

## *Dissertação de Mestrado*

# **PREDIÇÃO NÃO-LINEAR DE CURVAS DE PRODUÇÃO DE PETRÓLEO VIA REDES NEURAIS RECURSIVAS**

**Aldayr Dantas de Araújo Júnior**

**Natal, janeiro de 2010**

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE- UFRN  
CENTRO DE TECNOLOGIA - CT  
CENTRO DE CIÊNCIAS EXATAS E DA TERRA – CCET  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA E ENGENHARIA DE  
PETRÓLEO - PPGCEP

DISSERTAÇÃO DE MESTRADO

**PREDIÇÃO NÃO-LINEAR DE CURVAS DE PRODUÇÃO DE  
PETRÓLEO VIA REDES NEURAS RECURSIVAS**

**Aldayr Dantas de Araújo Júnior**

**Orientador:** Prof. Dr. Adrião Duarte Dória Neto

**Co-orientador:** Prof. Dr. Wilson da Mata

**Natal, RN, Janeiro de 2010**

**PREDIÇÃO NÃO-LINEAR DE CURVAS DE PRODUÇÃO DE  
PETRÓLEO VIA REDES NEURAS RECURSIVAS**

**Aldayr Dantas de Araújo Júnior**

**Natal/RN, Janeiro de 2010**

**Aldayr Dantas de Araújo Júnior**

**“Predição Não-Linear de Curvas de Produção de Petróleo Via Redes Neurais Recursivas”**

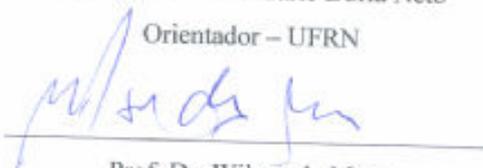
Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência e Engenharia de Petróleo PPGCEP, da Universidade Federal do Rio Grande do Norte, como parte dos requisitos para obtenção do título de Mestre em Ciência e Engenharia de Petróleo.

Aprovado em 27 de Jan de 2010.



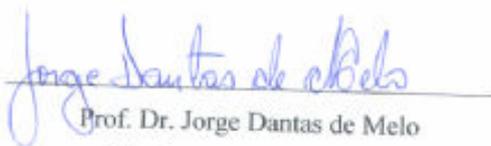
Prof. Dr. Adrião Duarte Dória Neto

Orientador – UFRN



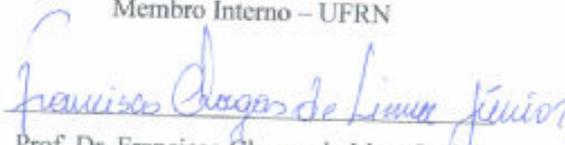
Prof. Dr. Wilson da Mata

Co-orientador – UFRN



Prof. Dr. Jorge Dantas de Melo

Membro Interno – UFRN



Prof. Dr. Francisco Chagas de Lima Junior

Membro Interno – UERN

**Araújo Júnior**, Aldayr Dantas – Predição não-linear de curvas de produção de petróleo via redes neurais recursivas. Dissertação de Mestrado, UFRN, Programa de Pós-Graduação em Ciência e Engenharia de Petróleo. Área de Concentração: Pesquisa e Desenvolvimento em Ciência e Engenharia de Petróleo. Linha de Pesquisa: Automação na Indústria de Petróleo e Gás Natural, Natal-RN, Brasil.

**Orientador:** Prof. Dr. Adrião Duarte Dória Neto

**Co-orientador:** Prof. Dr. Wilson da Mata

---

### ***RESUMO***

Uma das atividades essenciais na engenharia de petróleo é a estimativa de produção de óleo existente nas reservas petrolíferas. O cálculo dessas reservas é crucial para a determinação da viabilidade econômica de sua exploração. Atualmente, a indústria do petróleo tem se deparado com problemas para analisar a produção enquanto facilidades operacionais disponibilizam um volume de informações que crescem exponencialmente. Técnicas convencionais de modelagem de reservatórios como simulação matemática e visualização estão bem desenvolvidas e disponíveis. A proposta deste trabalho é o uso de técnicas inteligentes, como as redes neurais artificiais, para a predição de produção de petróleo e comparar seus resultados com os obtidos pela simulação numérica, método bastante utilizado na prática para a realização de predição do comportamento da produção de petróleo. As redes neurais artificiais serão usadas devido a sua capacidade de aprendizado, adaptação e interpolação.

---

**Palavras-chave:** predição, redes neurais artificiais, simulação numérica.

***ABSTRACT***

---

One of the main activities in the petroleum engineering is to estimate the oil production in the existing oil reserves. The calculation of these reserves is crucial to determine the economical feasibility of your exploitation. Currently, the petroleum industry is facing problems to analyze production due to the exponentially increasing amount of data provided by the production facilities. Conventional reservoir modeling techniques like numerical reservoir simulation and visualization were well developed and are available. This work proposes intelligent methods, like artificial neural networks, to predict the oil production and compare the results with the ones obtained by the numerical simulation, method quite a lot used in the practice to realization of the oil production prediction behavior. The artificial neural networks will be used due your learning, adaptation and interpolation capabilities.

---

**Keywords:** prediction, artificial neural networks, numerical simulation.

"Talvez eu tenha passado muitas realizações, muitos desafios, muitos sonhos, de uma vida maravilhosa... uma vida de sucesso, uma vida de diversões. E realmente sou privilegiado: sempre tive uma vida muito boa. Mas tudo isso que consegui foi através de dedicação, com perseverança, e muito desejo de atingir meus objetivos, muito desejo de vitória: vitória na vida, não vitória como piloto. Seja quem você for, seja qualquer posição que você tenha na vida, do nível altíssimo ao mais baixo social, tenha sempre como meta: força, muita determinação, e sempre faça tudo com muito amor, e com muita fé em Deus; que um dia você chega lá... de alguma maneira, você chega lá."

**(Ayrton Senna)**

## **Dedicatória**

*Este trabalho é dedicado aos meus pais Aldayr e Aura Helena e aos meus irmãos Arthur e Ana Júlia. Que sempre estiveram do meu lado não só na realização deste trabalho, mas em todos os momentos da minha vida.*

## **Agradecimentos**

À Deus, por permitir que esse momento tão importante acontecesse em minha vida.

Aos meus pais Aldayr e Aura Helena e aos meus irmãos Arthur e Ana Júlia por compartilharem comigo suas vidas e experiências e são responsáveis por todos os meus êxitos.

À minha família por todo incentivo ao longo dessa jornada.

Aos amigos do PPGCEP pelo apoio e incentivo diante das inúmeras dificuldades inerentes à nossa jornada.

À Keila Regina pela amizade, companheirismo e por toda ajuda imprescindível para a realização deste trabalho.

Aos amigos do Instituto Federal de Alagoas e da empresa Chemtech que sempre me apoiaram nos momentos de dificuldade.

Ao professor Allan Medeiros pela grande contribuição dada à realização deste trabalho.

Ao professor e orientador Adrião Duarte pela confiança depositada em mim e por compartilhar seus conhecimentos e experiências essenciais para a realização deste trabalho.

Ao professor co-orientador Wilson da Mata por todo esforço e dedicação ao programa e a nós alunos.

Aos professores e funcionários do PPGCEP pela receptividade e presteza.

A todos, credito os eventuais méritos que passo a receber.

## ÍNDICE

|          |   |           |
|----------|---|-----------|
| <b>1</b> | <b>Introdução Geral .....</b>                                 | <b>2</b>  |
| <b>2</b> | <b>Reservatórios e Campos Inteligentes .....</b>              | <b>6</b>  |
| 2.1      | Considerações sobre Engenharia de Reservatórios .....         | 6         |
| 2.1.1    | Volume Original de Hidrocarbonetos.....                       | 6         |
| 2.1.1.1  | Analogia .....  | 6         |
| 2.1.1.2  | Análise de Risco .....  | 7         |
| 2.1.1.3  | Método Volumétrico .....                                      | 7         |
| 2.1.2    | Desempenho do Reservatório.....                               | 8         |
| 2.1.2.1  | Análise de Declínio de Produção.....                          | 8         |
| 2.1.2.2  | Equação de Balanço de Materiais.....                          | 10        |
| 2.1.2.3  | Simulação Numérica de Reservatórios.....                      | 11        |
| 2.2      | Completação Inteligente.....                                  | 12        |
| 2.2.1    | Poços com Completação Inteligente .....                       | 13        |
| 2.2.2    | Campo Inteligente .....                                       | 14        |
| <b>3</b> | <b>Predição Inteligente e Redes Neurais Artificiais .....</b> | <b>19</b> |
| 3.1      | Redes Neurais Artificiais.....                                | 19        |
| 3.1.1    | Perceptron de Múltiplas Camadas .....                         | 22        |
| 3.1.2    | Predição de Séries Temporais com Redes MLP.....               | 25        |
| 3.1.3    | O Algoritmo de Levenberg-Marquardt .....                      | 29        |
| 3.1.4    | Vantagens das Redes Neurais Artificiais.....                  | 31        |
| <b>4</b> | <b>Estado da Arte .....</b>                                   | <b>34</b> |
| <b>5</b> | <b>Materiais e Métodos .....</b>                              | <b>38</b> |
| 5.1      | Ferramentas Computacionais .....                              | 38        |
| 5.2      | Modelo Físico .....   | 39        |
| 5.3      | Propriedades da Rocha-Reservatório.....                       | 40        |
| 5.4      | Características Operacionais do Modelo Base .....             | 41        |

|          |   |           |
|----------|---|-----------|
| 5.5      | Parâmetros Analisados .....   | 41        |
| 5.6      | Preditor Neural Aplicado.....   | 43        |
| 5.7      | Metodologia de Trabalho.....  | 46        |
| <b>6</b> | <b>Resultados e Discussões.....</b>   | <b>48</b> |
| 6.1      | Predição com Vazão de Injeção, Título de Vapor e Intervalo de Completação Constantes .                  | 49        |
| 6.1.1    | Predição para o Regressor de Saída com uma Memória de Linha de Atraso de Ordem 2.                       | 49        |
| 6.1.2    | Predição para o Regressor de Saída com uma Memória de Linha de Atraso de Ordem 10<br>.....              | 56        |
| 6.2      | Predição com Título de Vapor e Intervalo de Completação Constantes e Vazão de Injeção<br>Variável ..... | 62        |
| 6.2.1    | Predição para o Regressor de Saída com uma Memória de Linha de Atraso de Ordem<br>2.....                | 63        |
| 6.2.2    | Predição para o Regressor de Saída com uma Memória de Linha de Atraso de Ordem<br>10.....               | 69        |
| <b>7</b> | <b>Conclusões e Recomendações .....</b>   | <b>78</b> |
|          | <b>Referências .....</b>  | <b>80</b> |

## ÍNDICE DE FIGURAS

### Capítulo II

|   |    |
|---|----|
| Figura 2.1 Representação artística de um poço multilateral.....                   | 13 |
| Figura 2.2 Esquema típico de poço com completção inteligente .....                | 14 |
| Figura 2.3 Modelo de fluxo de campo inteligente.....                              | 15 |
| Figura 2.4 Esquema de campo inteligente que pode surgir em um futuro próximo..... | 16 |

### Capítulo III

|   |    |
|---|----|
| Figura 3.1. Modelo matemático de um neurônio artificial ..... | 20 |
| Figura 3.2. Função de ativação degrau.....                    | 21 |
| Figura 3.3. Função de ativação linear.....                    | 21 |
| Figura 3.4. Função de ativação sigmóide .....                 | 21 |
| Figura 3.5. Rede Neural feedforward .....                     | 23 |
| Figura 3.6. Modelo de espaço de estados .....                 | 24 |
| Figura 3.7. Predição h passos à frente .....                  | 26 |
| Figura 3.8. Rede NARX .....                                   | 28 |

### Capítulo V

|  |    |
|--|----|
| Figura 5.1. Modelo base .....                                    | 39 |
| Figura 5.2 .Esquemas de injeção de vapor .....                   | 43 |
| Figura 5.3. Preditor construído a partir de uma Rede Neural..... | 44 |

### Capítulo VI

|   |    |
|---|----|
| Figura 6.1. Treinamento para a curva de produção acumulada.....                 | 50 |
| Figura 6.2. Sinal erro de treinamento da produção acumulada .....               | 51 |
| Figura 6.3. Sinal da produção acumulada obtido pela predição de 12 passos.....  | 52 |
| Figura 6.4. Sinal erro de predição para a produção acumulada de 12 passos ..... | 52 |
| Figura 6.5. Treinamento para a curva de vazão.....                              | 53 |
| Figura 6.6. Sinal erro de treinamento da vazão .....                            | 54 |
| Figura 6.7. Sinal da vazão obtido pela predição de 9 passos.....                | 55 |
| Figura 6.8. Sinal erro de predição para a vazão de 9 passos .....               | 55 |

|  |    |
|--|----|
| Figura 6.9. Treinamento para a curva de produção acumulada.....  | 56 |
| Figura 6.10. Sinal erro de treinamento da produção acumulada .....   | 57 |
| Figura 6.11. Sinal da produção acumulada obtido pela predição de 12 passos.....                                | 58 |
| Figura 6.12. Sinal erro de predição para a produção acumulada de 12 passos .....                               | 58 |
| Figura 6.13. Treinamento para a curva de vazão.....  | 59 |
| Figura 6.14. Sinal erro de treinamento da vazão .....  | 60 |
| Figura 6.15. Sinal da vazão obtido pela predição de 8 passos.....  | 61 |
| Figura 6.16. Sinal erro de predição para a vazão com 8 passos .....  | 61 |
| Figura 6.17. Treinamento para a curva de produção acumulada com a vazão de injeção variada. 63                 |    |
| Figura 6.18. Sinal erro de treinamento da produção acumulada com a vazão de injeção variada . 64               |    |
| Figura 6.19. Sinal da produção acumulada obtido pela predição de 12 passos com a vazão de injeção variada..... | 65 |
| Figura 6.20. Sinal erro de predição para a produção acumulada de 12 passos com a vazão de injeção variada..... | 65 |
| Figura 6.21. Treinamento para a curva de vazão de petróleo com a vazão de injeção variada.....                 | 66 |
| Figura 6.22. Sinal erro de treinamento da vazão de petróleo com a vazão de injeção variada .....               | 67 |
| Figura 6.23. Sinal da vazão de petróleo obtido pela predição de 12 passos.....                                 | 68 |
| Figura 6.24. Sinal erro de predição para a vazão de 12 passos .....  | 68 |
| Figura 6.25. Treinamento para a curva de produção acumulada.....   | 69 |
| Figura 6.26. Sinal erro de treinamento da produção acumulada .....   | 70 |
| Figura 6.27. Sinal da produção acumulada obtido pela predição de 12 passos.....                                | 71 |
| Figura 6.28. Sinal erro de predição para a produção acumulada de 12 passos .....                               | 71 |
| Figura 6.29. Treinamento para a curva de vazão.....  | 72 |
| Figura 6.30. Sinal erro de treinamento da vazão .....  | 73 |
| Figura 6.31. Sinal da vazão obtido pela predição de 12 passos.....   | 74 |
| Figura 6.32. Sinal erro de predição para a vazão com 12 passos .....   | 74 |

## ÍNDICE DE TABELAS

### **Capítulo V**

|   |    |
|---|----|
| Tabela 5.1 Propriedades do reservatório .....                 | 40 |
| Tabela 5.2 Propriedades da rocha.....                         | 41 |
| Tabela 5.3 Configurações operacionais do modelo base.....     | 41 |
| Tabela 5.4 Níveis dos parâmetros operacionais analisados..... | 42 |

### **Capítulo VI**

|   |    |
|---|----|
| Tabela 6.1. Erros observados no período de treinamento e de predição para uma memória de linha de atraso de ordem 2 ..... | 75 |
| Tabela 6.2. Erros observados no período de treinamento e de predição para uma memória de linha de atraso de ordem 10..... | 75 |
| Tabela 6.3. Erros observados no período de treinamento e de predição de memória de linha de atraso de ordem 2.....        | 76 |
| Tabela 6.4. Erros observados no período de treinamento e de predição de memória de linha de atraso de ordem 10.....       | 76 |

## **Nomenclaturas e abreviações**

CMG - Computer Modelling Group

MLP – MultiLayer Perceptron

NARX – Nonlinear AutoRegressive model with eXogenous input

N<sub>p</sub> - Produção acumulada total de óleo m<sup>3</sup>

P - Pressão KPa

Q – Vazão de injeção m<sup>3</sup>std/dia

B<sub>o</sub> – Fator volume de formação do fluido Adimensional

VR - Volume total da rocha de hidrocarbonetos m<sup>3</sup>

S<sub>w</sub> - Saturação de água %

S<sub>wc</sub> - Saturação de água conata %

SPE – “Society of Petroleum Engineers”

STARS – “Steam, Thermal and Advanced Reservoir Simulator”

t - Tempo de projeto anos

T - Temperatura do fluido °C

VOIP - Volume de Óleo in Place m<sup>3</sup>

∅ – Porosidade %

---

***CAPÍTULO I:***

***Introdução Geral***

---

# 1 Introdução Geral

A engenharia de reservatórios tem apresentado um grande crescimento em temas relacionados à utilização de poços inteligentes. Esse tipo de poço possui um conjunto de equipamentos de instrumentação (sensores, válvulas e dispositivos de controle de fluxo, etc.) instalados ao longo de sua tubulação de produção. Esses equipamentos medem as variáveis de operação do poço (temperatura, pressão, abertura de válvula, etc.), alimentam bancos de dados e são usadas para monitorar, em tempo real, todas as operações do poço.

Essa grande quantidade de dados gerada permite a implementação de estratégias para melhorar a operação dos poços, ter uma noção completa do que está acontecendo quando intervenções são feitas e, principalmente, prever o que se pode acontecer no futuro.

O problema se torna ainda mais complexo quando se estende o conceito de poços inteligentes para campos inteligentes, onde o campo é visto como um sistema de poços injetores e produtores integrados, já que olhar o sistema de forma abrangente aumenta o número de fontes de geração de dados, e o número de aspectos inter-relacionados.

Essa grande quantidade de dados gera um desafio, como também uma oportunidade ímpar na tecnologia de reservatórios. O desafio é pensar como se pode modelar esse tipo de problema adequadamente. Normalmente, para eventos como esse, em que uma seqüência de dados é acompanhada ao longo do tempo, métodos de séries temporais têm sido usados, com êxito, nas mais variadas áreas (Medicina, Economia, Engenharia, Meteorologia, etc.), porém ainda têm sido usadas de forma incipiente na tecnologia de reservatórios.

As redes neurais artificiais se inserem como uma importante técnica de problemas de série temporais e será utilizada como a principal ferramenta deste trabalho.

O objetivo desta dissertação é a validação de modelos preditivos para a obtenção das características de reservatórios de petróleo a partir de dados simulados, utilizando as redes neurais artificiais como técnica para a predição de produção de petróleo. As RNA (Redes Neurais

Artificiais) serão utilizadas por possuírem boas características no que se refere à classificação de padrões e de reconhecimento de padrões, além da sua capacidade de aproximação de funções e interpolação, tornando-as ideais para realizar tarefas de predição.

A finalidade deste trabalho não é substituir as ferramentas e métodos clássicos de estimar características dos reservatórios, que serão abordados no capítulo 2. A pretensão fica por conta de se buscar novas técnicas que podem apresentar vantagens em situações que os métodos clássicos (em especial a simulação) consomem mais tempo e recursos computacionais. Outro ponto importante é a oportunidade de se usar dados que agora estão disponíveis com a implantação de poços inteligentes.

A dissertação está organizada em sete capítulos. O primeiro capítulo apresenta comentários iniciais, descreve o embasamento teórico ao longo da história que serviu como fundamento para a construção desse trabalho e discute a utilização das redes neurais artificiais como uma ferramenta extra na resolução de um vasto número de problemas de Engenharia de Petróleo.

No capítulo II, Reservatórios e Campos Inteligentes, são apresentadas algumas considerações relacionadas à Engenharia de Reservatórios, seus campos de atuação e seus principais temas de estudo. Aborda os métodos de se estimar os volumes originais de hidrocarbonetos e de reservas em uma jazida de petróleo, explica os conceitos de completação inteligente, poços inteligentes e como se chegou a um conceito mais amplo de campos inteligentes.

O capítulo III, Predição Inteligente e Redes Neurais Artificiais, apresenta uma visão geral dos métodos de predição e das redes neurais artificiais, citando o seu princípio de funcionamento, a arquitetura de Perceptrons de Múltiplas Camadas, as Redes Neurais Recorrentes e o algoritmo de treinamento supervisionado Levenberg-Marquardt para redes recorrentes.

O capítulo IV apresenta o Estado da Arte relacionado à Predição de Produção de Petróleo e Poços, Campos e Completação Inteligente.

No capítulo V a Modelagem do Processo é descrita, em que são expostas as ferramentas computacionais utilizadas relacionadas à simulação de reservatórios e à inteligência artificial, da formulação do problema estudado, além da metodologia utilizada.

O capítulo VI apresenta os resultados obtidos e suas discussões, a partir do que foi obtido na simulação do processo.

O capítulo VII aponta de forma objetiva as conclusões a partir dos resultados obtidos e propõe algumas recomendações para trabalhos futuros.

E finalmente são apresentadas as referências (artigos, livros, teses, programas, sites) utilizadas como base para esta dissertação.

---

***CAPÍTULO II:***  
***Reservatórios e Campos Inteligentes***

---

## **2 Reservatórios e Campos Inteligentes**

Neste capítulo estão apresentados alguns conceitos essenciais da Engenharia de Reservatórios e da Completação Inteligente para a compreensão do trabalho.

### **2.1 Considerações sobre Engenharia de Reservatórios**

A engenharia de reservatórios busca retirar os fluidos do interior das rochas e levá-los à superfície de forma segura e a custos otimizados. Para isso, estuda a caracterização das jazidas, as propriedades das rochas, as propriedades dos fluidos nelas contidos, a maneira como estes fluidos interagem dentro da rocha e as leis físicas que regem o movimento dos fluidos no seu interior, tudo isso para maximizar a produção de hidrocarbonetos e minimizar os custos (Thomas et al., 2001,).

#### **2.1.1 Volume Original de Hidrocarbonetos**

A tarefa de estimar as reservas de óleo e/ou gás natural existentes em uma jazida petrolífera é extremamente importante para se determinar se seu tamanho viabiliza sua exploração econômica. Outro ponto importante na engenharia de reservatório é não haver uma maneira única de se estimar os volumes originais de hidrocarbonetos e de reservas em uma jazida de petróleo. Dependendo das circunstâncias, essas informações podem ser calculadas de maneiras bastante diversas, dependendo, entre outros fatores, da época em que é feito o estudo e da quantidade de informações que se tem a respeito da jazida (Thomas et al., 2001,). Os métodos utilizados são destacados a seguir:

##### **2.1.1.1 Analogia**

Este é um tipo de procedimento utilizado em uma época que precede à perfuração do primeiro poço a penetrar na jazida, ou seja, do poço descobridor. Nessa época as informações a respeito do reservatório são praticamente inexistentes. Tem-se uma série de evidências e, entretanto, ainda não se tem a comprovação da existência de uma acumulação de petróleo na

região que está sendo pesquisada. As estimativas são feitas a partir de dados e resultados de reservatórios localizados nas proximidades, os quais se acredita que tenham características semelhantes às do reservatório que está sendo estudado. É evidente que esse tipo de estimativa está sujeito a erros, uma vez que o estudo não se baseia em dados reais do reservatório (Rosa et al., 2005,).

### **2.1.1.2 Análise de Risco**

Como o método anterior, a *análise de risco* também é um processo utilizado antes da perfuração do poço descobridor. Da mesma forma, a estimativa é feita a partir de resultados de reservatórios cujas características são semelhantes às do reservatório em estudo e que se localizam nas suas proximidades. A diferença entre os dois processos reside no fato de que na análise de risco existe uma certa sofisticação no tratamento estatístico dos dados e os resultados são apresentados, não como um valor único, mas como uma faixa de resultados possíveis (Rosa et al., 2005,).

