



**Alvaro Gustavo Talavera Lopez**

**Controle Preditivo com Aprendizado por Reforço  
para Produção de Óleo em Poços Inteligentes**

**Dissertação de Mestrado**

Dissertação apresentada como requisito parcial para  
obtenção do grau de Mestre pelo Programa de Pós-  
graduação em Engenharia Elétrica do Departamento  
de Engenharia Elétrica da PUC-Rio.

Orientadora: Prof. Marley Maria Bernardes Rebuzzi Vellasco

Rio de Janeiro  
Abril de 2010



**Alvaro Gustavo Talavera Lopez**

**Controle Preditivo com Aprendizado por  
Reforço para Produção de Óleo em Poços  
Inteligentes**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica do Centro Técnico Científico da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

**Profa. Marley Maria Bernardes Rebuzzi Vellasco**  
Orientadora  
Departamento de Engenharia Elétrica – PUC-Rio

**Profa. Luciana Faletti Almeida**  
CEFET-RJ

**Profa. Karla Tereza Figueiredo Leite**  
Departamento de Engenharia Elétrica – PUC-Rio

**Prof. José Eugenio Leal**  
Coordenador Setorial do Centro Técnico Científico – PUC-Rio

Rio de Janeiro, 14 de abril de 2010

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

### **Alvaro Gustavo Talavera Lopez**

Graduado Engenheiro Eletronico pela Universidad Católica de Santa Maria (UCSM) em 2003. Mestrado em Engenharia Elétrica, área de concentração Métodos de apoio à Decisão, pela Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio) em 2010.

#### Ficha Catalográfica

Talavera Lopez, Alvaro Gustavo

Controle preditivo com aprendizado por reforço para produção de óleo em poços inteligentes / Alvaro Gustavo Talavera Lopez ; orientadora: Marley Maria Bernardes Rebuzzi Vellasco. – 2010.  
113 f. : il. (color.) ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2010.  
Inclui bibliografia

1. Engenharia elétrica – Teses. 2. Controle preditivo. 3. Aprendizado por reforço. 4. Redes neurais artificiais. 5. Proxies. 6. Reservatórios petrolíferos. 7. Campos Inteligentes. I. Vellasco, Marley Maria Bernardes Rebuzzi. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. III. Título.

CDD: 621.3

A Deus, por cumprir sua vontade.

## Agradecimentos

À CAPES, CNPq e a PUC - Rio pela concessão da bolsa e dos auxílios que tornaram possível a realização deste trabalho.

À minha orientadora, Marley Maria Bernardes Rebuzzi Vellasco, pela oportunidade e confiança desde o primeiro dia.

Aos amigos que contribuíram ao desenvolvimento desse trabalho: Yvan Tupac, Juan Lazo, Cleomar Pereira, Bruno Messer e Luciana Faletti. A uma grande amiga Susana Modiano pelo seu sincero apoio e amizade, a Jaime Grande pela sua ajuda e amizade na chegada neste país. A meus amigos Sergio Duarte, Jefferson Ferraz e Leonardo Forero.

À minha família, em especial a minha mãe Margarita Lopez de Almeida pelo seu amor, apoio e suporte em todo momento; a um grande amigo como é meu pai Gustavo Talavera Prado; ao meu querido irmão Ivan, minha cunhada Lulu e meus maravilhosos sobrinhos Rodrigo e Alejandro. A Marina Ajul por estar no meu coração e comigo.

Aos amigos do ICA por seu contínuo apoio e colaboração.

## Resumo

Talavera, Alvaro Lopez; Vellasco, Marley M. B. Rebuzzi **Controle Preditivo com Aprendizado por Reforço para Produção de Óleo em Poços Inteligentes**. Rio de Janeiro, 2010. 113p. Dissertação de Mestrado - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Este trabalho apresenta a modelagem e o desenvolvimento de uma metodologia baseada em Controle com Modelo Preditivo (MPC) aplicada ao controle da produção de óleo em um reservatório de petróleo com poços produtores e injetores já existentes. A estratégia MPC utiliza um modelo de aprendizado de máquina, baseado em Aprendizado por Reforço (*Reinforcement Learning*), como método de busca da política ótima de controle. Os experimentos se realizaram em um reservatório petrolífero sintético com atuadores que são 3 válvulas de injeção de água. Assim, a atuação é realizada através das taxas de injeção de água para determinados intervalos de tempo. As variáveis de saída do campo são: Pressão média do reservatório, taxa diária de produção de óleo, gás, água e *water cut* na produção. A previsão dessas variáveis é realizada mediante a utilização de uma *proxy*, a qual é um modelo identificado da planta implementado utilizando redes neurais. Os resultados obtidos indicam que o modelo proposto é capaz de controlar a produção de óleo mesmo com perturbações no poço produtor, para diferentes valores de referência de produção de óleo.

