79%
Enchova	0.09	4,05%	0.13	3,28%

5 Conclusão

As RNAs constituem uma poderosa e complexa técnica computacional de Inteligência Artificial e em conjunto com a técnica de janela de atraso de tempo, formam uma ótima ferramenta para previsão de séries temporais. Em relação à previsão usando a RNA notou-se que esta representação diverge à medida que o horizonte de previsão aumenta. A divergência se dá devido ao distanciamento da série. De acordo com o índice de desempenho apresentado, as RNAs pode ser considerada um modelo eficiente para previsões de médio-prazo (1 a 2 anos à frente).

A previsão da produção dos campos de petróleo é fundamental para o cálculo e distribuição das Participações Governamentais. Conhecer os valores de futuros repasses contribui para um melhor planejamento dado a essas receitas. O Sistema permite ser acoplado pela camada de cálculo e distribuição das PGs para fornecer os volumes de produção para o campo. É importante notar que o sistema não leva em consideração para a previsão, fatores que podem influenciar na produção de um campo. Uma parada de produção seja por motivo de greve, manutenção, dentre outros. Como também, uma nova plataforma de petróleo a ser incorporada a um campo, aumentando a sua produção. Portanto, a previsão para um determinado mês pode ter uma diferença considerável se houver uma parada de produção, ou seja, são fatores que não são possíveis de estimar.

Enfim, o sistema desenvolvido requer uma série histórica de produção para que possa ser estimado produções futuras. Para campos novos com pouca informação de produção disponibilizados e para campos ainda não existentes, o que inclui, entre outros, as áreas do pré-sal ainda não licitadas, o sistema não é capaz de realizar a previsão da produção. Para uma previsão de produção dos campos nessas situações, é necessário dados confidenciais, não considerados neste trabalho. Para campos novos o sistema poderá realizar a previsão, porém, com um horizonte menor e com um grau de incerteza maior. Os campos pertencentes as áreas do pré-sal despertam um interesse maior em conhecer os valores a serem pagos de royalties e participações especiais, devido as suas elevadas estimativas de reserva. O trabalho foi realizado utilizando dados de produção de óleo e gás disponíveis no sítio da ANP.

Finalmente, o estudo de caso apresentando mostra de forma clara e objetiva como usar o sistema e foi possível fazer a validação com valores reais, mostrando que os resultados obtidos são bem próximos dos valores reais para os anos testados.

7 Referências

- [1] HAYKIN, S. Redes Neurais: Princípios e Prática, Porto Alegre: **Bookman**, (2001).
- [2] EHLERS, R. S. Análise de Séries Temporais. Curitiba, PR: **Laboratório de Estatística e Geoinformação, Departamento de Estatística**, (2009).
- [3] MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. J. Forecasting: methods and applications. New York: **John Wiley & Sons**, (1998).
- [4] MADDALA, G.S., KIM, I.M., Unit roots, cointegration, and structural change. **New York: Cambridge University**, 505 p. (1998).
- [5] VASCONCELLOS, R. A. E. de; FERREIRA, F. P.; GONZALEZ, S. M.; VALENTE, R. Georoyalties: sistema de geoprocessamento para visualizar a distribuição dos royalties do petróleo. **XXVIII Encontro Nacional de Engenharia de Produção, Rio de Janeiro**, Agosto (2008).
- [6] ORACLE, C. I. Java. (2010). Acessado em 10/07/2010. Disponível em: <<http://www.oracle.com/technetwork/java/index.html>>.
- [7] BRAGA, A. D. P.; CARVALHO, A. C. P. D. L. F. D.; LUDERMIR, T. B. Redes Neurais Artificiais Teoria e Aplicações. Rio de Janeiro: **Livros Técnicos e Científicos Editora**, (2000)
- [8] RUSSELL, S.; NORVIG, P. Artificial Intelligence - A Modern Approach. New Jersey: **Prentice-Hall**, (1995).
- [9] SERRA, R. V.; GONZÁLES, S. M.; VASCONCELLOS, R. A.; FERREIRA, F. P.; MUNIZ, T. Projeção das rendas petrolíferas para o estado do rio de janeiro. **Petróleo, Royalties & Região**, Campos dos Goytacazes, n. 25, p. 1–10, 9 (2009).