### **2.1.1.3 Método Volumétrico**

Este é um método para cálculo do volume original que pode ser usado tanto para reservatório de líquido quanto para reservatório de gás. O método se baseia na determinação volumétrica da quantidade total de hidrocarbonetos originalmente existente no reservatório. Para o cálculo do volume original são necessárias as seguintes informações:

VR – volume total da rocha de hidrocarbonetos obtida por meio de sísmica de reflexão;

$\phi$  - porosidade média da rocha obtida por interpretação de perfis ou em ensaios de laboratório;

$S_w$  – saturação do fluido obtido por interpretação de perfis ou em ensaios de laboratório;

$B_o$  – Fator volume de formação do fluido obtido por meio de análise feita em laboratório.

Serve para a conversão do volume do óleo no reservatório para as condições de superfície.

O volume original é então calculado pela expressão (Thomas et al., 2001,):

$$N = \frac{V_R \phi (1 - S_w)}{B_o} \quad (2.1)$$

## **2.1.2 Desempenho do Reservatório**

Além de se estimar o tamanho das reservas petrolíferas, uma outra componente de engenharia econômica deve ser levada em conta para um retorno adequado dos investimentos a serem feitos ao longo da vida útil do campo. A escolha de um projeto de desenvolvimento de acordo com as características do campo a ser explorado pode ser fundamental para a exploração do campo de forma lucrativa. Para isso, métodos de previsão de comportamento futuro de reservatórios são utilizados e auxiliam o engenheiro na escolha do projeto a ser implantado e no gerenciamento do campo. Para tanto é necessário que o reservatório já tenha um histórico de produção. Em alguns casos também são necessárias informações sobre o mecanismo de produção do reservatório.

A análise do declínio de produção, a utilização da equação de balanço de materiais para a previsão de comportamento e a simulação numérica de reservatórios são métodos que se inserem no grupo denominado *desempenho do reservatório*. A utilização de um ou outro método depende de fatores tais como a quantidade e o tipo de dados da rocha e fluidos disponíveis, a existência de recursos de informática (software e hardware), entre outros. Esses métodos são descritos a seguir.

### **2.1.2.1 Análise de Declínio de Produção**

Esse método se baseia apenas na observação do comportamento das vazões de produção ao longo do tempo. O declínio gradual da pressão do reservatório, decorrente da produção de fluidos, acarreta também um gradual declínio nas vazões de produção dos poços. A partir da análise do histórico de produção pode-se caracterizar a tendência de declínio da vazão. A partir da extrapolação dessa tendência passada, estima-se o comportamento futuro da produção (Thomas et al., 2001,).

A análise de curvas de declínio é um método simplificado e bastante usado na prática para a realização de ajuste de histórico e/ou previsão do comportamento de poços isolados, de reservatórios ou mesmo de campos de óleo (Rosa et al., 2005,). Esse método é particularmente útil nas seguintes situações:

- realização de estudos preliminares ou de rotina, pois sua aplicação demanda menos tempo que outros métodos;

- realização de ajuste de histórico quando não há dados suficientes para a utilização de outros métodos analíticos;

- estimativa de comportamento (produção e recuperação) quando há pouco ou nenhum histórico de produção, embora muitas vezes seja empregado também quando está disponível um histórico razoável do comportamento do poço, reservatório ou campo.

A taxa de declínio de produção de um poço, reservatório ou campo produtor de óleo é definida como (Rosa et al., 2005.):

$$a = -\frac{1}{q} \frac{dq}{dt} \quad (2.2)$$

onde  $q$  é a vazão de produção e  $t$  o tempo. Para a realização de um estudo de previsão do comportamento da vazão, e conseqüentemente da recuperação de óleo, é necessário o conhecimento da taxa de declínio  $a$ . O valor de  $a$  deve ser determinado através do estudo de comportamento passado do poço, reservatório ou campo, ou a partir do comportamento de reservatórios semelhantes ao que está sendo estudado. Observações empíricas dos comportamentos de poços e de reservatórios mostraram que, na prática, a taxa de declínio de produção obedece à seguinte relação:

$$a = ai \left( \frac{q}{qi} \right)^n, 0 \leq n \leq 1 \quad (2.3)$$

onde  $ai$  é a taxa de declínio inicial,  $qi$  a vazão inicial e  $n$  uma constante. No caso particular em que  $n=1$  diz-se que o declínio de produção é do tipo harmônico, e a taxa de declínio é dada por:

$$a = ai \left( \frac{q}{qi} \right) \quad (2.4)$$

Como  $ai$  e  $qi$  são constantes e a vazão  $q$  sempre diminui com o tempo, a menos que sejam feitas alterações no sistema, como por exemplo através da realização de operações de

restauração e/ou estimulação nos poços, o declínio harmônico apresenta taxas de declínio  $a$  decrescentes ao longo do tempo. O declínio harmônico é portanto um tipo de declínio extremamente favorável, que dificilmente ocorre na prática, com certas fases da vida produtiva de reservatórios com mecanismo de acentuado influxo de água. No outro extremo dos valores de  $n$ , ou seja, quando  $n=0$ , tem-se um declínio a taxas constantes, também chamado de declínio exponencial. Neste caso:

$$a = ai \tag{2.5}$$

Este é um caso bastante desfavorável, já que a taxa de declínio permanece constante e igual à inicial. Normalmente ocorre em reservatórios ou poços que produzem sob o mecanismo de gás em solução, ou no final da vida produtiva de reservatórios com outros mecanismos de produção. Reservatórios com este tipo de declínio em geral apresentam baixas recuperações finais.

Finalmente, se  $0 \leq n \leq 1$ , o declínio é chamado de hiperbólico. Acredita-se que este tipo de declínio ocorra na maioria dos reservatórios reais (Rosa et al., 2005,).

### **2.1.2.2 Equação de Balanço de Materiais**

As equações de balanço de materiais são relações que associam o balanço de massa dos fluidos do reservatório com as reduções de pressão no interior do mesmo. A equação de balanço de materiais é a representação matemática da seguinte expressão: “A um tempo qualquer da vida produtiva do reservatório, a soma das massas dos fluidos existentes no reservatório com a massa dos fluidos produzidos até então é igual à massa de fluidos originalmente existente nesse meio poroso” (Thomas et al., 2001,).

Essas equações são escritas em termos das propriedades da rocha e do comportamento do fluido em função da pressão, das propriedades rocha-fluido e do histórico de produção, e são particularizadas para cada caso, dependendo dos mecanismos de produção atuantes no reservatório.

Para se fazer a previsão procura-se escrever a equação de balanço de materiais de uma maneira que o comportamento passado do reservatório esteja representado, ou seja, a equação deve relacionar a produção acumulada com a queda de pressão observada. Ao se encontrar essa equação, admite-se que ela também seja capaz de descrever o comportamento futuro do reservatório. Com essa equação estima-se que produção de fluidos corresponderá à queda de pressão que ocorrerá no reservatório.

Como a equação de balanço de materiais fornece apenas relações entre a produção acumulada de fluido e a queda de pressão, são necessárias outras equações que relacionem as produções acumuladas com vazões de produção e tempos.

As principais utilizações da equação de balanço de materiais são:

- determinação do volume original de gás e óleo;
- determinação do influxo de água proveniente de aquíferos;
- previsão do comportamento de reservatórios.

### **2.1.2.3 Simulação Numérica de Reservatórios**

O termo simulação numérica de reservatórios se aplica à utilização de simuladores numéricos e computacionais em estudos de reservatórios.

Os procedimentos utilizados para se fazer previsões do comportamento futuro são semelhantes aos utilizados na equação de balanço de materiais. São introduzidos no modelo as informações geológicas e geofísicas, os dados de rocha, os dados de fluido, as propriedades rocha-fluido, etc., de maneira que este reproduza, com uma certa precisão, o histórico de produção. Quando o modelo passa a descrever o passado de maneira satisfatória, está pronto para ser utilizado na previsão do comportamento futuro (Thomas et al., 2001,).

A diferença básica entre os dois processos está na maneira como é tratado o reservatório. Enquanto que no balanço de materiais se usa uma única equação descrevendo o reservatório como se fosse um único bloco com propriedades uniformes, a simulação matemática permite a

---

subdivisão em células com propriedades diferentes, e envolve a solução simultânea de um grande número de equações que representam o fluxo no meio poroso. Outra diferença significativa é que, diferentemente da equação de balanço de materiais, a simulação fornece os seus resultados em função do tempo.

Os simuladores numéricos permitem bons resultados nos estudos dos reservatórios e estes vão ficando cada vez melhores a cada refinamento do modelo, onde novos e melhores dados da rocha, dos fluidos, da geologia, do histórico de produção vão tornando o modelo cada vez mais próximo das características do reservatório.

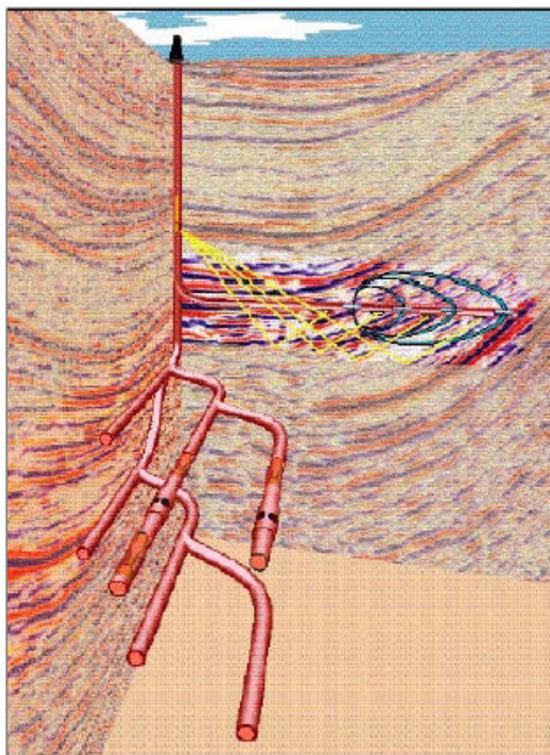
## **2.2    Completação Inteligente**

Nos tópicos anteriores, analisou-se sucintamente os métodos que são usados para se estimar os volumes originais de hidrocarbonetos e de reservas em uma jazida. Entretanto, uma outra atividade importante na engenharia de reservatório está relacionada à tarefa de gerenciamento da exploração desses campos de petróleo. Nesta tarefa, o profissional comanda intervenções nos poços com operações de isolamento de intervalos produtores, abertura de novos intervalos, acidificações, fraturamentos, testes de formação para coleta de dados, e tantas outras operações de restauração para otimizar a produção. Porém, estas operações com intervenções nos poços estão sempre associadas a altos custos, em especial quando se trata de campos *offshore* com completação molhada, tornando inviável algumas dessas operações e acarretando um gerenciamento não otimizado.

Para solucionar este problema surge o conceito de poços com completação inteligente que se propõe a diminuir custos nas operações de restauração mais frequentes que são o isolamento e a abertura de novos intervalos produtores, e, além disso, permitir um monitoramento em tempo real dos dados de produção (vazões, pressões e temperaturas), resultando assim, em melhor gerenciamento do campo. Outro conceito importante que surge é o de campos inteligentes onde são instalados vários poços inteligentes implicando que se trate o reservatório como um grande sistema, onde os dados coletados em tempo real podem ser usados para otimizar as operações de produção.

### **2.2.1 Poços com Completação Inteligente**

Mais detalhadamente, um poço inteligente, segundo (Yeten; Durlofsky; Aziz, 2002), é um poço não convencional que possui equipamentos de instrumentação (sensores, válvulas e dispositivos de controle de fluxo) instalados ao longo de sua tubulação de produção. Tais poços permitem a monitoração *in-situ* contínua das taxas de pressão e de fluxo de fluidos e do ajuste periódico das válvulas do poço. Essa tecnologia fornece uma grande flexibilidade na operação de poços multilaterais (Figura 2.1) porque cada ramificação do poço pode ser controlada independentemente. No caso de poços convencionais, onde há apenas um furo (monobore – horizontal ou com desvio), a instrumentação o transforma essencialmente em um poço multi-segmentado com a capacidade de controlar cada segmento de forma independente. Na Figura 2.2 é mostrado um esquema típico de um poço inteligente.



**Figura 2.1 Representação artística de um poço multilateral**

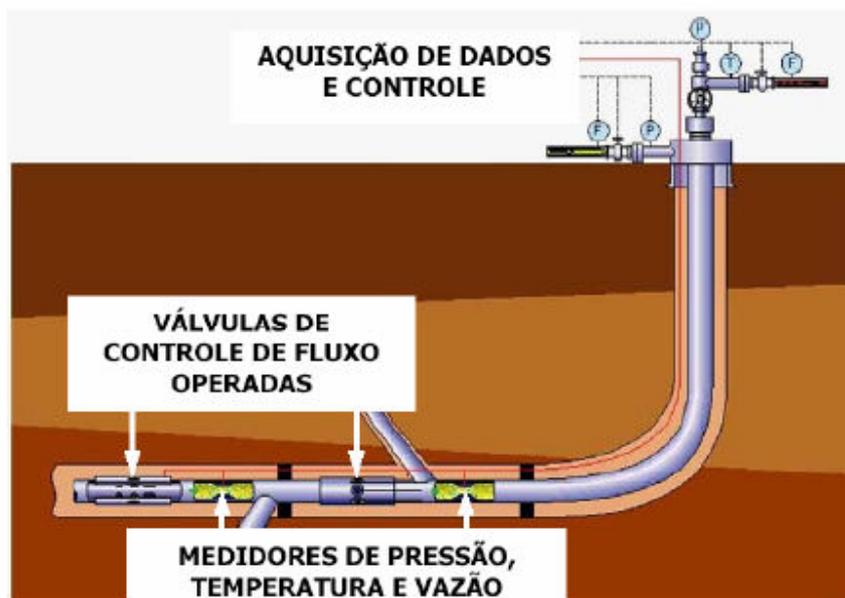


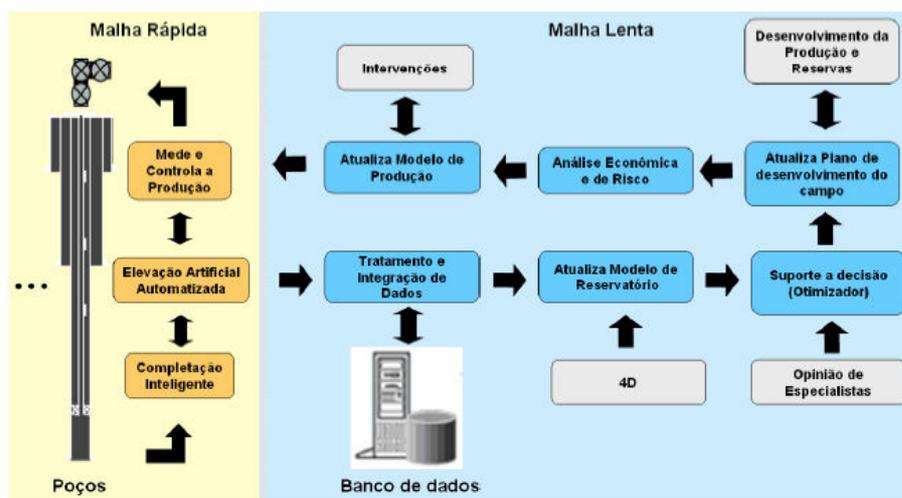
Figura 2.2 Esquema típico de poço com completação inteligente

### 2.2.2 Campo Inteligente

A definição de Campo Inteligente, segundo (Silva Jr et al., 2005,), é um processo de gerenciamento de produção usando conhecimentos de especialistas, monitoramento em tempo real e controle de otimização de fluxo com o intuito de se aumentar a produção, aumentar as reservas, diminuir custos e conseqüentemente adicionar valor aos recursos disponíveis pela companhia.

Este gerenciamento pode ser usado tanto em atividades e operações de malha rápida relacionadas a operações de poço e elevação artificial, monitorando e controlando suas variáveis de produção, quanto em operações e atividades relacionadas à malha lenta permitindo atualizações nos modelos de produção, de análise econômica e de risco e no plano de desenvolvimento do campo.

O diagrama de fluxo apresentado na Figura 2.3, retirado de (Silva Jr et al., 2005,), leva em consideração todos os principais processos de produção: reservatório, engenharia de poços, elevação artificial, garantia de fluxo, facilidades de produção e operação e integração a processos novos.



**Figura 2.3 Modelo de fluxo de campo inteligente**

Baseado na estratégia da empresa e em seus estudos de retorno do investimento para cada conjunto de equipamentos e suas instalações, e também em termos de facilidades operacionais e redução de custos, pode-se, segundo (Silva Jr et al., 2005,), classificar os recursos relacionados a campos inteligentes em quatro níveis de inteligência, onde o nível 1 seria o nível “mais inteligente”:

Nível 4 – Automação de superfície e facilidades de produção.

Nível 3 – Automação de superfície, facilidades de produção e de poços.

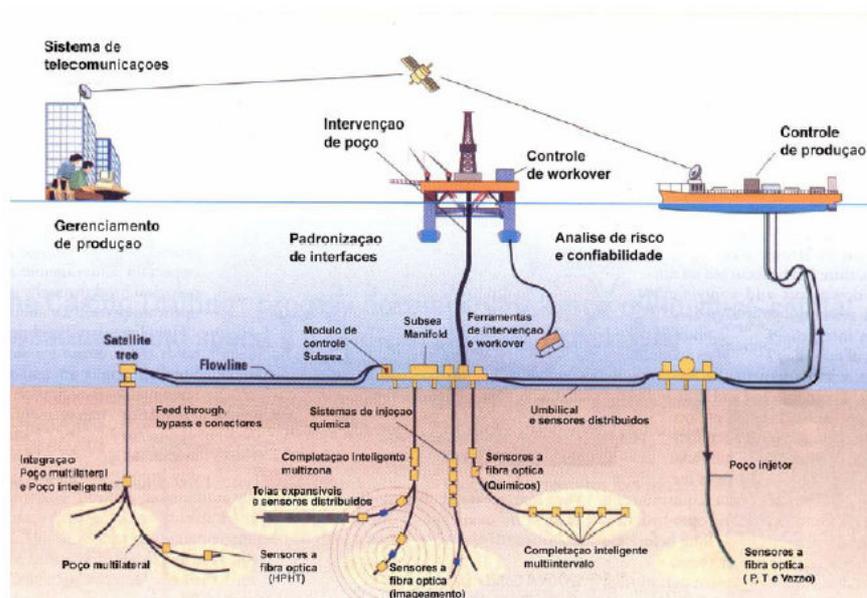
Nível 2 – Automação de superfície, facilidades de produção e de poços, e monitoramento de subsuperfície.

Nível 1 – Automação de superfície, facilidades de produção e de poços, e monitoramento e controle de subsuperfície.

Esses níveis de complexidade e de investimentos permitem a empresa avaliar para cada campo a melhor opção com relação às técnicas empregadas e às variáveis financeiras.

Quanto às possibilidades em relação ao futuro deste conceito de campo inteligentes, já se acredita que essa tecnologia irá permitir o gerenciamento integrado da produção de reservatórios

observando-se variáveis mercadológicas. Na Figura 2.4 é apresentado um esquema em que um campo inteligente funcionaria acoplado a sistemas de monitoração e controle remoto permitindo que todas as operações de produção do campo sejam otimizadas em função da oferta e demanda de petróleo no mercado.



**Figura 2.4** Esquema de campo inteligente que pode surgir em um futuro próximo

Como se pode observar, esta figura dá uma idéia geral do potencial dos campos inteligentes, disponibilizando vantagens em Tecnologia de Engenharia de Produção, Tecnologia de Engenharia de Poços e Tecnologia de Reservatórios, a saber:

**Tecnologia de Engenharia de Produção** – Há vantagens relativas à interligação do fluxo das informações (malha rápida) que são tratadas e direcionadas a um centro de operações para que os responsáveis pela gestão e análise da produção tenham acesso à monitoração, em tempo real, dos parâmetros de produção, de superfície e de subsuperfície. Outra aplicação já idealizada tem relação a equipamentos de superfície em poços terrestres. Neste caso, cartas de bombeio de fundo são comparadas a cartas de bombeio padrões pré-estabelecidas. Esse monitoramento permitiria mudanças no regime de funcionamento da unidade de bombeio mecânico quando percebesse mudanças de padrão de funcionamento normal para outra classe de funcionamento.

**Tecnologia de Engenharia de Poços** – Facilitaria a operação com a monitoração de variáveis de fundo de poço e através do controle remoto de válvulas de subsuperfície.

**Tecnologia de Engenharia de Reservatórios** – Na otimização da injeção de água em relação a um campo convencional, retardando ao máximo a produção de água. Na caracterização dos reservatórios, atualizando os dados de simulação (malha lenta). Neste caso, as informações de pressão, vazão e temperatura dos sensores de fundo servem como uma realimentação de informações, possibilitando um constante ajuste do modelo geológico do reservatório. Com isso, pode-se atualizar o modelo de exploração e se fazer uma nova análise econômica e de risco.

Em uma recuperação secundária, permitiria um melhor controle das válvulas de produção e injeção garantindo uma melhor exploração do campo e um maior controle na relação água/óleo nos poços de produção.

Outra vantagem é quando há uma incerteza quanto ao modelo estrutural do campo, ou seja, deseja-se saber se há interligações entre várias camadas produtoras. A presença de válvulas nas várias camadas permite que testes (de interferência) sejam feitos abrindo-se apenas uma válvula injetora de cada vez para saber a que intervalos de produção ela se relaciona. Em certos casos, o modelo estrutural é bem diferente do original, mas este conhecimento permite gerar um novo modelo do reservatório e uma nova avaliação do impacto econômico no empreendimento com relação ao gerenciamento do reservatório.

---

***CAPÍTULO III:***

***Predição Inteligente e Redes Neurais Artificiais***

---

## **3 Predição Inteligente e Redes Neurais Artificiais**

Alguns conceitos essenciais da Predição Inteligente e das Redes Neurais Artificiais estão apresentados neste capítulo para o entendimento do trabalho.

### **3.1 Redes Neurais Artificiais**

Uma rede neural é um processador paralelamente distribuído constituído de unidade de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso (Haykin, 2001). Sua modelagem é inspirada no funcionamento nos neurônios biológicos e assemelha-se ao cérebro em dois aspectos:

- O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
- Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Outras características importantes das RNAs:

- São modelos adaptativos fáceis de treinar;
- Podem representar domínios complexos (não lineares);
- São capazes de generalização diante de informações incompletas;
- São algoritmos robustos e vastamente utilizados;
- São capazes de fazer armazenamentos associativos de informações.

O modelo de um neurônio artificial, conhecido como o modelo de McCulloch-Pitts (Haykin, 2001), pode ser visto na Figura 3.1 onde se observam os seguintes elementos:

- Pesos sinápticos: correspondem às forças de ligação entre os neurônios da rede e são representados por  $w_{kj}$ , onde  $k$  corresponde ao neurônio e  $j$  a uma de suas entradas.
- Combinador Linear: realiza o somatório das entradas do neurônio ponderadas pelos pesos sinápticos correspondentes, gerando o campo local induzido,  $v_k$ .
- Função de Ativação: limita o campo local induzido entre 0 e 1 ou -1 e 1 para assegurar que sua amplitude tenha um valor finito. Pode ser linear ou não-linear.