## Palavras-chave

Controle Preditivo; Aprendizado por Reforço; Redes Neurais Artificiais; Proxies; Reservatórios Petrolíferos; Campos Inteligentes.

## Abstract

Talavera, Alvaro Lopez; Vellasco, Marley M. B. Rebuzzi (Advisor)  
**Predictive Control with Reinforcement Learning for Oil Production in Smart Wells.** Rio de Janeiro, 2010. 113p. MSc. Dissertation - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

This work presents the modeling and development of a methodology based on Model Predictive Control with (MPC) applied to the control of oil production in an oil reservoir with existing production and injection wells. The MPC strategy is based on a machine learning model - Reinforcement Learning (Reinforcement Learning) - as the method of searching the optimal control policy. The experiments were carried out in an oil reservoir with synthetic valve actuators that are 3 water injections. Therefore, the action is performed by injecting water rates for certain time intervals. The output variables of the field are: average pressure of the reservoir, the daily production of oil, gas, water and water cut. The forecast of these variables is accomplished by a proxy, which is a model identification of the plant implemented by neural networks. The results indicate that the proposed model is capable of controlling oil production even with disturbances in the producing well, for different reference values for oil production.

## Keywords

Predictive Control; Reinforcement Learning; Artificial Neural Networks; Proxies; Petroleum Reservoir; Smart Wells.

## Sumário

1 Introdução	13
1.1. Motivação	13
1.2. Objetivos	16
1.3. Descrição do trabalho	17
1.4. Estrutura da Dissertação	18
2 Aprendizado de Máquina	20
2.1. Tipos de Aprendizado	21
2.1.1. Aprendizado Supervisionado	21
2.1.2. Aprendizado por Reforço	22
2.1.3. Aprendizado não Supervisionado	22
2.2. Redes Neurais	23
2.2.1. Redes Multilayer Perceptron	24
2.2.2. Algoritmo de Aprendizado Backpropagation	25
2.3. Aprendizado por Reforço	29
2.3.1. Processos Markovianos	31
2.3.2. Métodos de Aprendizado por Reforço	34
3 Controle Preditivo Aplicado a Poços Inteligentes	42
3.1. Introdução	42
3.2. Controle Preditivo: Abordagem Markoviano	42
3.2.1. Controle Automático	42
3.2.2. Controle Preditivo	43
3.2.3. Controle Preditivo Neural	46
3.2.4. MPC no Processo de Decisão de Markov	48
3.2.5. MPC com Aprendizado por Reforço	52
3.3. Poços Inteligentes no Desenvolvimento de Campos Petrolíferos	53
3.3.1. Fundamentos de Simulação de Reservatórios	54
3.3.2. Poços Inteligentes	54
3.3.3. Estratégias de Controle	56



4 Proposta deMPC com Aprendizado por Reforço	57
4.1. Introdução	57
4.2. Modelo MPC-RL	57
4.2.1. Planta Estudada	58
4.2.2. Proxy do Reservatório	59
4.2.3. Configurações do RL e MPC	61
4.3. Algoritmo MPC-RL	63
5 Estudo de Caso	66
5.1. Reservatório Estudado	66
5.1.1. Sensibilidade do Reservatório	68
5.2. Resultados da Proxy de Reservatório	70
5.3. Seleção do valor das ações das válvulas	74
5.4. Resultados com e-greedy Modificado	76
5.5. Resultados com Distintos setpoint	77
5.6. Estudos Comparativos	80
5.6.1. Comparação MPC-RL com 1 passo a frente de Previsão	80
5.6.2. MPC-RL vs RL	84
5.7. MPC-RL Frente a Perturbações	86
6 Conclusões e Trabalhos Futuros	94
6.1. Conclusões	94
6.2. Trabalhos Futuros	95
Referências Bibliográficas	97
Apêndice	105