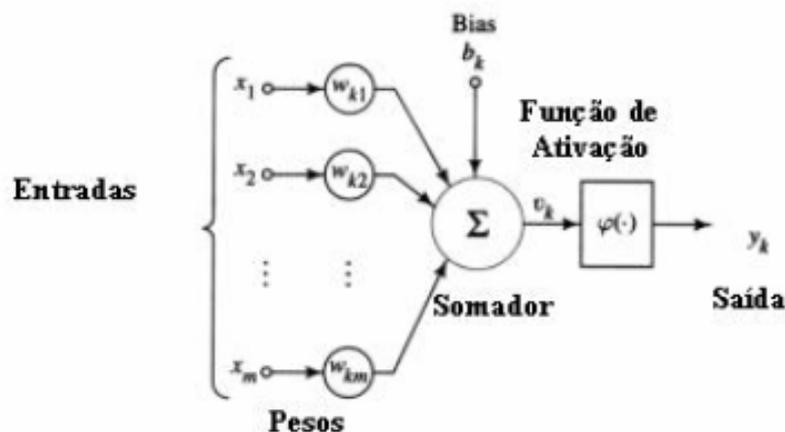


Figura 3.1. Modelo matemático de um neurônio artificial

A partir da estrutura acima pode-se formular um modelo matemático do neurônio artificial descrito pelas equações 3.1 e 3.2:

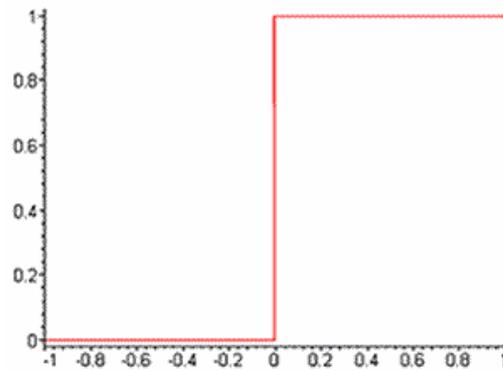
$$v_k = \sum_{j=1}^m w_{kj} x_j \quad (3.1)$$

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

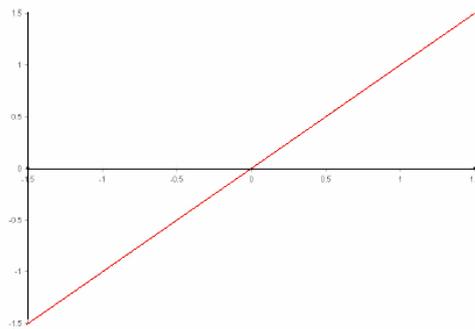
onde  $x_1, x_2, \dots, x_m$  representam os sinais de entrada,  $w_{kj}$  corresponde a cada peso sináptico,  $v_k$  é o campo local induzido ou potencial de ativação  $v_k$  do neurônio  $k$ , e  $y_k$  é a saída do neurônio. O termo  $b_k$  corresponde ao bias, aplicado externamente e tem o efeito de aumentar ou diminuir a entrada da função de ativação.

A função  $\varphi(\cdot)$  corresponde à função de ativação. Costumam ser implementados quatro tipos básicos de funções de ativação que podem ser: degrau, linear, sigmóide ou tangente

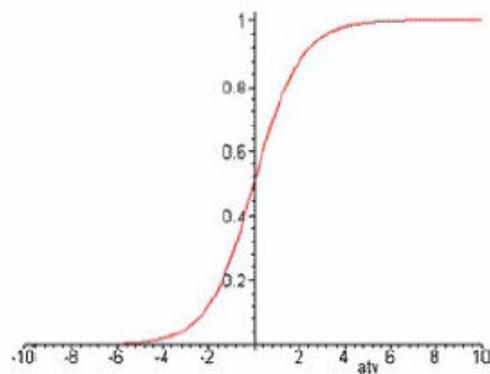
hiperbólica. As Figuras 3.2, 3.3 e 3.4 ilustram alguns exemplos de função degrau, linear e sigmóide, respectivamente.



**Figura 3.2. Função de ativação degrau**



**Figura 3.3. Função de ativação linear**



**Figura 3.4. Função de ativação sigmóide**

A maneira pela qual os neurônios de uma rede neural estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede. Pode-se classificar os algoritmos de treinamento de acordo com o paradigma de aprendizagem abordado. Sob este ponto de vista o processo de treinamento pode ser supervisionado ou não-supervisionado.

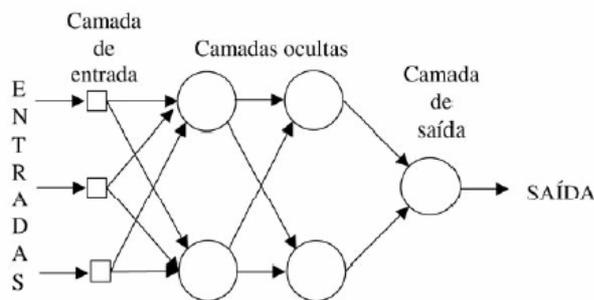
O treinamento supervisionado é caracterizado pela presença de um professor. O conhecimento se encontra na forma de conjuntos de exemplos de entrada-saída e é através deles que o professor consegue treinar a rede neural, alterando os pesos sinápticos e diminuindo o erro de saída. Uma das arquiteturas de rede neural mais utilizada é a rede Perceptron de Múltiplas Camadas, ou *Multilayer Perceptron* (MLP), na qual os neurônios são organizados em camadas e conectados entre si.

Na aprendizagem não-supervisionada, não há um professor externo para supervisionar o processo de aprendizado. A rede neural extrai informações somente dos padrões de entrada sem a necessidade de uma resposta desejada.

### **3.1.1 Perceptron de Múltiplas Camadas**

Como ilustra a Figura 3.5, uma 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. 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.

As redes MLP podem ser divididas em duas categorias: as redes alimentadas adiante, ou redes *feedforward*, e as redes recorrentes, ou recursivas.



**Figura 3.5. Rede Neural feedforward**

As redes *feedforward* são aquelas cuja informação é propagada a partir da camada de entrada, passando pelas camadas ocultas, até a camada de saída sem a realimentação da informação, ou seja, as saídas de cada camada são conectadas somente às entradas da camada posterior. A Rede Neural *feedforward* é apresentada na Figura 3.5.

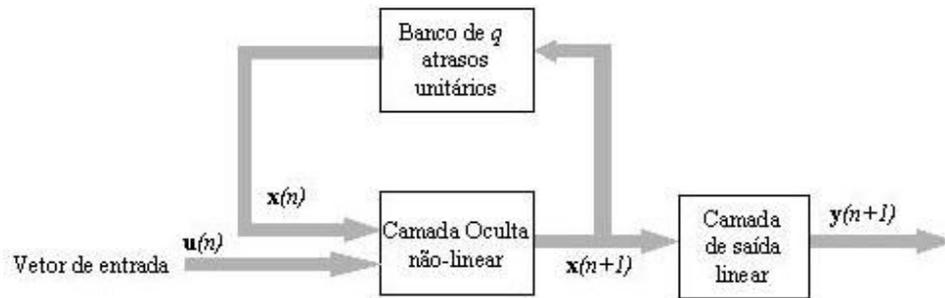
As redes *feedforward* são estáticas e podem não ser capazes de capturar a dinâmica de um sistema. Para capturar a dinâmica de um sistema com mais eficácia, é mais apropriado o uso das redes recorrentes, devido à sua capacidade de agregar memória à rede neural (Principe & Kuo, 1995). As redes com realimentação são objetos de estudo deste trabalho devido a essa característica.

As redes neurais recorrentes possuem conexões de realimentação em sua arquitetura, ou seja, as saídas dos neurônios podem ser alimentadas de volta para suas entradas ou para os neurônios das camadas anteriores.

Estas são facilmente adaptadas a partir das redes *feedforward* bastando introduzir conexões de realimentação em suas camadas. O uso de realimentação com atrasos introduz memória à rede tornando-a apropriada para predição.

A realimentação em redes recorrentes pode ser tanto local como global. No caso local, as saídas das camadas ocultas são realimentadas entre si enquanto que no caso global a resposta da camada de saída é inserida na camada de entrada. De acordo com o tipo de realimentação podemos distinguir arquiteturas diferentes das redes recorrentes.

Uma propriedade importante de uma rede recorrente é que ela pode ser descrita pelo modelo de espaço de estados e pode aproximar uma ampla classe de sistemas dinâmicos não-lineares (Haykin, 2001).



**Figura 3.6. Modelo de espaço de estados**

A noção de estado desempenha um papel vital na formulação matemática de um sistema dinâmico. O estado de um sistema dinâmico é formalmente definido como um conjunto de quantidades que resume toda a informação sobre o comportamento passado que é necessária para descrever unicamente o seu comportamento futuro, exceto pelos efeitos puramente externos que surgem devido à entrada aplicada. Em termos matemáticos, o comportamento dinâmico do sistema ilustrado pela rede recorrente da Figura 3.6, assumindo livre do ruído, é descrito pelo seguinte par de equações não-lineares:

$$\mathbf{x}(n+1) = \varphi(\mathbf{W}_a \mathbf{x}(n) + \mathbf{W}_b \mathbf{u}(n)) \quad (3.3)$$

$$\mathbf{y}(n) = \mathbf{C} \mathbf{x}(n) \quad (3.4)$$

onde  $\mathbf{x}(n)$  é um vetor  $q$ -por-1 representando o estado do sistema,  $\mathbf{u}(n)$  é um vetor  $m$ -por-1, correspondente às entradas aplicadas ao sistema, e  $\mathbf{y}(n)$  é um vetor  $p$ -por-1 que representa a saída. A função  $\varphi(\cdot)$  é a função de ativação linear. A dimensionalidade do espaço de estados, ou seja,  $q$ , é a ordem do sistema e, assim, o modelo de espaço de estados da Figura 3.6 é um modelo recorrente de ordem  $q$ , com  $m$  entradas e  $p$  saídas.

A matriz  $\mathbf{W}_a$ , de dimensão  $q$ -por- $q$ , representa os pesos sinápticos dos  $q$  neurônios na camada oculta que estão conectados aos nós de realimentação na camada de entrada. A matriz  $\mathbf{W}_b$  é uma matriz  $q$ -por- $(m+1)$  que representa os pesos sinápticos destes neurônios ocultos que estão conectados aos nós fontes na camada de entrada. Assume-se que os termos de bias para os neurônios ocultos estão incorporados na matriz de pesos  $\mathbf{W}_b$ . A matriz  $\mathbf{C}$  representa os pesos sinápticos dos  $p$  neurônios lineares na camada de saída que estão conectados aos neurônios ocultos e tem dimensão  $p$ -por- $q$ . Assume-se que os termos de bias para os neurônios de saída estão incorporados na matriz de pesos  $\mathbf{C}$ .

### 3.1.2 Predição de Séries Temporais com Redes MLP

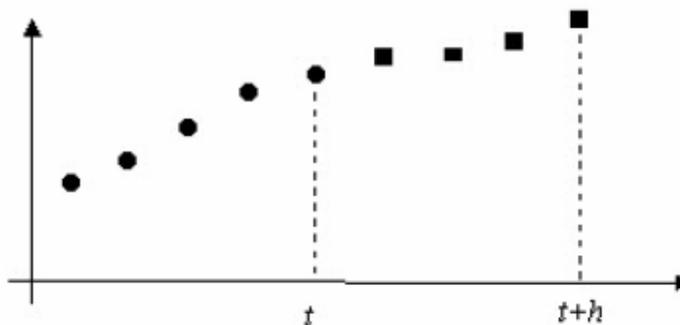
A predição, por ser um tema bastante importante, tem gerado interesse para muitos estudos e, conseqüentemente, o aparecimento de muitas técnicas e métodos. As séries temporais são um método de predição em que uma seqüência de dados ordenados no tempo consiste nas saídas geradas por um determinado sistema o qual se deseja analisar. Esse método pode ser aplicado quando ocorrem as seguintes premissas:

- Existem informações sobre o passado;
- Essa informação pode ser quantificada;
- Pode-se assumir que alguns aspectos do padrão passado se repetirão no futuro.

Os modelos de séries temporais tratam o sistema como uma caixa preta e não se importam com os fatores que afetam o seu comportamento. Dessa maneira, a predição de valores futuros é baseada nos valores passados e/ou erros passados. O termo previsão também é utilizado com este conceito e ambos serão utilizados no decorrer do desenvolvimento desta proposta.

Obtendo-se um conjunto de observações de uma série temporal até um determinado instante de tempo  $t$  e um modelo capaz de representar o mecanismo gerador destas informações, a previsão do valor da série no tempo  $t + h$  pode ser obtida, como ilustra a Figura 3.7.

A previsão de valores futuros de uma série temporal é utilizada, principalmente, nas áreas de economia, controle e otimização de processos industriais, planejamento comercial, entre outros.



**Figura 3.7. Predição h passos à frente**

De acordo com o horizonte de predição desejado, podem existir duas maneiras de se prognosticar os valores futuros de uma série temporal (Mueller, 1996):

- Previsão de Passo Simples: a previsão é realizada para um período de tempo imediatamente posterior ao atual, a partir de observações passadas da série. Considera-se um horizonte de curto prazo.

- Previsão de Passos Múltiplos: adotada para horizontes de médio e longo prazo.

Na previsão múltiplos passos, o conjunto de valores correntes é empregado na realização da previsão para determinado instante; esta previsão é, então, introduzida entre as observações passadas, compondo, desta forma, um novo conjunto de dados, sobre o qual será obtida a previsão do tempo subsequente.

Idealmente, a realização de previsões seria feita a partir do conhecimento das equações que modelam os mecanismos responsáveis pela geração das séries. No entanto, em muitas situações reais, não é possível obter as informações necessárias para a construção destas equações. Nestes casos, utiliza-se um modelo que possa se aproximar do sistema responsável pela

geração da série de tempo observada e, a partir desse modelo, predizer os valores futuros da mesma.

A predição realizada através de um modelo é baseada na extrapolação de características de observações passadas e do inter-relacionamento entre elas, levando em consideração que tais observações contêm todas as informações sobre o padrão de comportamento da série temporal e que o comportamento desta série, no futuro, é similar ao passado.

A predição de séries temporais vem sendo realizada com o uso dos tradicionais modelos Auto-Regressivos e/ou Médias Móveis (AR, MA e ARMA) e modelos Auto-Regressivos Integrados de Médias Móveis (ARIMA). Trata-se de modelos paramétricos através dos quais a previsão das futuras observações é obtida a partir da combinação linear de valores passados e, quando for o caso, com as componentes de ruído da série de interesse ponderadas por um conjunto de parâmetros.

A partir do final da década de 1980 as redes neurais começaram a ser consideradas para realizar atividades de predição de séries temporais. Devido à sua capacidade de agregar conhecimento em sua estrutura, a partir de exemplos, um preditor baseado em rede neural tem condições de estimar o comportamento futuro de uma série temporal apenas a partir de suas amostras passadas. Um modelo de predição deste tipo é chamado de não-paramétrico, uma vez que não há a necessidade de se conhecer os parâmetros do processo que gera o sinal. O modelo do processo é estimado através de um algoritmo de aprendizagem onde os exemplos são apresentados à rede neural e seus pesos são atualizados de acordo com o erro de predição.

Além da capacidade de aprendizagem, as redes neurais têm capacidade de lidar com sistemas cujas séries temporais apresentam maiores dificuldades para a predição, como não-linearidades e ruídos. Os modelos estatísticos tradicionais são lineares e não são capazes de lidar com a natureza não-linear e a não-estacionaridade de certos sinais. Já as redes neurais têm condições de realizar um mapeamento entrada-saída não linear devido às funções de ativação.

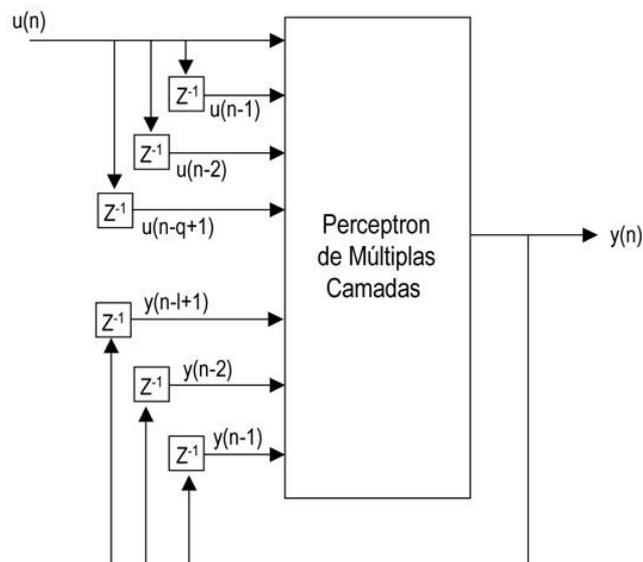
Um exemplo típico de rede neural aplicada à predição consiste de uma rede treinada a partir de janelas de tempo. A entrada da rede consiste em uma memória com a observação atual e

as passadas do sinal, e a saída desejada para esta entrada é a observação obtida no próximo passo de tempo.

O modelo que será pesquisado neste trabalho é o modelo de rede NARX, que nada mais é do que uma rede MLP cuja entrada consiste da própria saída realimentada com atrasos no tempo e uma entrada exógena, também com atrasos. Nesta arquitetura, as saídas estimadas da rede são introduzidas novamente às entradas, permitindo implementar a predição de passos múltiplos (Principe & Kuo 1995). Esta rede neural é um equivalente do modelo estatístico NARX (Nonlinear AutoRegressive model with eXogenous input), que realiza o seguinte mapeamento entrada-saída:

$$y(n) = g(y(n-1), \dots, y(n-l+1), u(n), \dots, u(n-q+1)) \quad (3.5)$$

onde  $u(n)$  e  $y(n)$  correspondem à entrada e saída da rede no tempo  $t$  e  $l$  e  $q$  são, respectivamente, as ordens da saída e da entrada. A função  $g(\cdot)$  é uma função não-linear geralmente desconhecida que pode ser aproximada, justamente, por ter uma rede MLP resultando na topologia apresentada na Figura 3.8.



**Figura 3.8. Rede NARX**

O modelo tem uma única entrada que é aplicada a uma memória de linha de atraso derivada com  $q$  unidades e também uma única saída que é realimentada para a entrada através de uma outra memória de linha de atraso derivada, também, com  $q$  unidades. Os conteúdos destas duas memórias são utilizados para alimentar a camada de entrada de um perceptron de múltiplas camadas. O valor presente da entrada do modelo é representado por  $u(n)$ , e o valor correspondente da saída do modelo é representado por  $y(n)$ .

Em (Haykin, 2001) mostra-se que o modelo NARX, representado pela Figura 3.8, com sua realimentação limitada ao neurônio de saída, é capaz de simular o modelo de espaço de estados das equações 3.3 e 3.4 (assumindo que  $m = 1$  e  $p = 1$ ), representado na Figura 3.6, sem nenhuma diferença entre os seus componentes de entrada-saída.

### 3.1.3 O Algoritmo de Levenberg-Marquardt

O algoritmo de aprendizagem utilizado neste trabalho se enquadra no método de treinamento supervisionado, caracterizado pela presença de um professor. O conhecimento se encontra na forma de conjuntos de exemplos de entrada-saída e é através deles que o professor consegue treinar a rede neural, alterando os pesos sinápticos e diminuindo o erro de saída.

Um exemplo típico de rede neural aplicada à predição consiste de uma rede treinada a partir de janelas de tempo. A entrada da rede consiste em uma memória com a observação atual e as passadas do sinal, e a saída desejada para esta entrada é a observação obtida no próximo passo de tempo.

Este trabalho utiliza o método de Levenberg-Marquardt como algoritmo de treinamento supervisionado para redes recorrentes usado na predição não-linear.

O algoritmo de Levenberg-Marquardt é uma técnica iterativa que localiza o valor mínimo de uma função que é expressa como a soma dos quadrados de valores reais de funções não-lineares (Lourakis, 2005). A sua aplicação faz-se necessária em virtude da sua capacidade de acelerar o processo de convergência (Hagan & Menhaj, 1994).

Ele se baseia, para a aceleração do treinamento, na determinação das derivadas de segunda ordem do erro quadrático em relação aos pesos, diferindo do algoritmo backpropagation tradicional que considera as derivadas de primeira ordem (Barbosa et al.,2005,).

O algoritmo de Levenberg-Marquardt se baseia no método de otimização de Newton para sistemas não-lineares, que faz uso da matriz Hessiana  $H$ . No método de Levenberg-Marquadt se faz uma aproximação para essa matriz, mostrada pela equação 3.6, determinada em função da matriz Jacobiana, que contém as primeiras derivadas dos pesos em função dos pesos sinápticos, expressa pela equação 3.7 (Barbosa et al.,2005,):

$$\mathbf{H} = \frac{\partial^2 E_R(\mathbf{W})}{\partial \mathbf{W}^2} \quad (3.6)$$

$$\mathbf{J} = \frac{\partial e(\mathbf{W})}{\partial \mathbf{W}} \quad (3.7)$$

onde  $E_R$  (erro quadrático médio) e  $e(\mathbf{W})$  são definidos conforme as expressões 3.8 e 3.9:

$$E_R = \frac{1}{n} \sum_{i=1}^n (y_i - y_{ei})^2 \quad (3.8)$$

$$e(\mathbf{W}) = \sum_{i=1}^n (y_i - y_{ei}) \quad (3.9)$$

onde  $y_i$  é a saída fornecida pela rede e  $y_{ei}$  é o valor exato correspondente à saída da rede.

A determinação da matriz Jacobiana é muito mais simples que a determinação da matriz Hessiana. Como, para uma rede neural, a performance de treinamento é expressa em função da soma dos erros quadráticos, a matriz Hessiana pode ser expressa pela expressão 3.10:

$$\mathbf{H} = \mathbf{J}^T(\mathbf{W})\mathbf{J}(\mathbf{W}) \quad (3.10)$$

o método de Newton atualiza os pesos segundo a expressão 3.11:

$$\mathbf{W}(k+1) = \mathbf{W}(k) - \mathbf{H}^{-1} \mathbf{g}_k \quad (3.11)$$

onde  $\mathbf{g}_k$  pode ser escrito conforme a equação 3.12:

$$\mathbf{g}_k = 2\mathbf{J}^T(\mathbf{W})\mathbf{e}(\mathbf{W}) \quad (3.12)$$

O algoritmo de Levenberg-Marquadt procede a atualização dos pesos baseado na mesma expressão do método de Newton 3.11, realizando as modificações para a determinação da matriz Hessiana, mostrada pela equação 3.13 (Barbosa et al.,2005,):

$$\mathbf{W}(k+1) = \mathbf{W}(k) - [\mathbf{J}^T(\mathbf{W})\mathbf{J}(\mathbf{W}) + \mu_k \mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{W})\mathbf{e}(\mathbf{W}) \quad (3.13)$$

onde:  $\mathbf{I}$  é a matriz identidade e  $\mu_k$  é a constante do método de Levenberg-Marquardt.

O parâmetro  $\mu_k$  funciona como um fator de estabilização do treinamento, ajustando a aproximação de forma a utilizar a rápida convergência do método de Newton e evitando passos muito grandes que possam levar a um erro de convergência (Hagan & Menhaj, 1994).

Esse método apresenta a convergência em menos iterações, mas requer mais cálculos por iteração devido ao cálculo de matrizes inversas. Apesar do grande esforço computacional, ele segue sendo o algoritmo de treinamento mais rápido para redes neurais, quando se trabalha com um número moderado de parâmetros na rede.

### 3.1.4 Vantagens das Redes Neurais Artificiais

Os modelos estatísticos auto-regressivos levam em consideração uma profunda análise da série temporal de interesse buscando identificar o melhor modelo capaz de representá-lo e estimar seus parâmetros. Este processo pode levar a uma série de iterações com o objetivo de encontrar o modelo que seja mais próximo do real. Pode ser um longo processo envolvendo a derivação,

implementação e refinamento dentre uma série de modelos para que se encontre o mais adequado.

As redes neurais superam esta dificuldade além de apresentar outras vantagens em relação a outros métodos de previsão de séries temporais. Devido à sua capacidade de aprender a partir de exemplos, um preditor baseado em rede neural estima o valor futuro de um sinal apenas a partir de suas amostras passadas. Um modelo de predição deste tipo é chamado de não-paramétrico, uma vez que não há necessidade de se conhecer os parâmetros do processo que gera o sinal. O modelo do processo é estimado através de um algoritmo de aprendizado onde os exemplos são apresentados à rede neural e seus pesos são atualizados de acordo com o erro de saída.

Além da capacidade de aprendizado, as redes neurais têm capacidade de lidar com sistemas cujas séries temporais apresentam maiores dificuldades para a predição, como não-linearidades e ruídos. Os modelos estatísticos tradicionais são lineares e não são capazes de lidar com a natureza não-linear e a não-estacionaridade de certos sinais. Já as redes neurais têm condições de realizar um mapeamento entrada-saída não-linear devido às funções de ativação.

---

***CAPÍTULO IV:***

***Estado da Arte***

---

## 4 Estado da Arte

Atualmente, vários trabalhos envolvendo a modelagem de problemas de engenharia propõem algum tipo de utilização de redes neurais. Na área de petróleo não tem sido diferente. Panda, M., Chopra, A. (1998) sugeriram a resolução da interação entre poços injetores e produtores modelando o problema utilizando redes neurais. Vantagens relativas ao consumo de tempo e de recursos computacionais foram obtidas em relação a métodos convencionais na resolução de problemas de esquemas de injeção e de potencial de adensamento de malha de injeção.

Stundner, M., Al-Thuwaini, J. (2001) tiveram como objeto de estudo o gerenciamento de um reservatório no Oriente Médio e também foi apresentada a otimização da razão injeção-produção por uma rede neural com algoritmo de *backpropagation*. Neste caso, foi concebido um ambiente de gerenciamento do reservatório híbrido, em que ferramentas tradicionais como curva de declínio e de balanço de materiais são usadas em conjunto com ferramentas inovadoras que utilizam técnicas de redes neurais e algoritmos genéticos.

Weiss, W. W., Balch, R. S., Stubbs, B. A. (2002) utilizaram a classificação por lógica fuzzy para escolher as variáveis de entrada de uma rede neural em que estas podem ser treinadas, testadas e usadas para prever a produção de petróleo.

Em 2002, *Johnstone*, S. et al. realizaram um projeto em que tinha como objetivo a integração de um sistema de controle de poços com completação inteligente com um sistema de produção marítimo, dentro das limitações existentes deste último, em campos maduros de produção de petróleo. Antes, práticas desse tipo eram realizadas em campos de produção mais novos.

Yeten, B., Durlofsky, L., Aziz, K. (2002) apresentaram um método geral para otimização de poços de petróleo com dispositivos de controle de fluxo. O método implica no uso de uma ferramenta de otimização baseada no algoritmo de gradiente conjugado. Esta ferramenta está vinculada com um simulador de reservatório comercial capaz de modelar os dispositivos de

controle de fluxo. O estudo concluiu que o uso de dispositivos de controle de fluxo otimizados pode aumentar em até 65% o óleo recuperado acumulado em relação a poços sem nenhuma instrumentalização.

Holland, J. et al., (2004) descreveram a experiência da implantação de um sistema automático de gerenciamento de reservatórios, no campo de Medusa, Golfo do México, utilizando a ferramenta computacional *Decide!*, um banco de dados em tempo real *offshore*, um banco de dados em tempo real *onshore*, a integração de banco de dados adicionais e simuladores. As principais vantagens obtidas pelo uso deste sistema foram a economia de tempo para se analisar dados do reservatório, tomadas de decisões melhores e mais rápidas, e uma melhor interação das equipes de trabalho.

Em 2004, *Paino, W.* et al. analisaram por meio da instalação de zonas de completção inteligente, compostas por válvulas de controle interno, um sensor de temperatura distribuído e seis medidores de pressão, no poço Bagan-7, em Brunei, que os dados de produção deste poço têm reduzido bastante o nível de informações incertas do bloco principal a que pertence esse poço, permitindo, desta maneira, obter uma melhora significativa no desenvolvimento de modelos de reservatório.

*Silva Jr, M.* et al., (2005) realizaram um estudo em que uma série de processos tecnológicos foram utilizados para automatizar por completo o campo de exploração de Carmópolis, Brasil. Este processo incluía a completção de poços inteligentes e a automação da elevação artificial com um sistema SCADA, para que uma integração sistemática das técnicas de medições, comunicação e controle do campo fosse alcançada, melhorando assim o gerenciamento da produção do reservatório. Eles concluíram que a aplicação dessa tecnologia permitiu centralizar as operações, com a possibilidade de remotamente configurar, atuar e melhorar decisões a serem tomadas.

*Silva, L.* (2006) estudou métodos inteligentes como redes neurais e algoritmos genéticos junto com ferramentas de modelagem de reservatórios, para produzir soluções mais eficientes na predição e otimização da produção de petróleo. As soluções testadas se mostraram eficientes na

modelagem do problema, permitindo bons resultados de previsão de produção, tanto para curto e longo prazo.

*Emerick, A., Portella, R. (2007)* descreveram uma implementação de um método para otimizar a produção em poços inteligentes variando as posições das válvulas de controle de fluxo usando um algoritmo de otimização, baseado em métodos de busca direta, acoplado em simuladores comerciais de fluxo. Este tipo de algoritmo de otimização, juntamente acoplado com os simuladores de fluxo, foi utilizado em dois campos brasileiros *offshore* reais para quantificar os benefícios trazidos usando a tecnologia de poços inteligentes em relação a um caso utilizando a completação convencional. Os resultados mostraram aumentos significativos na predição da produção de petróleo em relação a poços que utilizam a completação convencional.

Em 2007, *Almeida, L. et al.* apresentaram um sistema, baseado em algoritmos evolutivos, capazes de otimizar o processo de controle da tecnologia de poços inteligentes. Na otimização foi considerado o risco de defeito que poderia existir nos dispositivos de controle. Mesmo considerando a existência de incertezas na operação dos dispositivos, os resultados obtidos nos testes revelam ganhos significativos no uso da completação inteligente como: aumento do fator de recuperação do campo, a redução do volume de água produzida e o aumento da vida do campo.

*Meum, P. et al., (2008)* propuseram o uso de um método da teoria de controle preditivo não-linear juntamente com o simulador de reservatório ECLIPSE, usado para modelagem e predições, para a otimização da produção de petróleo. O uso deste algoritmo deve-se à capacidade de poder tratar com as propriedades não-lineares encontradas nos modelos de reservatório. O estudo demonstrou um aumento em média de 30% na recuperação de petróleo em comparação a poços sem o uso desta técnica.

---

**CAPÍTULO V:**

***Materiais e Métodos***

---

## 5 Materiais e Métodos

Neste capítulo são apresentados os dados referentes à simulação de reservatórios e características dos fluidos, da rocha-reservatório e operacionais utilizados, da formulação do problema estudado, além da metodologia de análise.

### 5.1 Ferramentas Computacionais

Para efetuar o estudo proposto, algumas ferramentas computacionais são necessárias. Tanto aquelas relacionadas à simulação de reservatórios quanto à inteligência computacional.

O processo foi realizado através do simulador comercial STARS (Steam, Thermal, and *Advanced Processes Reservoir Simulator*) – versão 2007, um simulador numérico trifásico de múltiplos componentes da CMG (*Computer Modelling Group*).

O STARS é o simulador térmico e de processos avançados de reservatório mais utilizado pela indústria. Suas robustas reações cinéticas e capacidades geo-mecânicas fazem-no o mais completo e flexível simulador de reservatório disponível para modelar o complexo processo de recuperação de óleo e gás que estão sendo estudados e implementados atualmente. Além de poder ser utilizado em vários sistemas operacionais.

As simulações nesse programa têm como dados de entrada a configuração da malha e o modelo físico, que consistem nas características do meio (propriedades físicas da rocha-reservatório); propriedades dos fluidos e condições de contorno (descrição das fronteiras do reservatório); processo de recuperação (método, quantidade, orientação, distribuição e atribuições dos poços) e condições iniciais. Como resultado, obtém-se a partir da iteração desses fatores, por exemplo, a produção e vazão de óleo e água em cada poço produtor, além de outros dados.

Os sistemas de malha podem ser cartesianos, cilíndricos ou de profundidade e espessura variáveis, podendo ser utilizadas configurações bidimensionais e tridimensionais para qualquer sistema de malha.

Para as redes neurais a ferramenta computacional utilizada para se fazer as implementações necessárias foi o software Matlab. Este possui uma grande facilidade de operar com matrizes e vetores, além de possuir uma linguagem interpretada bastante intuitiva. Além disso, possui vários *toolboxes* para diferentes aplicações, entre elas para otimização, redes neurais e cálculos financeiros.

## 5.2 Modelo Físico

O modelo físico adotado consiste em um modelo retangular tridimensional de malha cartesiana. A Figura 5.1 apresenta o reservatório em 3D, mostrando o refinamento utilizado e as dimensões do reservatório.

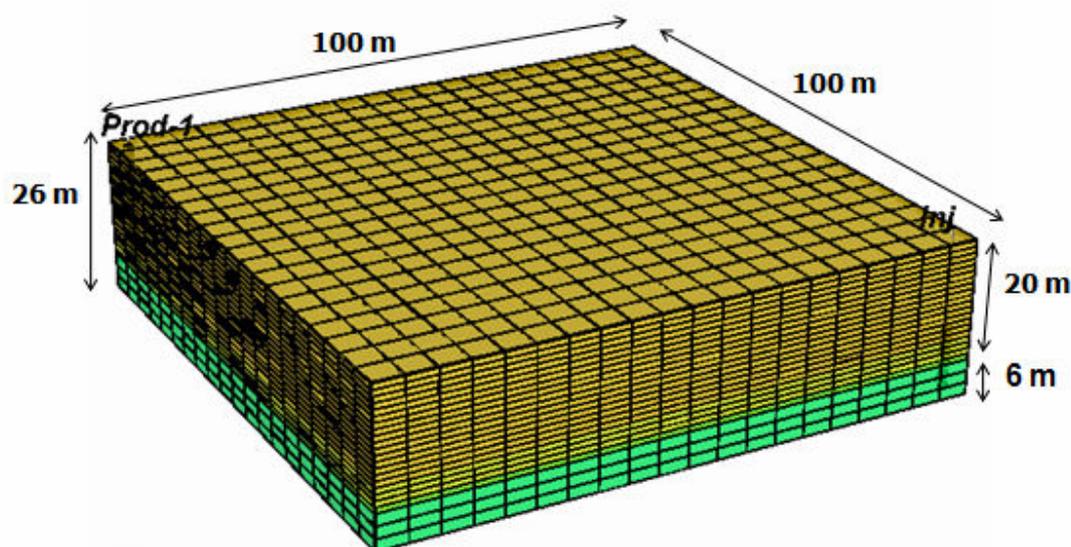


Figura 5.1. Modelo base

Considera-se que não existe fluxo de fluidos através dos limites do reservatório e são feitas as seguintes considerações:

- Só existem as fases água e óleo;
- A fase óleo é composta só por óleo;

- Não existem reações químicas;
- Não existem sólidos nos fluidos a serem considerados;
- Não existe perda de calor para as partes adjacentes do reservatório.

O reservatório estudado apresenta uma zona de água de 6 m. As características adotadas na simulação foram:

- Injeção em malha: ¼ Five spot
- Número de blocos: 9200 blocos
- Comprimento=largura: 20 blocos de 5,0 m cada
- Espessura: 20 camadas de 1 m; 3 camadas de 2 m

### 5.3 Propriedades da Rocha-Reservatório

Os valores das propriedades do reservatório estão apresentados na Tabela 5.1 e as propriedades da rocha na Tabela 5.2, respectivamente.

**Tabela 5.1 Propriedades do reservatório**

| <b>Propriedade</b>  | <b>Valor</b> |
|---|--------------|
| Profundidade do reservatório (m)  | 200          |
| Comprimento (m)   | 200          |
| Largura (m)   | 200          |
| Espessura (m)   | 26           |
| Temperatura inicial (°C)  | 37,8         |
| Saturação de água irreduzível   | 0,36         |
| Volume de óleo original – volume “ <i>in place</i> ” (m <sup>3</sup> std) | 119.570      |
| Espessura da zona de água (m)   | 6            |

**Tabela 5.2 Propriedades da rocha**

| <b>Propriedade</b>                        | <b>Valor</b> |
|---|--------------|
| Permeabilidade Horizontal (mD)            | 100          |
| Porosidade (%)                            | 24           |
| Condutividade Térmica da Rocha (J/m.s.°C) | 1,73         |
| Condutividade Térmica da Água (J/m.s.°C)  | 0,61         |
| Condutividade Térmica do Óleo (J/m.s.°C)  | 0,13         |
| Condutividade Térmica do Gás (J/m.s.°C)   | 0,04         |

#### 5.4 Características Operacionais do Modelo Base

A Tabela 5.3 apresenta as configurações operacionais adotadas no modelo base.

**Tabela 5.3 Configurações operacionais do modelo base**

| <b>Configuração operacional</b>               | <b>Valor</b> |
|---|--------------|
| Distância entre poços                         | 140 m        |
| Temperatura de injeção                        | 277°C        |
| Vazão de Injeção                              | 25 t/dia     |
| Título do Vapor                               | 50%          |
| Pressão máxima no poço injetor                | 7.198 kPa    |
| Pressão mínima nos poços produtores           | 196,5 kPa    |
| Intervalo de completação (Produtor e Injetor) | Camadas 1:21 |
| Tempo de projeto                              | 15 anos      |

#### 5.5 Parâmetros Analisados

Foi verificada a sensibilidade de alguns parâmetros operacionais (vazão de injeção de fluidos, qualidade do vapor, ou título de vapor, e intervalo de completação) sobre a produção acumulada de óleo.

Para analisar as respostas de interesse com base nas diferentes interações entre os parâmetros escolhidos, foi realizado um planejamento fatorial de três níveis: mínimos (-1), intermediários (0) e máximos (+1).

Desta maneira, para cada parâmetro analisado, foram obtidas 3 diferentes situações para se fazer as simulações necessárias. Estes parâmetros do reservatório foram utilizados para treinar a rede neural em 27 cenários diversos.

A Tabela 5.4 apresenta os parâmetros analisados com seus respectivos níveis.

**Tabela 5.4 Níveis dos parâmetros operacionais analisados**

| <b>Parâmetro</b>            | <b>Valor Mínimo<br/>(-1)</b> | <b>Valor Intermediário<br/>(0)</b> | <b>Valor Máximo<br/>(+1)</b> |
|-----------------------------|------------------------------|------------------------------------|------------------------------|
| Vazão de Injeção- t/dia     | 25                           | 37,5                               | 50                           |
| Título do Vapor (%)         | 50                           | 70                                 | 90                           |
| Intervalo de<br>Completação | Base                         | Centro                             | Topo                         |

A nomenclatura abaixo exhibe o significado das definições para o parâmetro intervalo de completação:

- BASE – Injetar na base da zona de óleo;
- TOPO – Injetar no topo da zona de óleo;
- CENTRO - Injetar no centro da zona de óleo;

A Figura 5.2 apresenta os esquemas de injeção utilizados, identificando as zonas de água, de óleo e a área em que ocorre a completação.

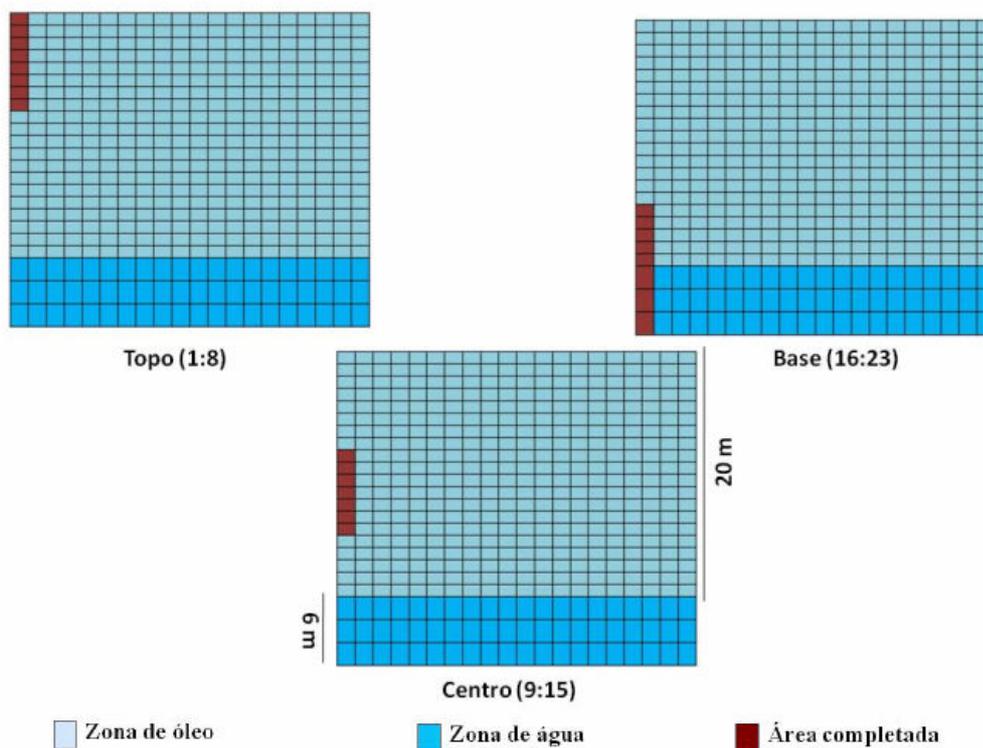
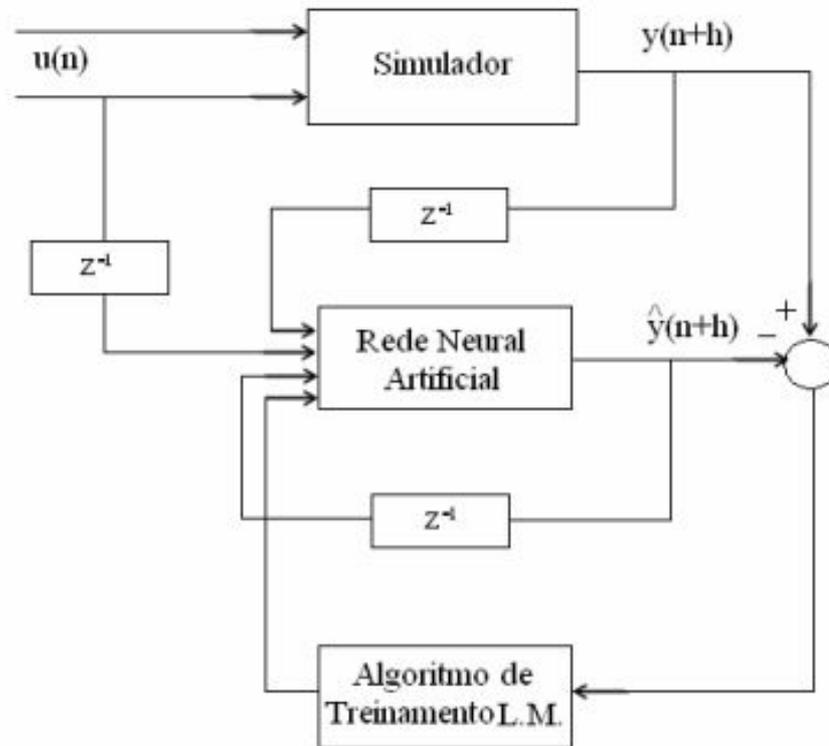


Figura 5.2 .Esquemas de injeção de vapor

## 5.6 Preditor Neural Aplicado

Este trabalho propõe um mecanismo capaz de reproduzir o comportamento do simulador utilizando apenas o conjunto de saídas, em uma abordagem de predição. O algoritmo de predição é baseado em uma rede neural recorrente do modelo NARX (Menezes, 2006). Esta rede possui uma arquitetura neural recorrente usada originalmente para identificação entrada-saída de sistemas não-lineares. Quando aplicada para predição de séries temporais, a rede NARX é projetada geralmente como um modelo autoregressivo não-linear (NAR). A Figura 5.3 ilustra o problema de predição estudado nesta dissertação.



**Figura 5.3. Preditor construído a partir de uma Rede Neural**

O algoritmo de predição proposto recebe como entrada os dados da simulação (as curvas de produção acumulada e de vazão) fornecidos pelo simulador e fornece como saída uma estimativa do valor no tempo  $n+h$  onde  $h$  representa o horizonte de predição. Se  $h = 1$ , tem-se predição de passos simples, enquanto  $h > 1$  corresponde à predição de passos múltiplos. A arquitetura recorrente em estudo neste trabalho deve ser capaz de prover estimativas confiáveis, tanto para um horizonte de predição de passos simples quanto para um horizonte de múltiplos passos.

Após uma série de simulações, variando a quantidade de camadas da rede, de neurônios em cada camada e a ordem da memória de linha de atraso, a seguinte arquitetura apresentou o melhor desempenho:

- Regressor de Saída: a memória de linha de atraso tanto com ordem 2 como com ordem 10 levou a resultados similares;
- Camadas Ocultas: uma com 10 neurônios Tangente Sigmóide;
- Camada de Saída: 1 neurônio do tipo linear puro.

A Figura 5.3 ilustra como é realizado o processo de treinamento da arquitetura selecionada. A saída da rede será comparada com o valor do sinal desejado  $y(n+h)$  proveniente do simulador. O erro de predição é calculado e, então, os pesos da rede são atualizados, utilizando o algoritmo de Levenberg-Marquardt.

No passo seguinte, um novo conjunto de treinamento é apresentado à entrada da rede. A resposta da mesma é realimentada para o regressor de saída, e a próxima resposta obtida,  $\hat{y}(n+h)$ , será comparada ao valor do sinal no instante de tempo subsequente em que o erro é calculado e utilizado para atualizar os pesos sinápticos novamente. Este processo se repete até que um número pré-definido de passos seja alcançado.

Após o processo de aprendizado, o objetivo é determinar um limite de confiabilidade para as estimativas realizadas pela rede neural, ou seja, deve-se garantir que o erro entre a saída do simulador e a saída da rede neural permaneça dentro de um limite aceitável. Sabe-se que, se uma medida é estimada através da predição de passo simples, a rede neural terá recebido como entradas as amostras reais do sinal. Estas observações são reais, no sentido que, são obtidas diretamente da saída do simulador e o erro de predição deverá ser pequeno para este caso. A predição de um sinal por múltiplos passos é diferente: a informação, na medida em que o horizonte de predição cresce, não provém do simulador, mas, das estimativas da própria rede neural. A confiabilidade destas estimativas tende a diminuir, à medida que o horizonte se distancia do ponto de partida da predição (Medeiros, 2009).

A análise do erro de predição, que corresponde à diferença entre o valor do simulador e o valor esperado, obtido através da predição, é utilizada para determinar se a predição para uma dada situação é viável ou não.

## **5.7 Metodologia de Trabalho**

A análise consistiu nas seguintes etapas:

- Construção do modelo base do reservatório;
- Treinar a rede neural com os dados obtidos do simulador;
- Análise da viabilidade de se utilizar redes neurais artificiais para se fazer previsões da produção acumulada ( $N_p$ ) e da vazão de petróleo.

---

## **CAPÍTULO VI:**

### ***Resultados e Discussões***

---

## **6 Resultados e Discussões**

Uma ferramenta vastamente usada para previsão do comportamento de curvas de produção é o simulador numérico. O objetivo deste estudo é avaliar o uso de RNAs como técnica para a previsão de produção e comparar seus resultados com os obtidos pelo simulador numérico. Com este intuito, alguns casos sintéticos foram construídos e computados no simulador para servir de referência nas comparações dos resultados.

Este estudo de casos tem a intenção de contemplar duas situações distintas. Na primeira, os valores da vazão de injeção de vapor, do título de vapor e do intervalo de completação não variam. Na segunda situação, o valor da vazão de injeção de vapor varia para metade no momento em que o reservatório atinge o valor máximo de vazão (produção), permanecendo constantes os valores do título de vapor e do intervalo de completação. Esta alteração no valor da vazão de injeção foi feita para verificar se o aprendizado da rede neural sofria alguma modificação com um parâmetro variável. Os valores destes parâmetros foram apresentados na Tabela 5.4.