## Lista de Figuras

Figura 1 – Ciclo de gerenciamento de reservatórios.	14
Figura 2 – Modelo simples de um aprendizado de máquina.	20
Figura 3 – Diagrama de blocos do aprendizado supervisionado.	21
Figura 4 – Diagrama de blocos do aprendizado não supervisionado.	22
Figura 5 – Representação geral da arquitetura multilayer perceptron.	24
Figura 6 – Diagrama de um sistema básico de aprendizado por reforço.	30
Figura 7 – Algoritmo Q-Learning.	40
Figura 8 – Diagrama em blocos de um sistema em malha fechada.	43
Figura 9 – Estratégia do controle preditivo.	44
Figura 10 – Diagrama em bloco do controlador neural preditivo.	47
Figura 11 – Exemplo de completações de um poço horizontal Inteligente.	55
Figura 12 – Modelo MPC-RL proposto.	58
Figura 13 – Reservatório estudado.	59
Figura 14 – Proxy do reservatório.	60
Figura 15 – Configuração da Proxy proposta	61
Figura 16 – Algoritmo do $\varepsilon$ -greedy.	62
Figura 17 – Algoritmo proposto.	65
Figura 18 – Etapa de aplicação do conhecimento do agente RL.	65
Figura 19 – Produção de óleo – sem injeção até 360.	69
Figura 20 – Pressão média do reservatório – sem injeção até 360.	69
Figura 21 – Saída da pressão.	72
Figura 22 – Saída da produção de óleo.	72
Figura 23 – Saída de gás.	73
Figura 24 – Saída de água.	73
Figura 25 – Saída de <i>water-cu.t</i>	74
Figura 26 – Saída da produção de óleo no experimento 1.	75
Figura 27 – Saída da produção de óleo.	75
Figura 28 – Saída da produção de óleo utilizando e-greedy modificado.	76
Figura 29 – Saída da produção de óleo utilizando o conhecimento do MPC-RL.	77
Figura 30 – Configuração das válvulas.	77
Figura 31 – Saída da produção de óleo utilizando o conhecimento do MPC-RL.	78

Figura 32 – Configuração das válvulas.	78
Figura 33 – Saída da produção de óleo utilizando o conhecimento do MPC-RL.	79
Figura 34 – Saída Configuração das válvulas.	79
Figura 35 – Saída da produção de óleo do MPC-RL 1 - Treinamento.	80
Figura 36 – Configuração das válvulas do MPC-RL 1 - Treinamento.	81
Figura 37 – Saída da produção de óleo do MPC-RL 1.	81
Figura 38 – Saída da produção de óleo do MPC-RL 1 - 1000 episódios.	82
Figura 39 – Configuração das válvulas do MPC-RL 1- 1000 episódios.	83
Figura 40 – Saída da produção de óleo do MPC-RL 1 - 1500 episódios.	83
Figura 41 – Configuração das válvulas do MPC-RL 1 - 1500 episódios.	84
Figura 42 – Bloco do RL para o controle da produção de óleo.	84
Figura 43 – Saída da produção de óleo do RL com 100 episódios.	85
Figura 44 – Configuração das válvulas do RL com 100 episódios.	85
Figura 45 – Configuração do reservatório para as perturbações.	87
Figura 46 - Saída da produção de óleo frente a perturbação: Experimento 1.	88
Figura 47 – Pressão media frente a perturbação: Experimento 1.	88
Figura 48 – Configuração das válvulas do reservatório frente a perturbação.	89
Figura 49 - Saída da produção de óleo frente a perturbação: Experimento 2.	90
Figura 50 – Pressão media frente a perturbação: Experimento 2.	90
Figura 51 – Configuração das válvulas do reservatório frente a perturbação.	91
Figura 52 - Saída da produção de óleo frente a perturbação: Experimento 3.	92
Figura 53 – Pressão media frente a perturbação: Experimento 3.	92
Figura 54 – Configuração das válvulas do reservatório frente a perturbação.	93
Figura 55 Arquivos de entrada e saída do IMEX	107

## Lista de Tabelas

Tabela 1 – Configuração do agente RL.	61
Tabela 2 - Ações do agente RL.	63
Tabela 3 – Conhecimento do agente RL.	64
Tabela 4 – Testes de sensibilidade campo.	68
Tabela 5 – Métricas de erro da <i>proxy</i> .	71
Tabela 6 – Comparação dos treinamentos dos modelos simulados.	86
Tabela 7 – Tipos de dados existentes no arquivo .DAT	107