Além disso, foram feitas simulações envolvendo um regressor de saída contendo uma memória de linha de atraso tanto de ordem 2 como de ordem 10, como citado anteriormente. Essas simulações têm o objetivo de comparar os resultados obtidos de modelos com memórias de linha de atraso de ordem diferentes.

Nas simulações que envolviam a memória de linha de atraso de ordem 2, a entrada da rede neural consistia dos valores da vazão de injeção de vapor, título de vapor, intervalo de completação e de duas saídas atrasadas no tempo realimentadas do simulador, para que a rede neural gerasse o passo seguinte de predição.

Já para o caso que contempla a memória de linha de atraso de ordem 10, a entrada da rede neural consistia dos valores da vazão de injeção de vapor, título de vapor, intervalo de completação e de dez saídas atrasadas no tempo realimentadas do simulador, para que a rede neural gerasse, desta maneira, o passo seguinte de predição.

A grande vantagem observada da utilização das redes neurais nas simulações, foi o tempo de processamento das informações. Enquanto que no simulador as simulações duravam um tempo de aproximadamente duas horas e meia, com as redes neurais o tempo gasto ficou em torno de 10 segundos.

## **6.1 Predição com Vazão de Injeção, Título de Vapor e Intervalo de Completação Constantes**

Como mencionado na Tabela 5.4, os parâmetros de entrada da rede (vazão de injeção, título de vapor e intervalo de completção) têm, cada um deles, três variações. Dessa maneira, pode-se ter 27 combinações diferentes. Portanto, foram feitas 27 simulações para esta situação com essas variáveis constantes.

Foi escolhido o caso a seguir, para apresentar o comportamento do preditor neural:

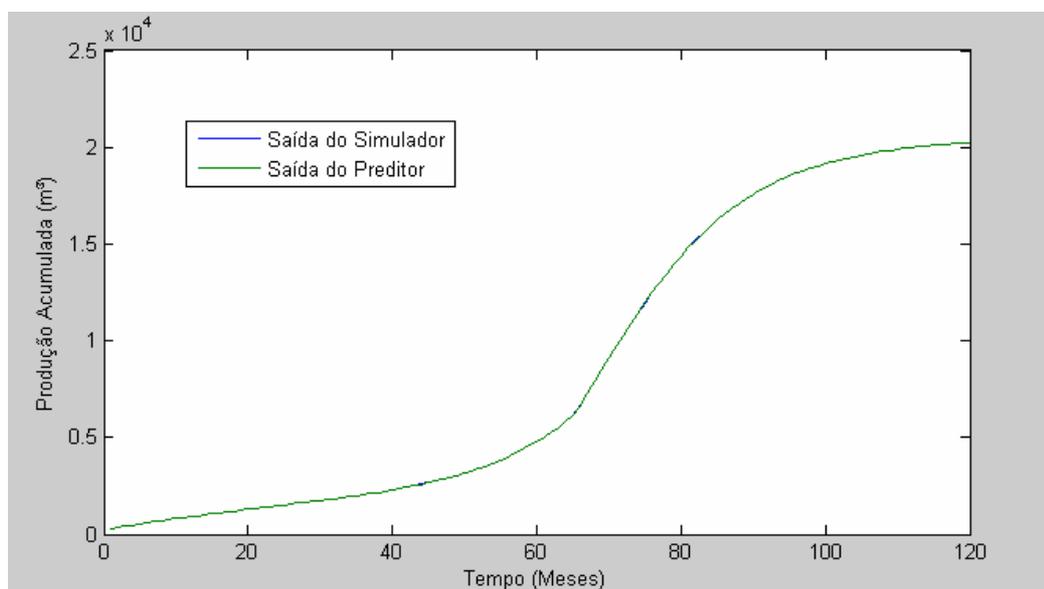
- Vazão de injeção: 25t/dia
- Intervalo de completção: Base
- Título de vapor: 50%

As simulações foram feitas para um período de 15 anos, com os dados (produção acumulada e vazão) sendo obtidos com intervalos mensais. O simulador gerou os dados de janeiro do ano 2000 até dezembro de 2014, totalizando 180 meses de informações. Nas predições de passo simples foi considerado um número de passos adiante em que o erro entre o sinal do simulador e o sinal proveniente da rede poderia ter no máximo um valor de 10%. Inicialmente serão mostrados os resultados obtidos para o regressor de saída com uma memória de linha de atraso de ordem 2 e, em seguida, os resultados com uma memória de linha de atraso de ordem 10.

### **6.1.1 Predição para o Regressor de Saída com uma Memória de Linha de Atraso de Ordem 2**

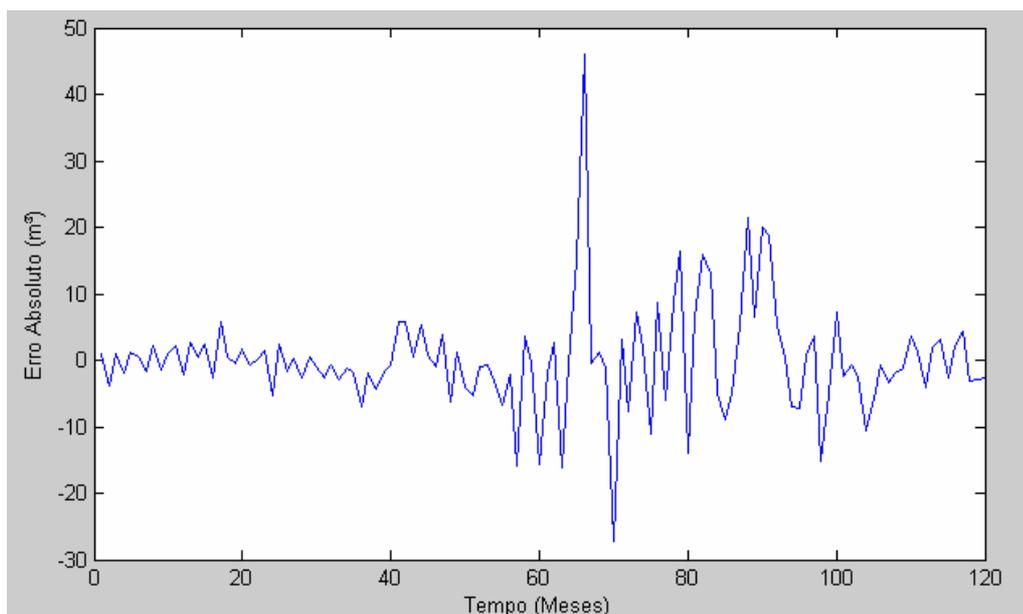
A Figura 6.1 ilustra a curva de treinamento da rede neural com a curva do simulador para a produção acumulada de petróleo. O algoritmo de Levenberg-Marquardt foi utilizado para o

processo de aprendizado. O sinal azul representa o simulador, enquanto que a rede neural é representada pelo sinal verde. O conjunto de treinamento tem os dados dos 10 primeiros anos da simulação, ou seja, 120 meses.



**Figura 6.1. Treinamento para a curva de produção acumulada**

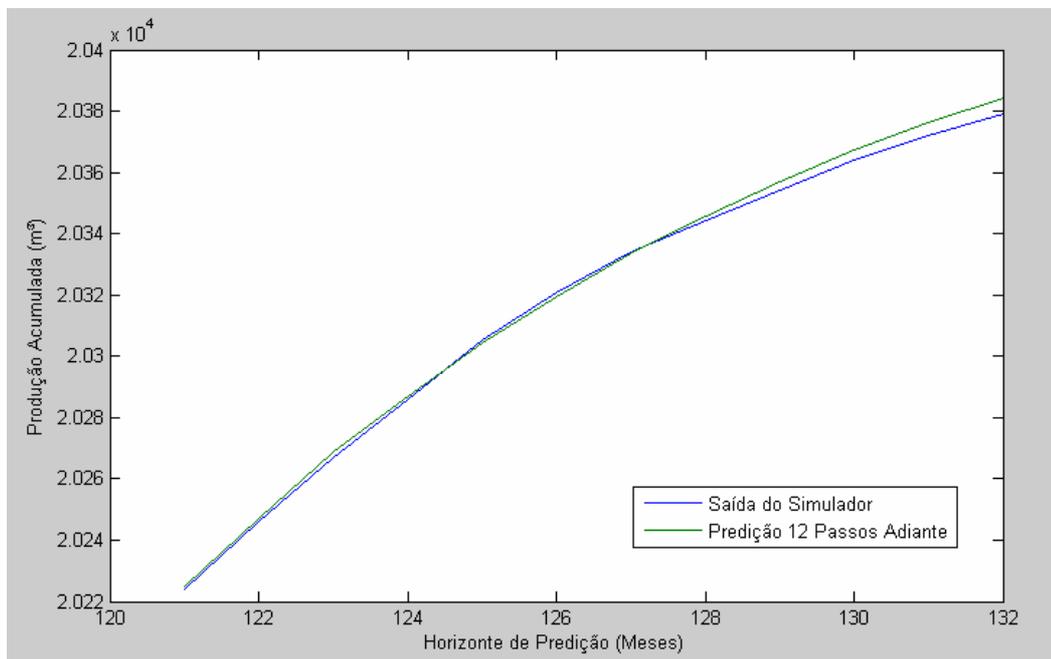
A Figura 6.2 corresponde ao erro obtido no treinamento da rede neural. O erro para o treinamento da rede pode ser considerado baixo, pois este ficou inferior a  $50 \text{ m}^3$ , e a produção acumulada ao final dos 120 meses atinge mais de  $20.000 \text{ m}^3$  de petróleo.



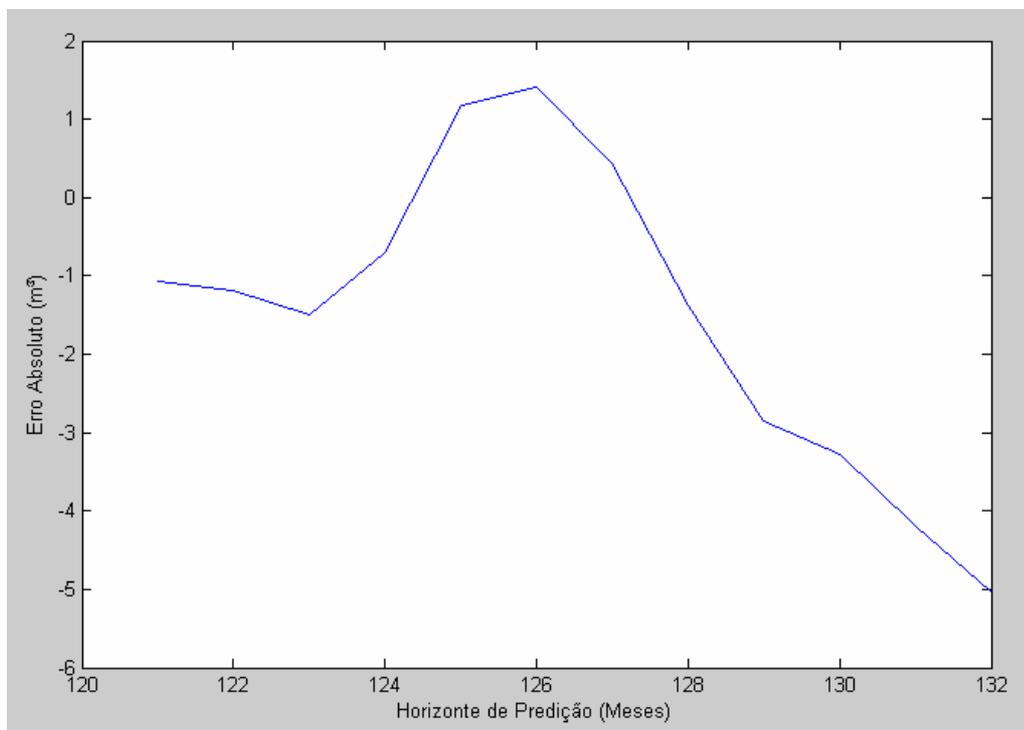
**Figura 6.2. Sinal erro de treinamento da produção acumulada**

Na Figura 6.3 é ilustrado o gráfico utilizado para analisar a predição de passo simples com 12 passos adiante, realizada pela rede neural para a produção acumulada de petróleo. Este gráfico mostra os sinais de saída do simulador e da rede NARX utilizada como preditor de passo simples. O sinal do preditor é representado pela linha verde, enquanto o sinal gerado pela saída do simulador é representado pela linha azul.

A Figura 6.4 corresponde ao gráfico do erro de predição. Foi verificado que para o gráfico da predição da produção acumulada não foi apresentado um erro com valor acima de 10% em relação ao sinal do simulador para um número de 12 passos adiante, ou 12 meses.



**Figura 6.3. Sinal da produção acumulada obtido pela predição de 12 passos**

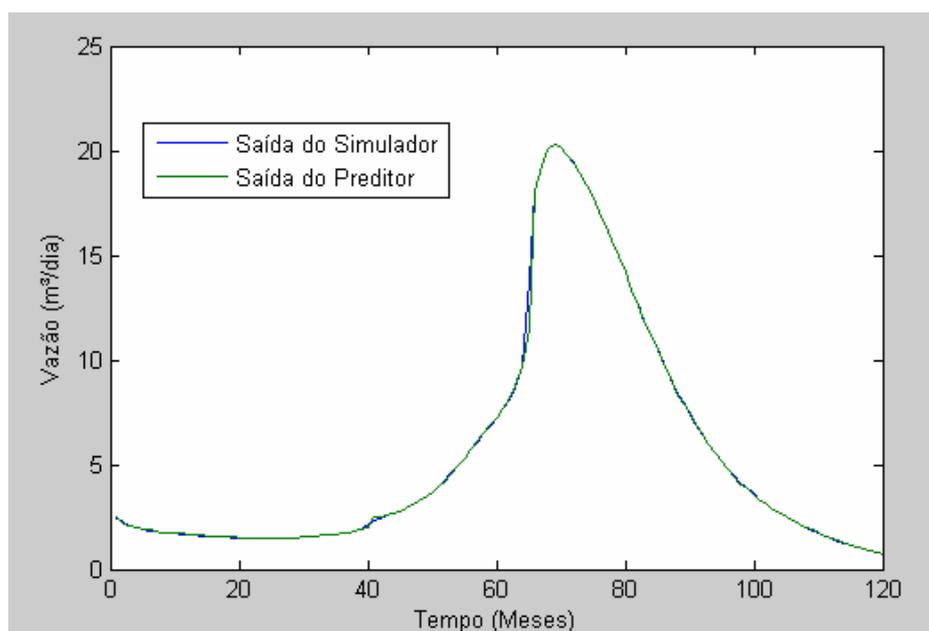


**Figura 6.4. Sinal erro de predição para a produção acumulada de 12 passos**

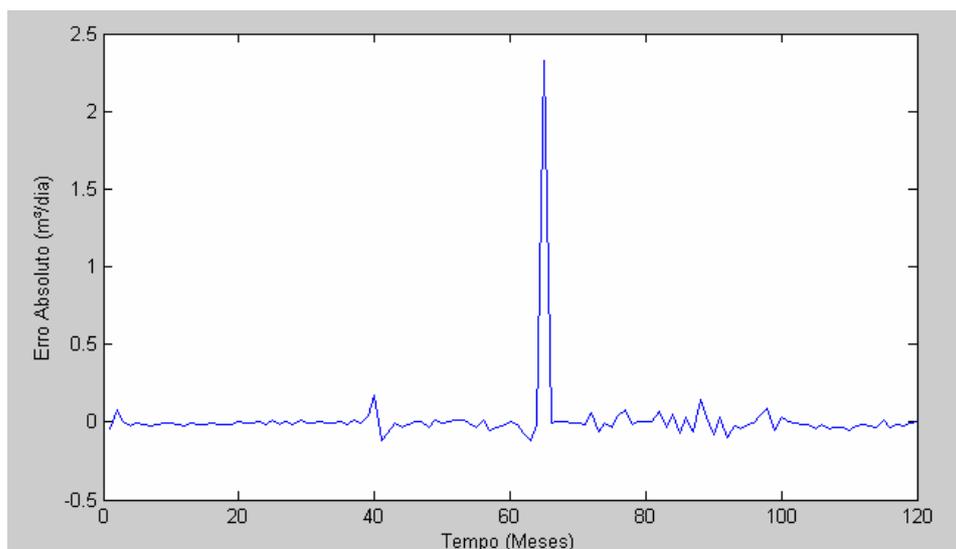
Da mesma maneira com que foi feita a curva de produção acumulada, foram realizadas as mesmas simulações com a curva de vazão.

A Figura 6.5 ilustra a curva de treinamento da rede neural com a curva do simulador para a vazão de petróleo. O algoritmo de Levenberg-Marquardt foi utilizado para o processo de aprendizado. O sinal azul representa o simulador, enquanto que a rede neural é representada pelo sinal verde. O conjunto de treinamento tem os dados dos 10 primeiros anos da simulação, ou seja, 120 meses.

A Figura 6.6 corresponde ao erro obtido no treinamento da rede neural. O erro para o treinamento da rede pode ser considerado baixo, pois esse não apresentou valores consideráveis em relação à quantidade gerada.



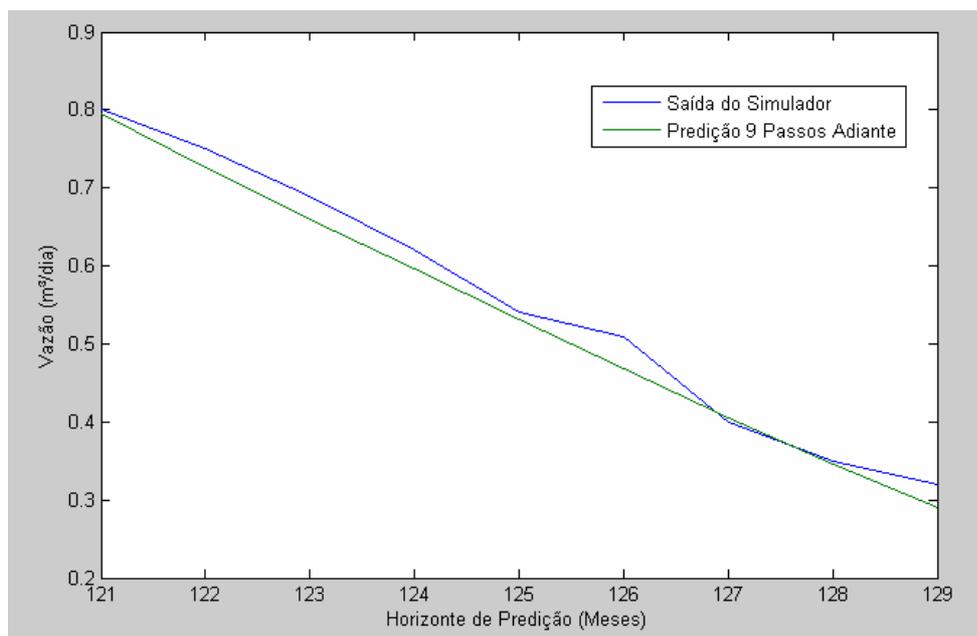
**Figura 6.5. Treinamento para a curva de vazão**



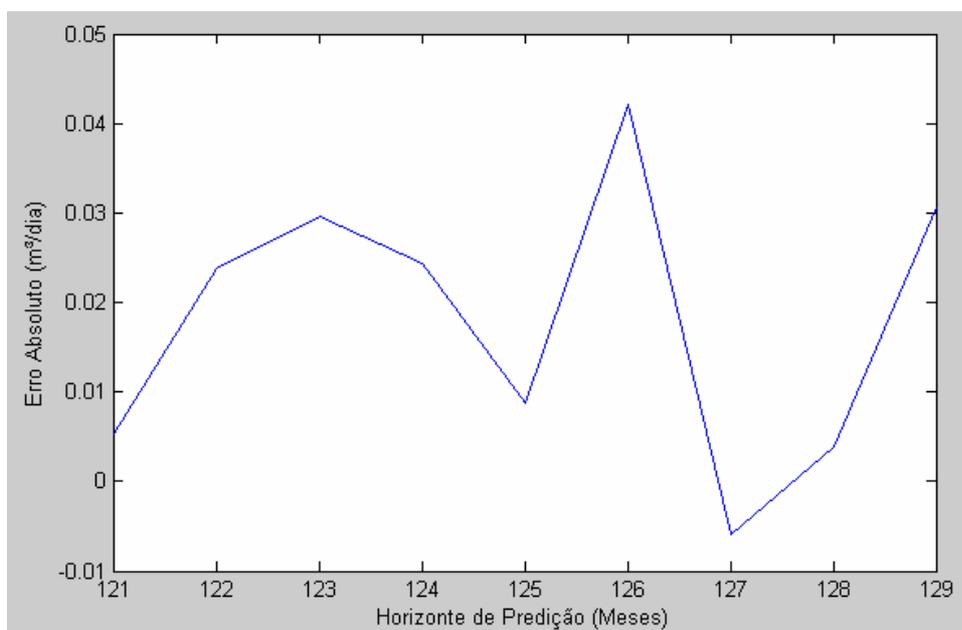
**Figura 6.6. Sinal erro de treinamento da vazão**

Na Figura 6.7 é ilustrado o gráfico utilizado para analisar a predição de passo simples com 9 passos adiante, realizada pela rede neural para a vazão de petróleo. Este gráfico mostra os sinais de saída do simulador e da rede NARX utilizada como preditor de passo simples. O sinal do preditor é representado pela linha verde, enquanto o sinal gerado pela saída do simulador é representado pela linha azul.

A Figura 6.8 corresponde ao gráfico do erro de predição. Foi verificado que para o gráfico da predição da vazão, não foi apresentado erro com valor acima de 10% em relação ao sinal do simulador para um número de 9 passos adiante, ou 9 meses. Para simulações com um número maior que 9 passos adiante, houve um erro maior que 10%.



**Figura 6.7. Sinal da vazão obtido pela previsão de 9 passos**

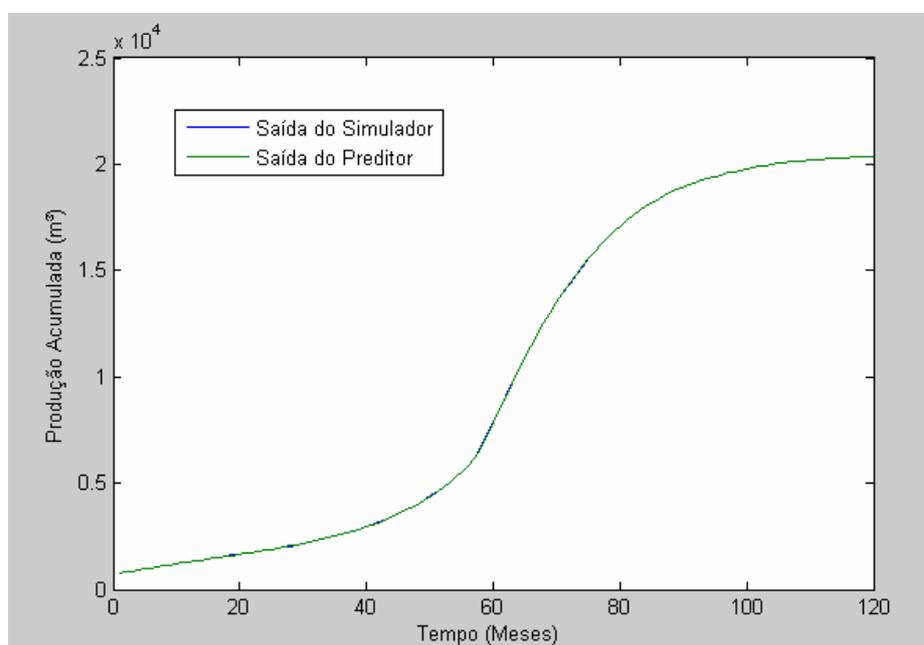


**Figura 6.8. Sinal erro de previsão para a vazão de 9 passos**

Foi observado nos gráficos de treinamento das curvas de produção acumulada e de vazão que o pico do erro entre a saída do simulador e da rede neural se dá justamente no ponto de inflexão dessas curvas. Para minimizar esse efeito uma solução seria aumentar o número de dados para o treinamento da rede.

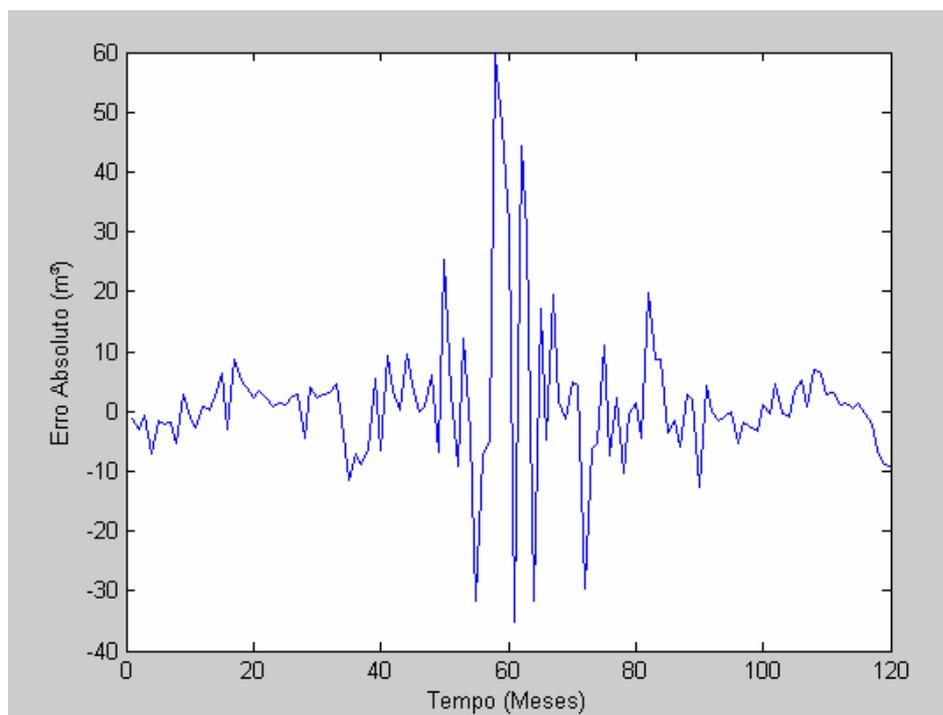
### 6.1.2 Predição para o Regressor de Saída com uma Memória de Linha de Atraso de Ordem 10

A Figura 6.9 ilustra a curva de treinamento da rede neural com a curva do simulador para a produção acumulada de petróleo. O algoritmo de Levenberg-Marquardt foi utilizado para o processo de aprendizado. O sinal azul representa o simulador, enquanto que a rede neural é representada pelo sinal verde. O conjunto de treinamento tem os dados dos 10 primeiros anos da simulação, ou seja, 120 meses



**Figura 6.9. Treinamento para a curva de produção acumulada**

A Figura 6.10 corresponde ao erro obtido no treinamento da rede neural. O erro para o treinamento da rede pode ser considerado baixo, pois este ficou inferior a  $65 \text{ m}^3$ , e a produção acumulada ao final dos 120 meses atinge mais de  $20.000 \text{ m}^3$  de petróleo.



**Figura 6.10. Sinal erro de treinamento da produção acumulada**

Na Figura 6.11 é ilustrado o gráfico utilizado para analisar a predição de passo simples com 12 passos adiante, realizada pela rede neural para a produção acumulada de petróleo. Este gráfico mostra os sinais de saída do simulador e da rede NARX utilizada como preditor de passo simples. O sinal do preditor é representado pela linha verde, enquanto o sinal gerado pela saída do simulador é representado pela linha azul.

A Figura 6.12 corresponde ao gráfico do erro de predição. Foi verificado que para o gráfico da predição da produção acumulada não foi apresentado um erro com valor acima de 10% em relação ao sinal do simulador para um número de 12 passos adiante, ou 12 meses.

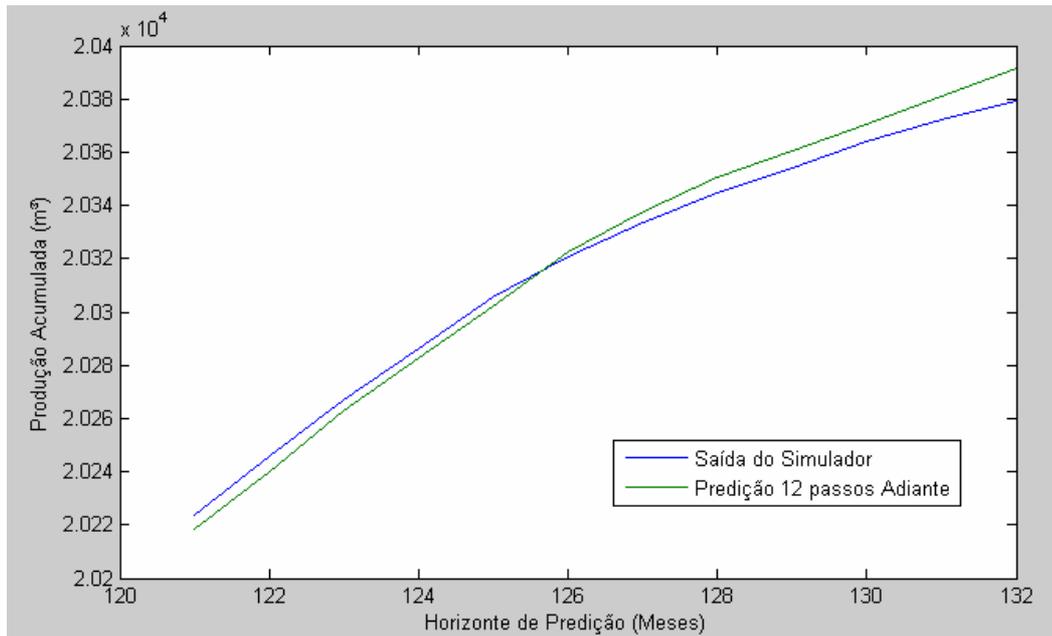


Figura 6.11. Sinal da produção acumulada obtido pela predição de 12 passos

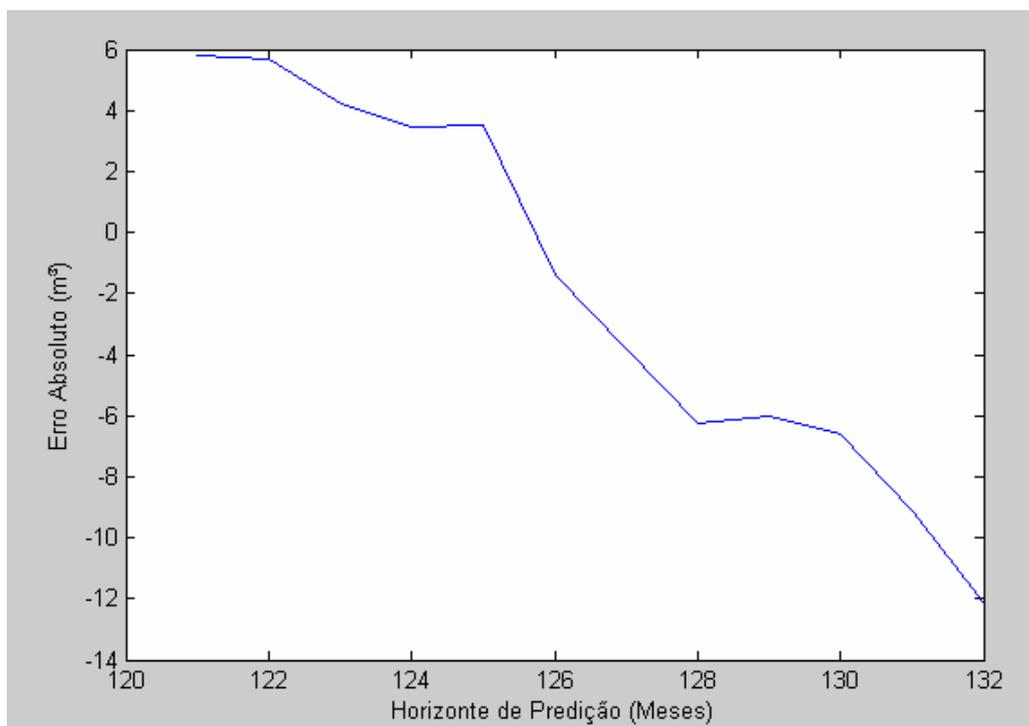
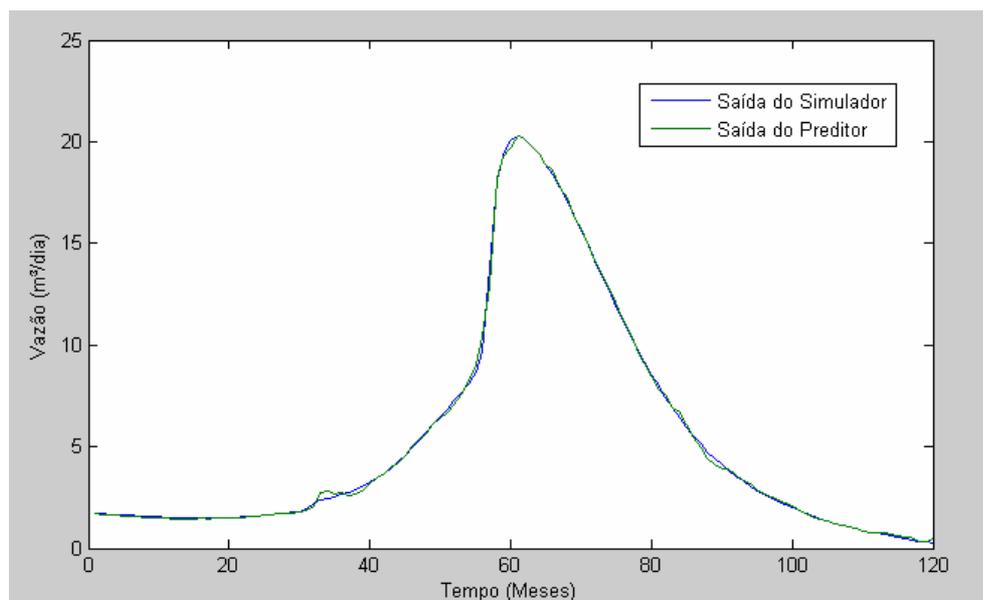


Figura 6.12. Sinal erro de predição para a produção acumulada de 12 passos

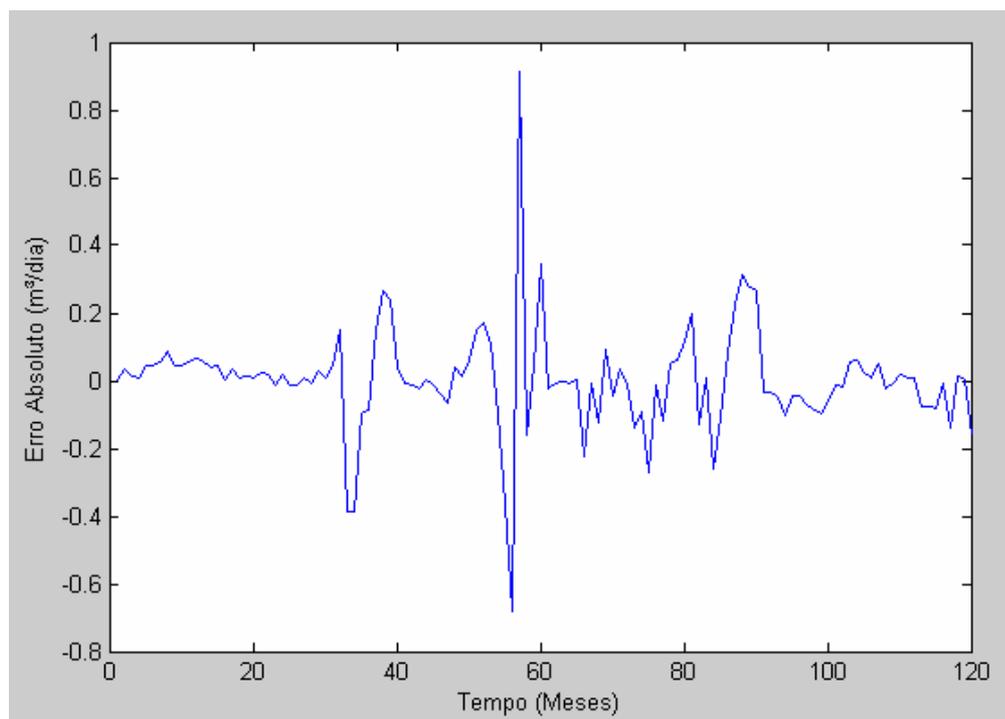
Da mesma maneira com que foi feita a curva de produção acumulada, foram realizadas as mesmas simulações com a curva de vazão.

A Figura 6.13 ilustra a curva de treinamento da rede neural com a curva do simulador para a vazão de petróleo. O algoritmo de Levenberg-Marquardt foi utilizado para o processo de aprendizado. O sinal azul representa o simulador, enquanto que a rede neural é representada pelo sinal verde. O conjunto de treinamento tem os dados dos 10 primeiros anos da simulação, ou seja, 120 meses.

A Figura 6.14 corresponde ao erro obtido no treinamento da rede neural. O erro para o treinamento da rede pode ser considerado baixo, pois esse não apresentou valores consideráveis em relação à quantidade gerada.



**Figura 6.13. Treinamento para a curva de vazão**



**Figura 6.14. Sinal erro de treinamento da vazão**

Na Figura 6.15 é ilustrado o gráfico utilizado para analisar a predição de passo simples com 8 passos adiante, realizada pela rede neural para a vazão de petróleo. Este gráfico mostra os sinais de saída do simulador e da rede NARX utilizada como preditor de passo simples. O sinal do preditor é representado pela linha verde, enquanto o sinal gerado pela saída do simulador é representado pela linha azul.

A Figura 6.16 corresponde ao gráfico do erro de predição. Foi verificado que para o gráfico da predição da vazão, não foi apresentado erro com valor acima de 10% em relação ao sinal do simulador para um número de 8 passos adiante, ou 8 meses. Para simulações com um número maior que 8 passos adiante, houve um erro maior que 10%.

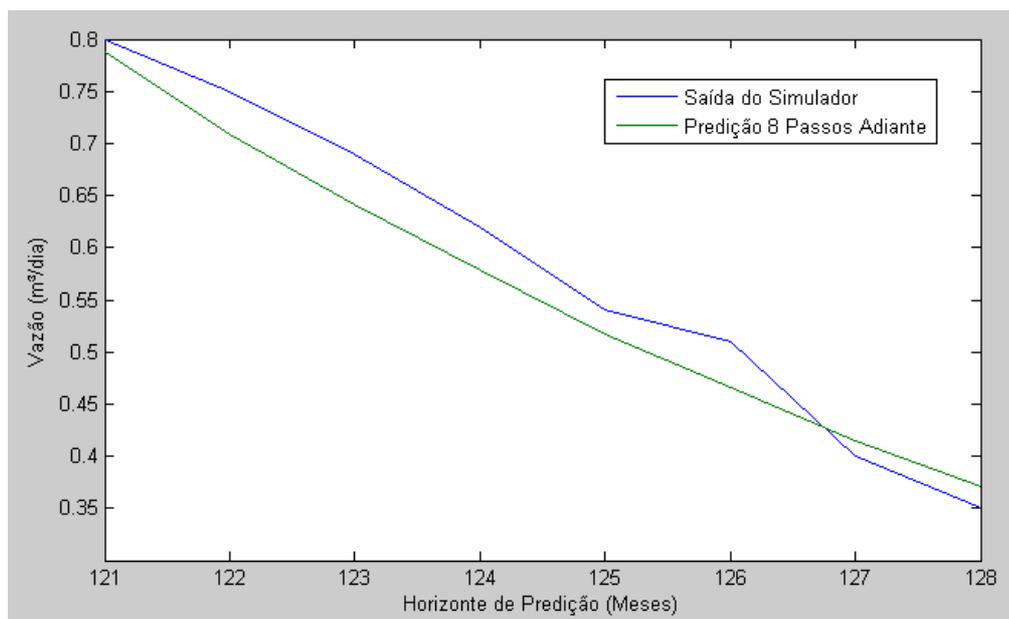


Figura 6.15. Sinal da vazão obtido pela previsão de 8 passos

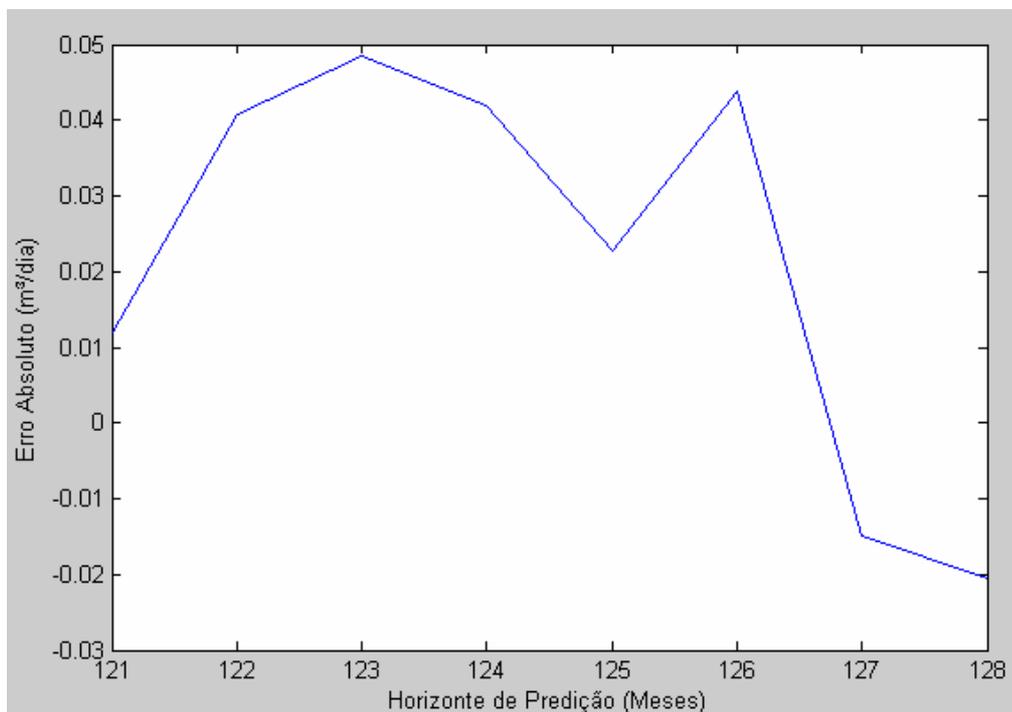


Figura 6.16. Sinal erro de previsão para a vazão com 8 passos

Foi observado nos gráficos de treinamento das curvas de produção acumulada e de vazão que o pico do erro entre a saída do simulador e da rede neural se dá justamente no ponto de

inflexão dessas curvas. Para minimizar esse efeito uma solução seria aumentar o número de dados para o treinamento da rede.

## **6.2 Predição com Título de Vapor e Intervalo de Completação Constantes e Vazão de Injeção Variável**

Nesta situação, as simulações realizadas mantiveram constantes os parâmetros título de vapor e o intervalo de completação, variando apenas a vazão de injeção de vapor. Este foi alterado para aproximadamente a metade do seu valor inicial no momento em que a vazão de petróleo atingia o seu valor máximo.

Para apresentar o comportamento do preditor neural, foi escolhido o mesmo caso da primeira situação, que é o relacionado abaixo:

- Vazão de injeção de vapor: 25t/dia
- Intervalo de completação: Base
- Título de vapor: 50%

A diferença em relação ao primeiro é que no momento em que este reservatório atinge o valor máximo da vazão, aproximadamente depois do 6º ano de produção, o parâmetro da vazão de injeção de vapor é modificado para 13t/dia.

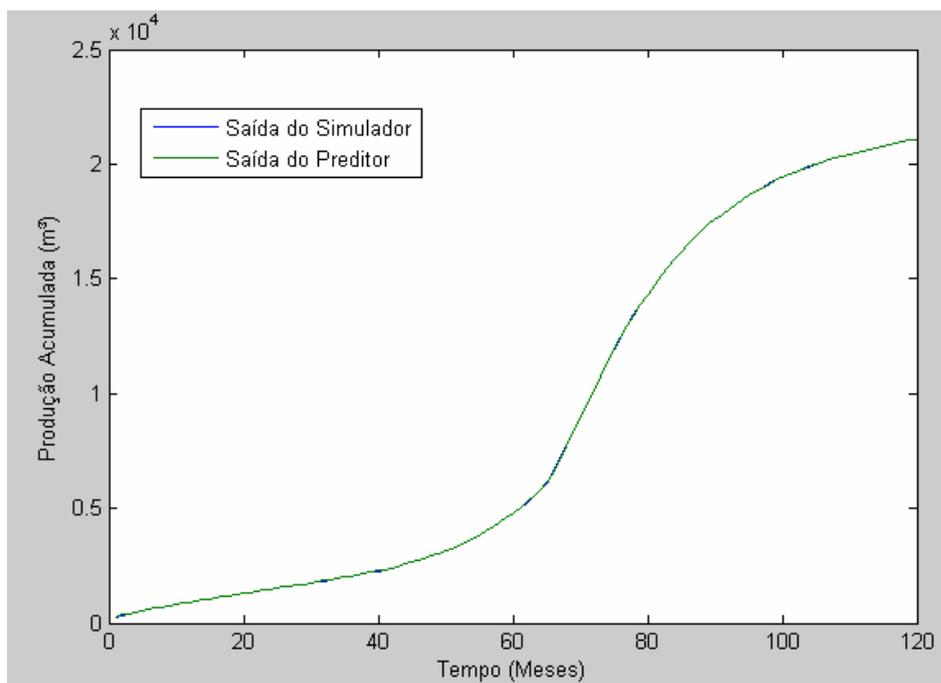
A intenção desta modificação é verificar como o preditor neural se comporta com a mudança do valor de algum parâmetro. Foi observado que quando há variação, conseguiu-se um número de passos adiante na predição maior do que quando todos os parâmetros são constantes. Isto se deve ao maior número de informações que a rede neural terá a sua disposição para se fazer o seu treinamento.

Da mesma forma que na primeira situação, as simulações foram feitas para um período de 15 anos, com os dados (produção acumulada e vazão) sendo obtidos com intervalos mensais. O simulador gerou os dados de janeiro do ano 2000 até dezembro de 2014, totalizando 180 meses

de informações. Nas predições de passo simples foi considerado um número de passos adiante em que o erro entre o sinal do simulador e o sinal proveniente da rede poderia ter no máximo um valor de 10%.

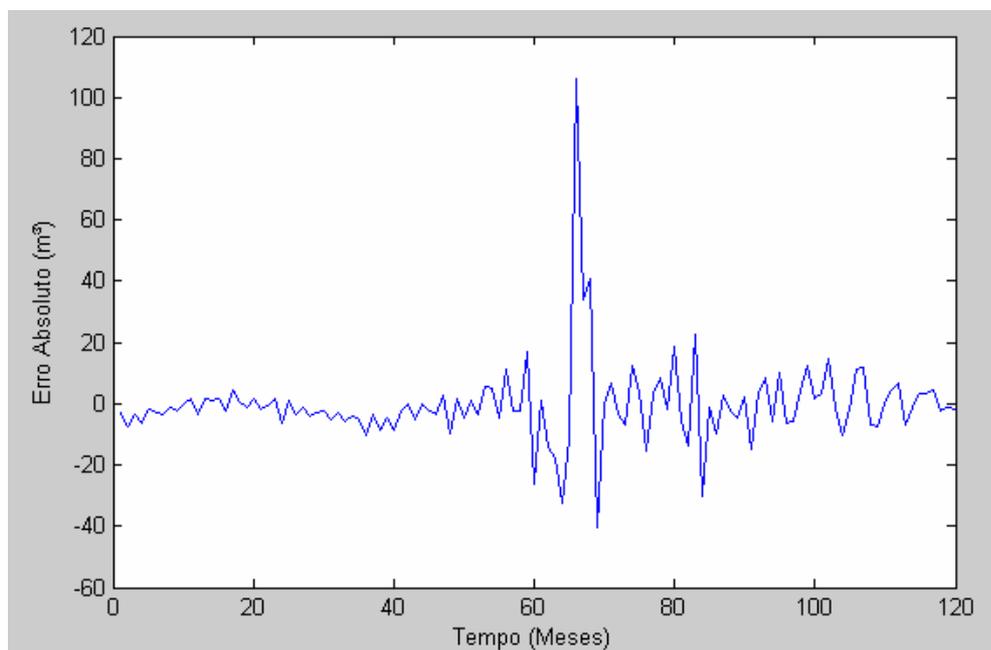
### 6.2.1 Predição para o Regressor de Saída com uma Memória de Linha de Atraso de Ordem 2

A Figura 6.17 ilustra a curva de treinamento da rede neural com a curva do simulador para a produção acumulada de petróleo. O algoritmo de Levenberg-Marquardt foi utilizado para o processo de aprendizado. O sinal azul representa o simulador, enquanto que a rede neural é representada pelo sinal verde. O conjunto de treinamento tem os dados dos 10 primeiros anos da simulação, ou seja, 120 meses.



**Figura 6.17. Treinamento para a curva de produção acumulada com a vazão de injeção variada**

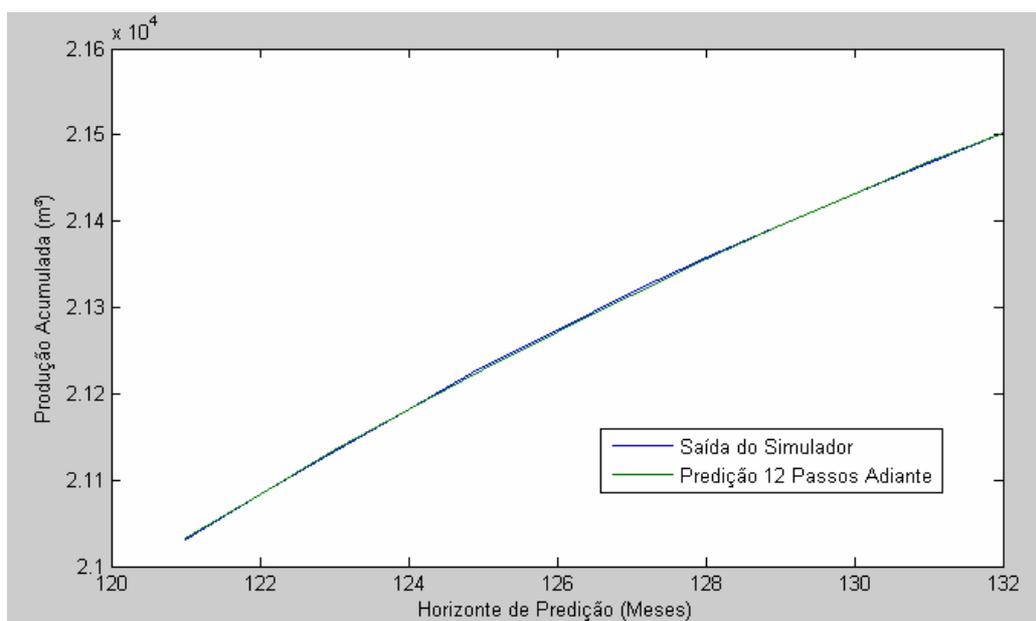
A Figura 6.18 corresponde ao erro obtido no treinamento da rede neural. O erro para o treinamento da rede pode ser considerado baixo, pois este não apresentou valores consideráveis em comparação com a produção acumulada que atinge mais de 20.000 m<sup>3</sup> de petróleo ao final dos 120 meses.



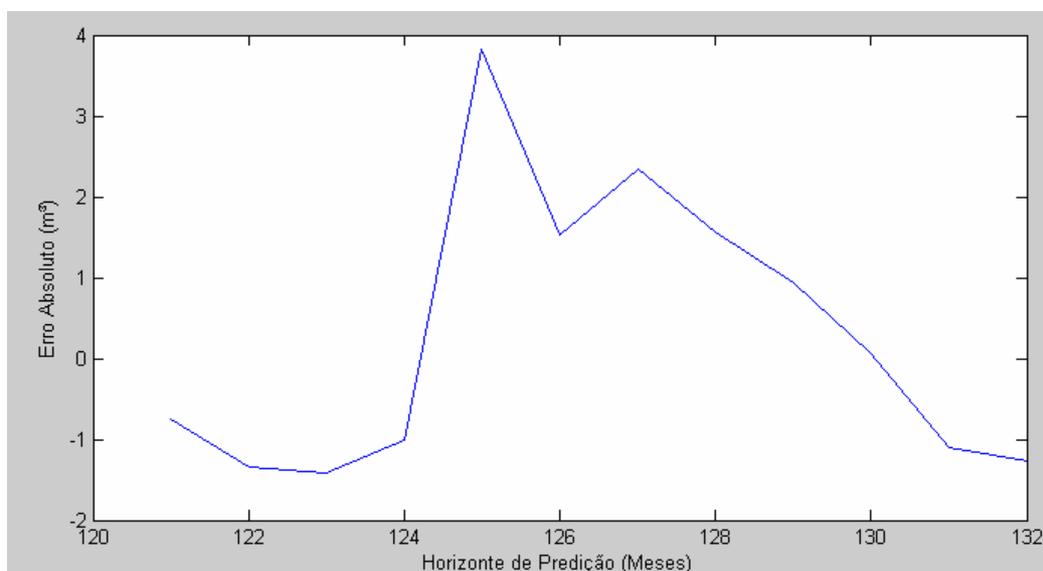
**Figura 6.18.** Sinal erro de treinamento da produção acumulada com a vazão de injeção variada

Na Figura 6.19 é ilustrado o gráfico utilizado para analisar a predição de passo simples com um número de 12 passos adiante, realizada pela rede neural para a produção acumulada de petróleo. Este gráfico mostra os sinais de saída do simulador e da rede NARX utilizada como preditor de passo simples. O sinal do preditor é representado pela linha verde, enquanto o sinal gerado pela saída do simulador é representado pela linha azul.

A Figura 6.20 corresponde ao gráfico do erro de predição. Foi verificado que para o gráfico da predição da produção acumulada, não foi apresentado um erro com valor acima de 10% em relação ao sinal do simulador para um número de 12 passos adiante, ou 12 meses.



**Figura 6.19.** Sinal da produção acumulada obtido pela predição de 12 passos com a vazão de injeção variada

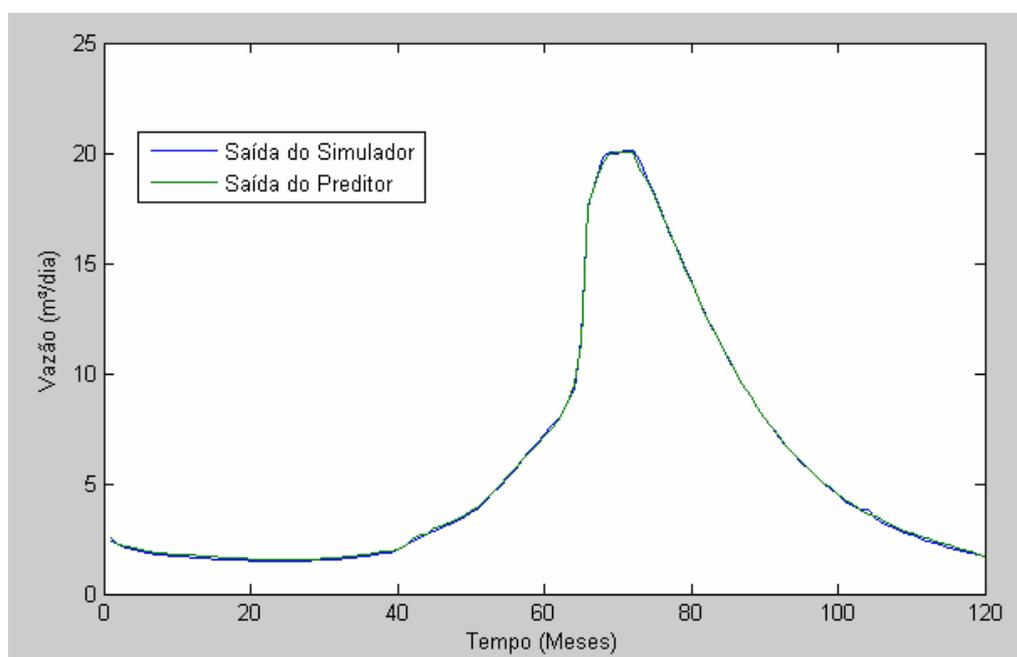


**Figura 6.20.** Sinal erro de predição para a produção acumulada de 12 passos com a vazão de injeção variada

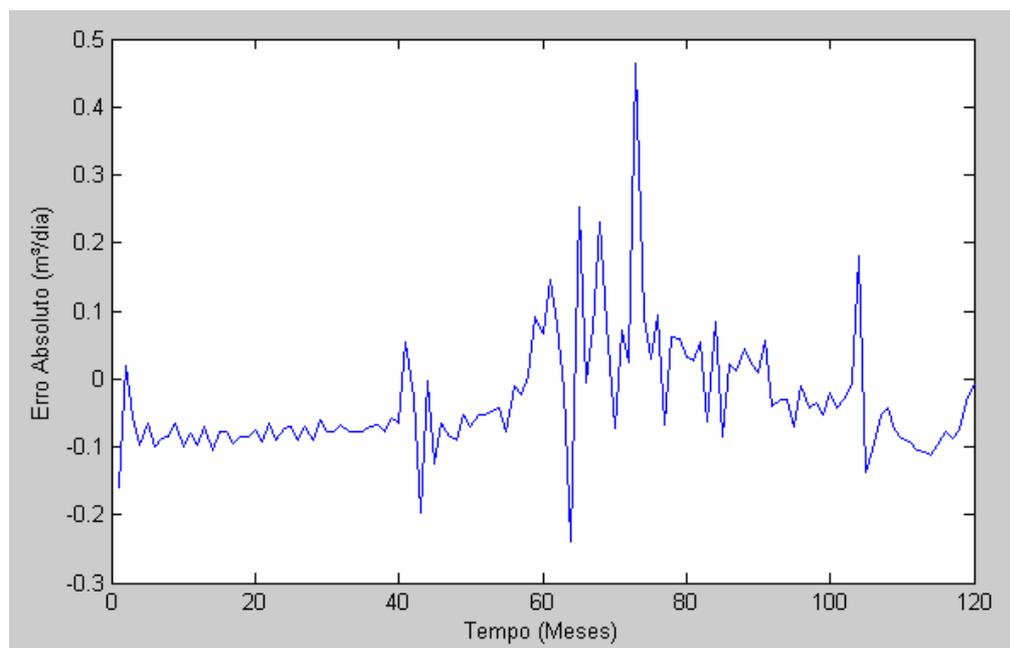
Da mesma maneira feita com a curva de produção acumulada, foram feitas as mesmas simulações com a curva de vazão.

A Figura 6.21 ilustra a curva de treinamento da rede neural com a curva do simulador para a vazão de petróleo. O algoritmo de Levenberg-Marquardt foi utilizado para o processo de aprendizado. O sinal azul representa o simulador, enquanto que a rede neural é representada pelo sinal verde. O conjunto de treinamento tem os dados dos 10 primeiros anos da simulação, ou seja, 120 meses.

A Figura 6.22 corresponde ao erro obtido no treinamento da rede neural. O erro para o treinamento da rede pode ser considerado baixo, pois esse não apresentou valores consideráveis em relação à quantidade gerada.



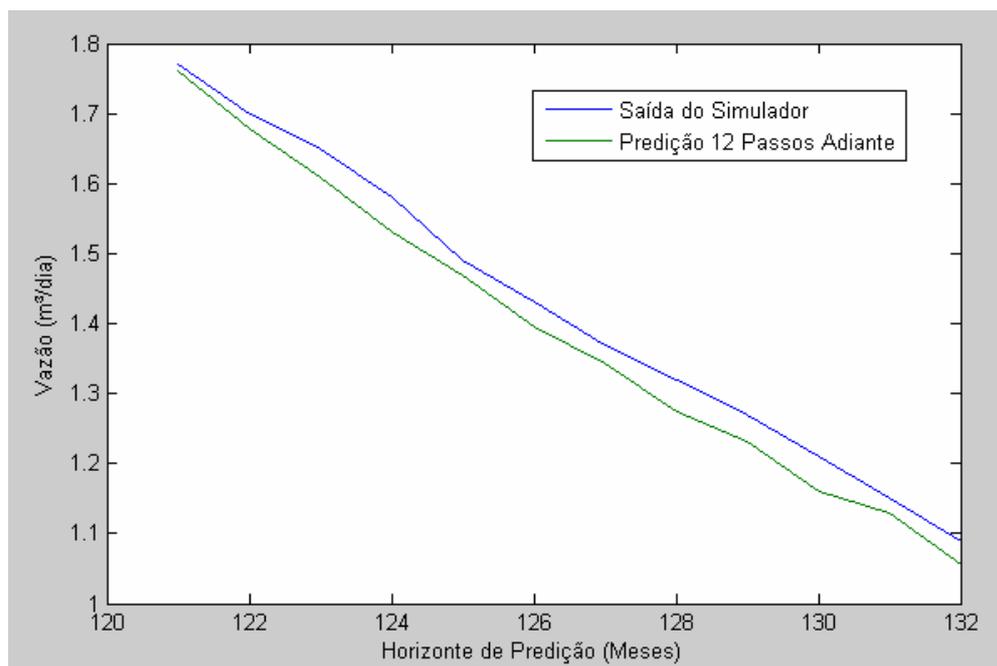
**Figura 6.21.** Treinamento para a curva de vazão de petróleo com a vazão de injeção variada



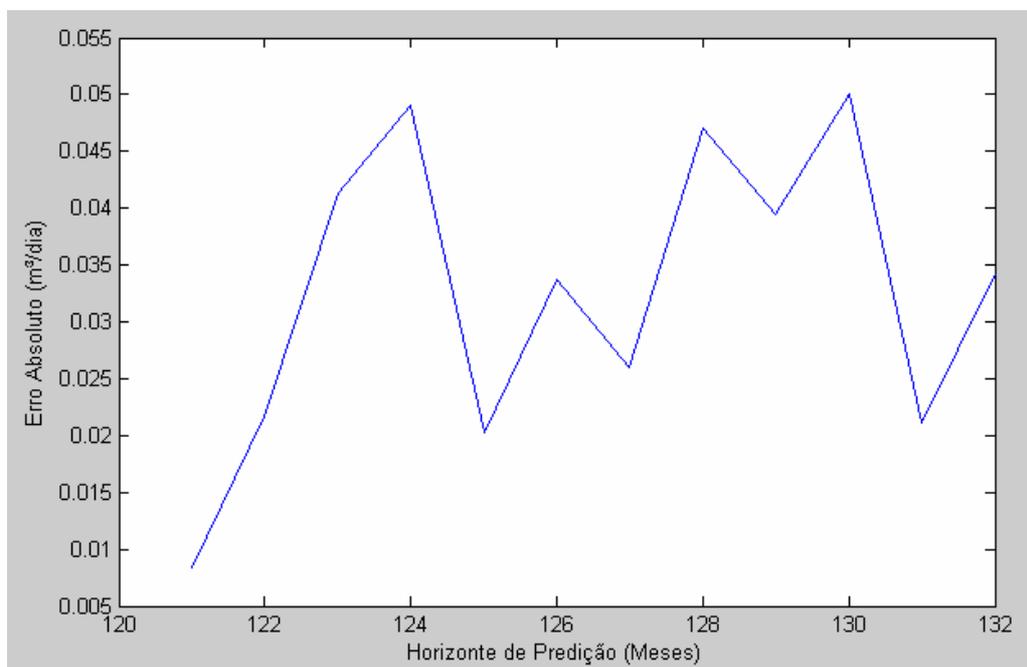
**Figura 6.22. Sinal erro de treinamento da vazão de petróleo com a vazão de injeção variada**

Na Figura 6.23 é ilustrado o gráfico utilizado para analisar a predição de passo simples com um número de 12 passos adiante, realizada pela rede neural para a vazão de petróleo. Este gráfico mostra os sinais de saída do simulador e da rede NARX utilizada como preditor de passo simples. O sinal do preditor é representado pela linha verde, enquanto o sinal gerado pela saída do simulador é representado pela linha azul.

A Figura 6.24 corresponde ao gráfico do erro de predição. Foi verificado que para o gráfico da predição da vazão, não foi apresentado erro com valor acima de 10% em relação ao sinal do simulador para um número de 12 passos adiante, ou 12 meses. Para simulações com um número de passos adiante maior que 12, houve um erro maior que 10%.



**Figura 6.23.** Sinal da vazão de petróleo obtido pela predição de 12 passos



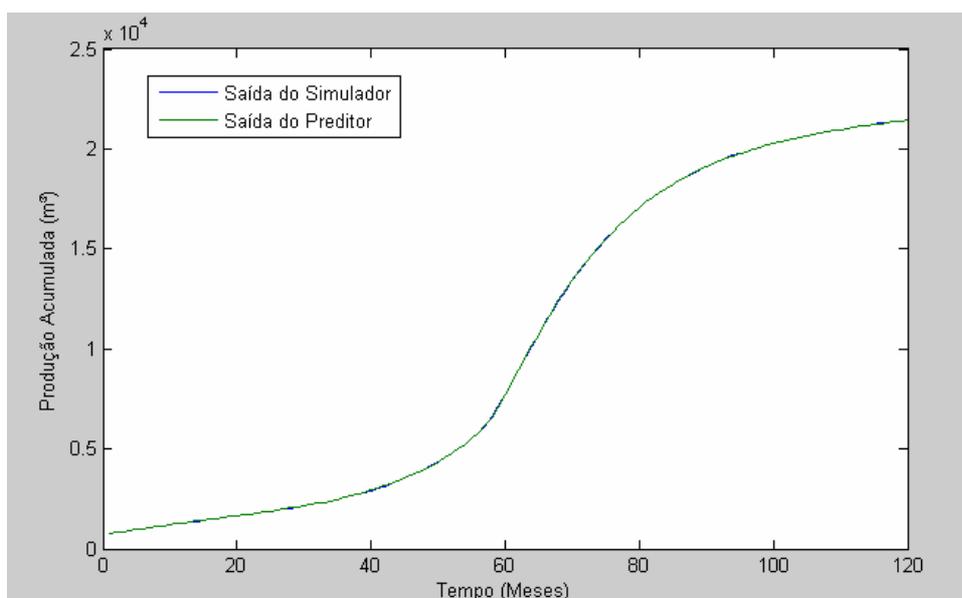
**Figura 6.24.** Sinal erro de predição para a vazão de 12 passos

Foi observado nos gráficos de treinamento das curvas de produção acumulada e de vazão que o pico do erro entre a saída do simulador e da rede neural se dá justamente no ponto de

inflexão dessas curvas. Para minimizar esse efeito uma solução seria aumentar o número de dados para o treinamento da rede.

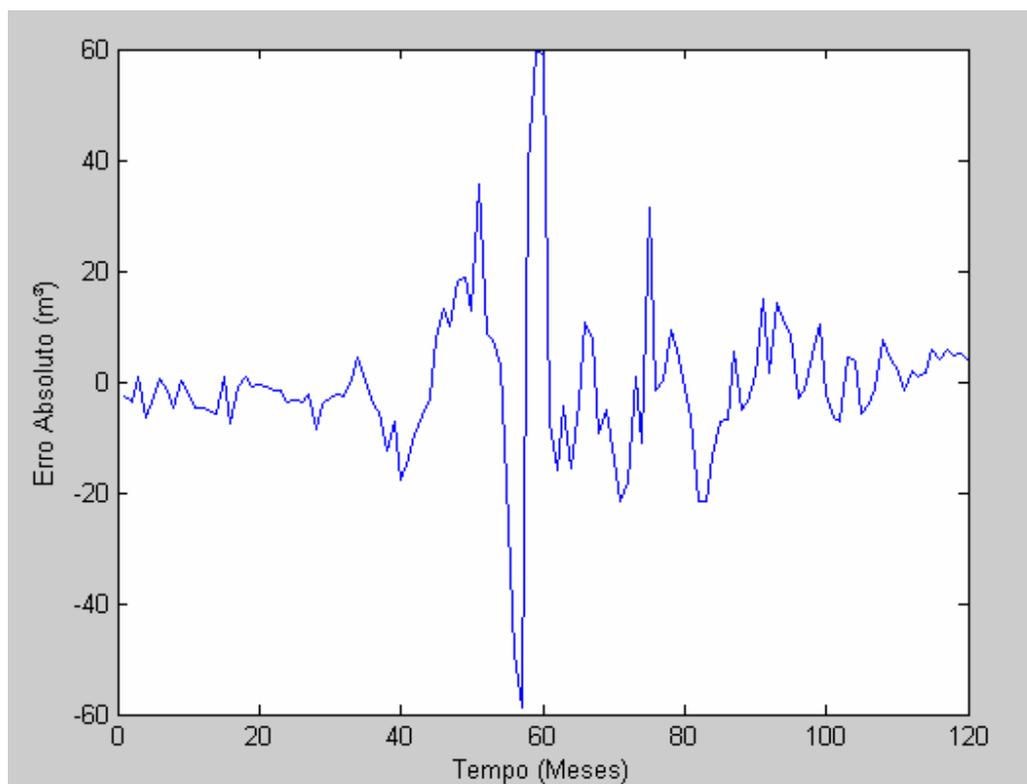
### 6.2.2 Predição para o Regressor de Saída com uma Memória de Linha de Atraso de Ordem 10

A Figura 6.25 ilustra a curva de treinamento da rede neural com a curva do simulador para a produção acumulada de petróleo. O algoritmo de Levenberg-Marquardt foi utilizado para o processo de aprendizado. O sinal azul representa o simulador, enquanto que a rede neural é representada pelo sinal verde. O conjunto de treinamento tem os dados dos 10 primeiros anos da simulação, ou seja, 120 meses



**Figura 6.25. Treinamento para a curva de produção acumulada**

A Figura 6.26 corresponde ao erro obtido no treinamento da rede neural. O erro para o treinamento da rede pode ser considerado baixo, pois este ficou inferior a  $65 \text{ m}^3$ , e a produção acumulada ao final dos 120 meses atinge mais de  $20.000 \text{ m}^3$  de petróleo.



**Figura 6.26. Sinal erro de treinamento da produção acumulada**

Na Figura 6.27 é ilustrado o gráfico utilizado para analisar a predição de passo simples com 12 passos adiante, realizada pela rede neural para a produção acumulada de petróleo. Este gráfico mostra os sinais de saída do simulador e da rede NARX utilizada como preditor de passo simples. O sinal do preditor é representado pela linha verde, enquanto o sinal gerado pela saída do simulador é representado pela linha azul.

A Figura 6.28 corresponde ao gráfico do erro de predição. Foi verificado que para o gráfico da predição da produção acumulada não foi apresentado um erro com valor acima de 10% em relação ao sinal do simulador para um número de 12 passos adiante, ou 12 meses.

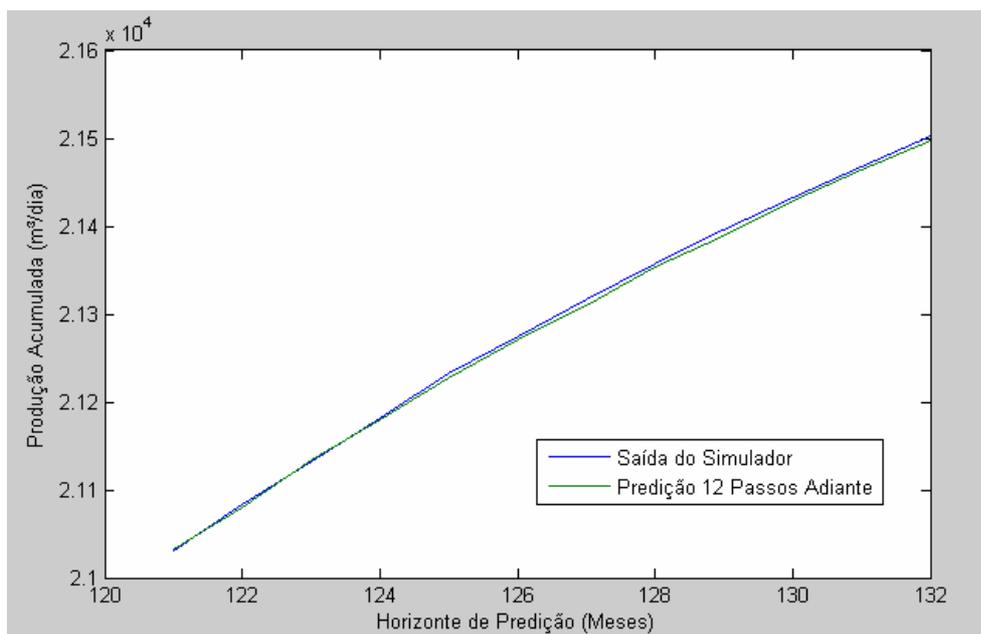


Figura 6.27. Sinal da produção acumulada obtido pela predição de 12 passos

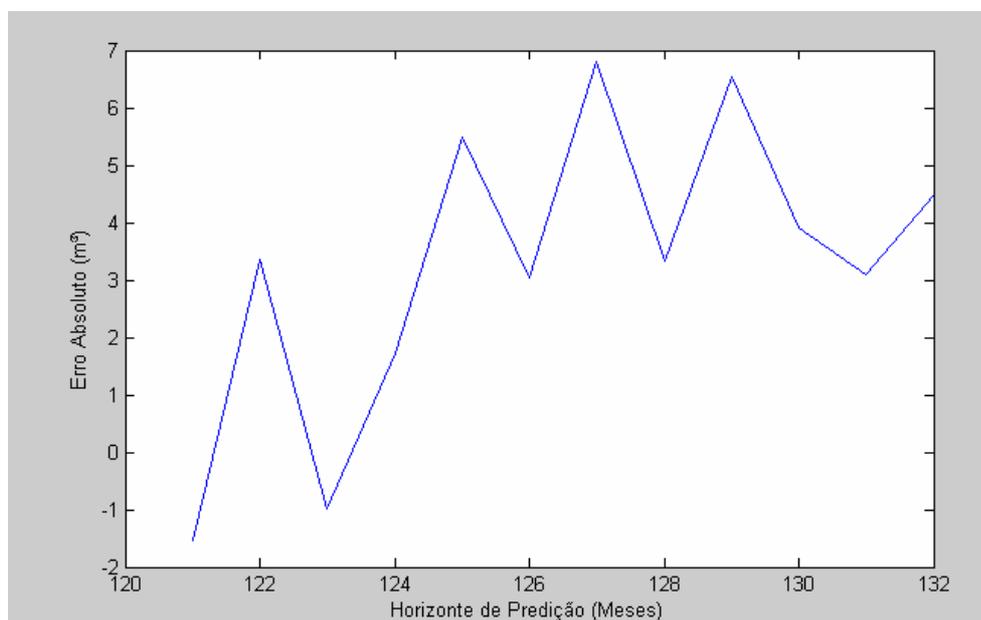
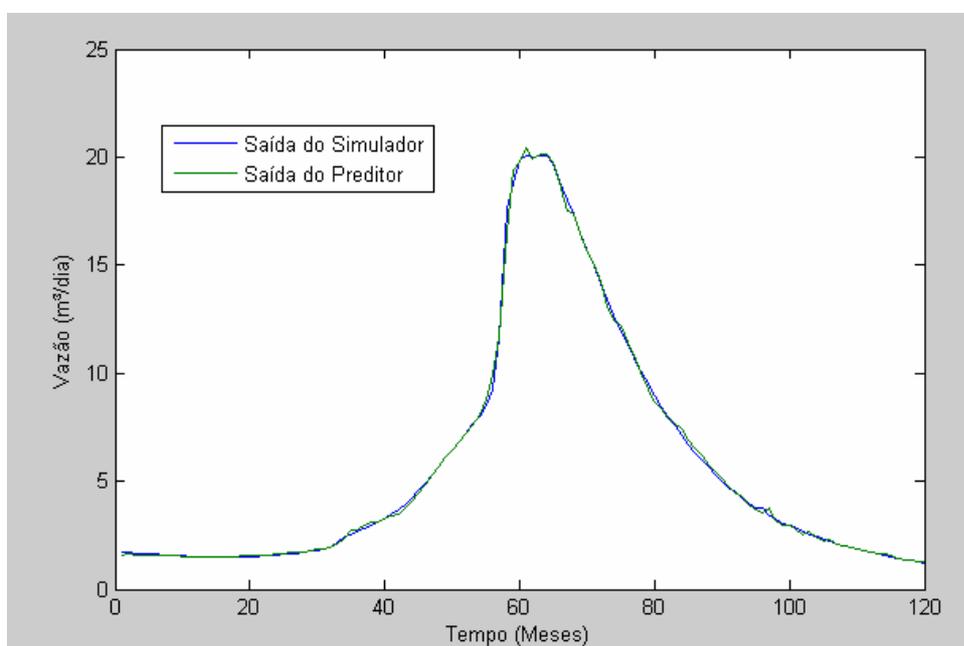


Figura 6.28. Sinal erro de predição para a produção acumulada de 12 passos

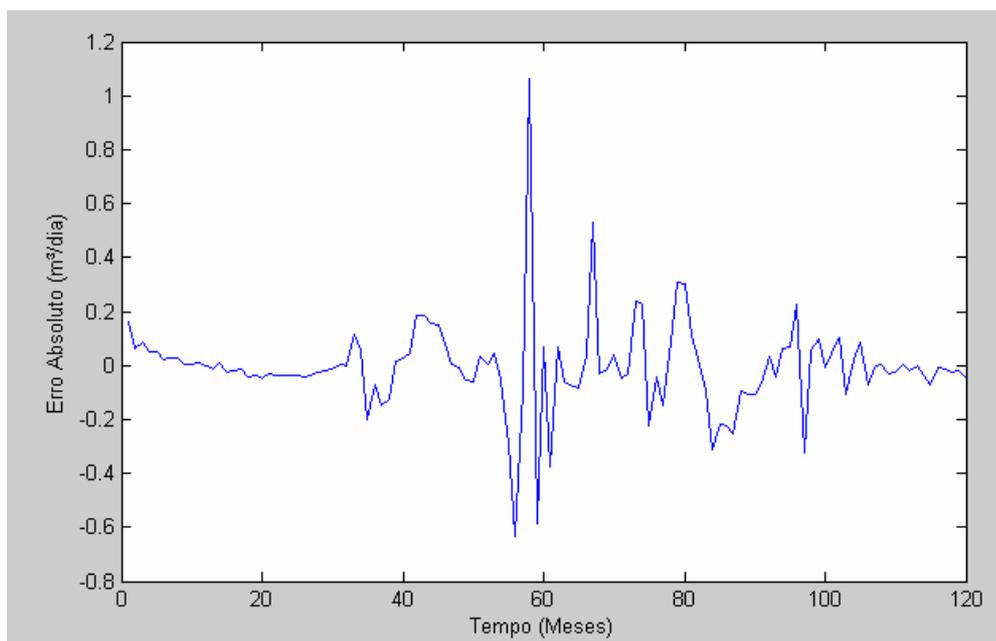
Da mesma maneira com que foi feita a curva de produção acumulada, foram realizadas as mesmas simulações com a curva de vazão. Esta apresentou um erro um pouco maior em relação à curva de produção acumulada devido à própria tendência da curva.

A Figura 6.29 ilustra a curva de treinamento da rede neural com a curva do simulador para a vazão de petróleo. O algoritmo de Levenberg-Marquardt foi utilizado para o processo de aprendizado. O sinal azul representa o simulador, enquanto que a rede neural é representada pelo sinal verde. O conjunto de treinamento tem os dados dos 10 primeiros anos da simulação, ou seja, 120 meses.

A Figura 6.30 corresponde ao erro obtido no treinamento da rede neural. O erro para o treinamento da rede pode ser considerado baixo, pois esse não apresentou valores consideráveis em relação à quantidade gerada.



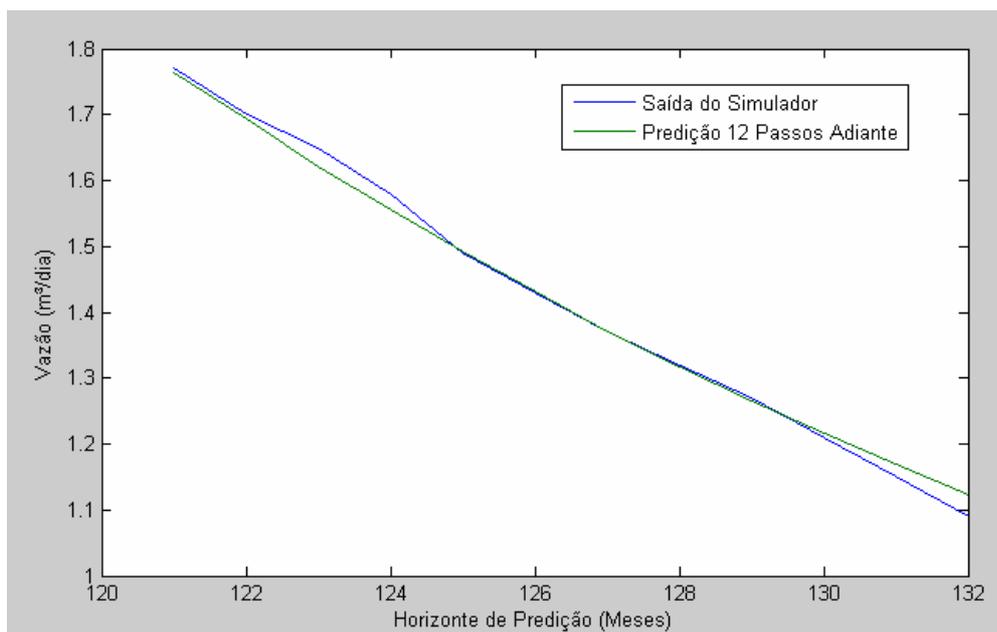
**Figura 6.29. Treinamento para a curva de vazão**



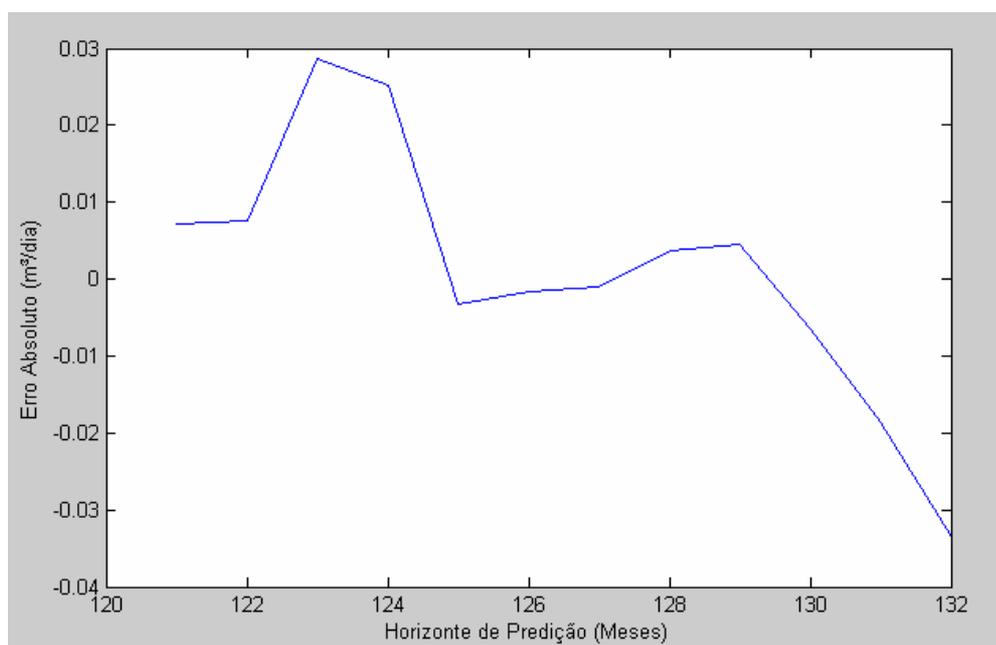
**Figura 6.30. Sinal erro de treinamento da vazão**

Na Figura 6.31 é ilustrado o gráfico utilizado para analisar a predição de passo simples com 12 passos adiante, realizada pela rede neural para a vazão de petróleo. Este gráfico mostra os sinais de saída do simulador e da rede NARX utilizada como preditor de passo simples. O sinal do preditor é representado pela linha verde, enquanto o sinal gerado pela saída do simulador é representado pela linha azul.

A Figura 6.32 corresponde ao gráfico do erro de predição. Foi verificado que para o gráfico da predição da vazão, não foi apresentado erro com valor acima de 10% em relação ao sinal do simulador para um número de 12 passos adiante, ou 12 meses. Para simulações com um número maior que 12 passos adiante, houve um erro maior que 10%.



**Figura 6.31.**Sinal da vazão obtido pela predição de 12 passos



**Figura 6.32.**Sinal erro de predição para a vazão com 12 passos

Foi observado nos gráficos de treinamento das curvas de produção acumulada e de vazão que o pico do erro entre a saída do simulador e da rede neural se dá justamente no ponto de inflexão dessas curvas. Para minimizar esse efeito uma solução seria aumentar o número de dados para o treinamento da rede.

Nas Tabelas 6.1, 6.2, 6.3 e 6.4 são apresentados os erros médios quadráticos encontrados pelas simulações realizadas tanto para a situação em que os parâmetros vazão de injeção de vapor, intervalo de completação e título de vapor são constantes, tabelas 6.1 e 6.2, quanto para a situação em que a vazão de injeção de vapor é variável, tabelas 6.3 e 6.4.

Nas simulações de predição, foi verificado que os erros médios quadráticos ficaram menores na situação em que vazão de injeção de vapor variava, quando se observava o mesmo número de passos adiante.

**Tabela 6.1. Erros observados no período de treinamento e de predição para uma memória de linha de atraso de ordem 2**

| <b>Simulação</b>                              | <b>Erro Médio Quadrático (%)</b> |
|---|----------------------------------|
| Treinamento da Produção Acumulada de Petróleo | 0,8643                           |
| Predição da Produção Acumulada de Petróleo    | 0,0295                           |
| Treinamento da Vazão de Petróleo              | 0,231                            |
| Predição da Vazão de Petróleo                 | 0,0083                           |

**Tabela 6.2. Erros observados no período de treinamento e de predição para uma memória de linha de atraso de ordem 10**

| <b>Simulação</b>                              | <b>Erro Médio Quadrático(%)</b> |
|---|---------------------------------|
| Treinamento da Produção Acumulada de Petróleo | 0,7403                          |
| Predição da Produção Acumulada de Petróleo    | 0,1932                          |
| Treinamento da Vazão de Petróleo              | 0,122                           |
| Predição da Vazão de Petróleo                 | 0,0054                          |

**Tabela 6.3. Erros observados no período de treinamento e de predição de memória de linha de atraso de ordem 2**

| <b>Simulação</b>                              | <b>Erro Médio Quadrático (%)</b> |
|---|----------------------------------|
| Treinamento da Produção Acumulada de Petróleo | 0,8991                           |
| Predição da Produção Acumulada de Petróleo    | 0,0128                           |
| Treinamento da Vazão de Petróleo              | 0,0438                           |
| Predição da Vazão de Petróleo                 | 0,0046                           |

**Tabela 6.4. Erros observados no período de treinamento e de predição de memória de linha de atraso de ordem 10**

| <b>Simulação</b>                              | <b>Erro Médio Quadrático (%)</b> |
|---|----------------------------------|
| Treinamento da Produção Acumulada de Petróleo | 0,916                            |
| Predição da Produção Acumulada de Petróleo    | 0,0762                           |
| Treinamento da Vazão de Petróleo              | 0,1507                           |
| Predição da Vazão de Petróleo                 | 0,0021                           |

---

**CAPÍTULO VII:**

*Conclusões e Recomendações*

---

## **7 Conclusões e Recomendações**

Este trabalho teve como objetivo estudar um método de técnicas inteligentes, as redes neurais, junto com ferramentas da engenharia de reservatórios para tentar produzir soluções mais eficientes na predição de produção de petróleo.

Foi implementado um preditor, baseado em uma rede neural recorrente, utilizado para reproduzir as saídas do simulador. Os resultados obtidos demonstraram a capacidade preditiva do algoritmo e se mostraram satisfatórias, tanto na situação em que os parâmetros de entrada (vazão de injeção, título de vapor e intervalo de completação) são constantes quanto na situação em que o valor da vazão de injeção é alterada para a metade ao longo de sua dinâmica, sendo esta última situação com um melhor desempenho de predição em relação à primeira.

Com a predição de passo simples pode-se concluir que o preditor neural tem capacidade de reproduzir o comportamento do simulador ao longo do tempo.

As situações testadas se mostraram eficientes na modelagem do problema, permitindo bons resultados de previsão de produção. A utilização de uma memória de linha de atraso de ordem 2 forneceu resultados similares aos obtidos com memória de linha de atraso de ordem 10, sugerindo que a memória de linha de atraso de ordem 2 já se constitui em uma boa aproximação para este problema.

Este bom resultado pode sugerir o uso de redes neurais como uma ferramenta adicional às já atualmente utilizadas curvas de declínio e simulação numérica ou ainda em situações que essas ferramentas são de difícil utilização.

Como trabalhos futuros, esta metodologia pode ser empregada na implementação de problemas de inteligência artificial, como tomadas de decisão, além de situações práticas e de grande porte.

---

## **Referências**

---

## Referências

- ALMEIDA, L. F. et al., *Evolutionary Optimization of Smart–Wells Control Under Technical Uncertainties*. Society of Petroleum Engineers – 107872. Buenos Aires, Argentina, 2007.
- BARBOSA, A. H.; FREITAS, M. S. R.; NEVES, F. A. Confiabilidade Estrutural Utilizando o Método de Monte Carlo e Redes Neurais. *Rev. Esc. Minas*, vol.58, n. 3, pp. 247-255, 2005.
- CMG, Computer Modelling Group Ltda. Guia para el usuario. Steam, Thermal and Advanced Reservoir Simulator – STARS. Versão 2007.11, Calgary-Alberta-Canadá.
- EMERICK, A. A.; PORTELLA, R.C.M., *Production Optimization With Intelligent Wells*. Society of Petroleum Engineers – 107261. Buenos Aires, Argentina, 2007.
- GOMES, D.T. *Redes Neurais Recorrentes para Previsão de Séries Temporais de Memórias Curta e Longa*. Dissertação (Mestrado), Universidade Estadual de Campinas, Campinas, SP, 2005.
- HAGAN, M. T.; MENHAJ, M. B. Training Feedforward Networks with the Marquardt Algorithm. *IEEE Transactions on Neural Networks*, vol. 5, n.5, pp. 989-993, 1994.
- HAYKIN, S. *Redes Neurais: Princípios e Prática*, 2. ed. Porto Alegre: Bookman, 2001.
- HOLLAND, J. et al., *Utilizing the Value of Continuously Measured Data*. Society of Petroleum Engineers – 90404. Houston, USA, 2004.
- JOHNSTONE, S. et al., *Implementing Intelligent Well Completion in Brown Field Development*. Society of Petroleum Engineers – 77657. San Antonio, USA, 2002.
- KROME, J.; MATSON, J., *Proper Project Selection of Real-Time Management Approaches*. Society of Petroleum Engineers – 106927. Houston, USA, 2007.

- LOURAKIS, M. *A Brief Description of the Levenberg-Marquardt Algorithm*. Institute of Computer Science. Crete, Greece, 2005.
- MEDEIROS, J.P. de. *Estudo e Implementação de Algoritmos Inteligentes para Detecção e Classificação de Falhas na Medição de Gás Natural*. Dissertação (Mestrado em Ciência e Engenharia de Petróleo) – Centro de Tecnologia, Programa de Pós-Graduação em Ciência e Engenharia de Petróleo, Universidade Federal do Rio Grande do Norte, Natal, 2009.
- MENEZES, J. M. P. *Redes Neurais Dinâmicas para Predição e Modelagem Não-Linear de Séries Temporais*. Dissertação (Mestrado em Engenharia de Teleinformática) – Programa de Pós-Graduação em Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2006.
- MEUM, P. et al., *Optimization of Smart Well Production Through Nonlinear Model Predictive Control*. Society of Petroleum Engineers 112100. Amsterdam, The Netherlands, 2008.
- MUELLER, A. *Uma Aplicação de Redes Neurais Artificiais na Previsão do Mercado Acionário*. Dissertação (Mestrado), Universidade Federal de Santa Catarina, Florianópolis, 1996.
- PAINO, W. et al., *Using Intelligent Well Technology to Define Reservoir Characterization and Reduce Uncertainty*. Society of Petroleum Engineers 88533. Perth, Australia, 2004.
- PANDA, M. N.; CHOPRA, A. K. *An Integrated Approach to Estimate Well Interactions*. Society of Petroleum Engineers 39563. Nova Deli, India, 1998.
- PRINCIPE, J.C.; KUO. J. Dynamic Modelling of Chaotic Time Series with Neural Networks. *Advances in Neural Information Processing Systems* 7, p. 311-318, 1995.
- ROSA, A. J.; CARVALHO, R. de S.; XAVIER, J. A. D. *Engenharia de reservatórios de petróleo*, 1. ed., Rio de Janeiro: Interciência, 2006.

SILVA Jr, M. F.; PORTELLA, R.C.M.; IZETTI, R.G.; CAMPOS, S.R.V., *Technologies Trials of Intelligent Field Implementation in Carmopolis Field*. Society of Petroleum Engineers 95517. Dallas, USA, 2005.

SILVA, L. C. F. da. *Inteligência Computacional para Predição de Produção de Reservatórios de Petróleo*. Tese (Doutorado em Engenharia Civil) – COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.

SOARES, P. P. S.; N, JURANDIR. Aplicação de uma Rede Neural *Feedforward* com Algoritmo de Levenberg - Marquardt para Classificação de Alterações do Segmento ST do. Eletrocardiograma. In: IV CONGRESSO BRASILEIRO DE REDES NEURAIS, 07, 1999, São José dos Campos. pp. 384-389.

STUNDNER, M.; AL-THUWAINI, J. S., *How Data-Driven Modeling Methods Like Neural Networks Can Help to Integrate Different Types of Data into Reservoir Management*. Society of Petroleum Engineers 68163. Bahrain, 2001.

THOMAS, J.E. et al. *Fundamentos de Engenharia de Petróleo*, 2ª ed. Rio de Janeiro: Interciência , 2001.

WEISS, W. W.; BALCH, R. S.; STUBBS, B. A., *How Artificial Intelligence Methods Can Forecast Oil Production*. Society of Petroleum Engineers 75143. Tulsa, USA, 2002.

YETEN, B.; DURLOFSKY, L. J.; AZIZ, K., *Optimization of Smart Well Control*. Society of Petroleum Engineers 79031. Calgary, Canada, 2002.

<http://www.mathworks.com> acesso em 31 de maio de 2009.

<http://www.petrobras.com.br/> acesso em 10 de fevereiro de 2009.

<http://www.anp.gov.br/> acesso em 13 de junho de 2009.