

1 Introdução

1.1. Motivação

Na engenharia de reservatórios (Crichlow, 1977), otimizar a exploração de um reservatório petrolífero significa desenvolver uma estratégia que permita produzir a maior quantidade de hidrocarboneto possível dentro dos limites físicos e econômicos existentes. Dois fatores determinantes do nível de produção são: o sistema de exploração a ser instalado e o reservatório geológico existente.

O gerenciamento de reservatórios é um processo recorrente (Saputelli, 2003), no qual o operador de campo de petróleo utiliza dados, conhecimento e informação para otimizar a rentabilidade do reservatório ou algum objetivo declarado sobre o desempenho do campo petrolífero. O gerenciamento de reservatórios tem como objetivo integrar diversas metodologias da área petrolífera. Na Figura 1 (Saputelli, 2003) pode-se notar a integração das diferentes áreas de conhecimento aplicadas ao setor petrolífero, como: Atualização do Modelo; Caracterização no subsolo; Otimização de produção; Perfurações, construção e operação; Monitoração e Controle.

Neste trabalho propõe-se abordar uma dessas áreas desse sistema de gerenciamento integrado, que está relacionada com o controle da produção de óleo. A motivação para abordar este item é a necessidade de implementar uma estratégia de controle devido à existência de poços injetores e produtores instrumentados, mais conhecidos como poços inteligentes, que possibilita o estabelecimento de um ponto de operação (produção de óleo) a partir das medições tomadas nos sensores de pressão e fluxo e as ações tomadas nos atuadores, constituindo um problema de controle. O controle da produção de óleo tem sido investigado por muitos centros de pesquisa em petróleo no mundo devido ao grande investimento inicial na construção de um reservatório petrolífero. O bom desempenho no controle da produção de óleo é um fator decisivo na rentabilidade do reservatório (Saputelli, 2003). O desenvolvimento da

instrumentação digital em poços de petróleo, também chamados de poços inteligentes, favoreceu o gerenciamento de reservatórios. Este avanço tornou possível utilizar alguns benefícios da teoria de controle em malha fechada (Jansen, Douma, *et al.*, 2009) aplicando-os na otimização e controle de produção de óleo, como por exemplo, a teoria de controle ótimo, que é a mais empregada. Trabalhos como (Nikolaou, Cullick e Saputelli, 2006) estudaram a aplicação da teoria de controle ótimo e de horizonte móvel para otimizar a produção de óleo em um reservatório. Outros trabalhos como (Sarma, Durlofsky, *et al.*, 2006), (Sarma, 2006), (Chen, Oliver e Zhang, 2009) e (Wang, Gaoming e Reynolds, 2009) combinam a teoria de controle ótimo e um algoritmo para a atualização do modelo para a otimização da produção em tempo real.

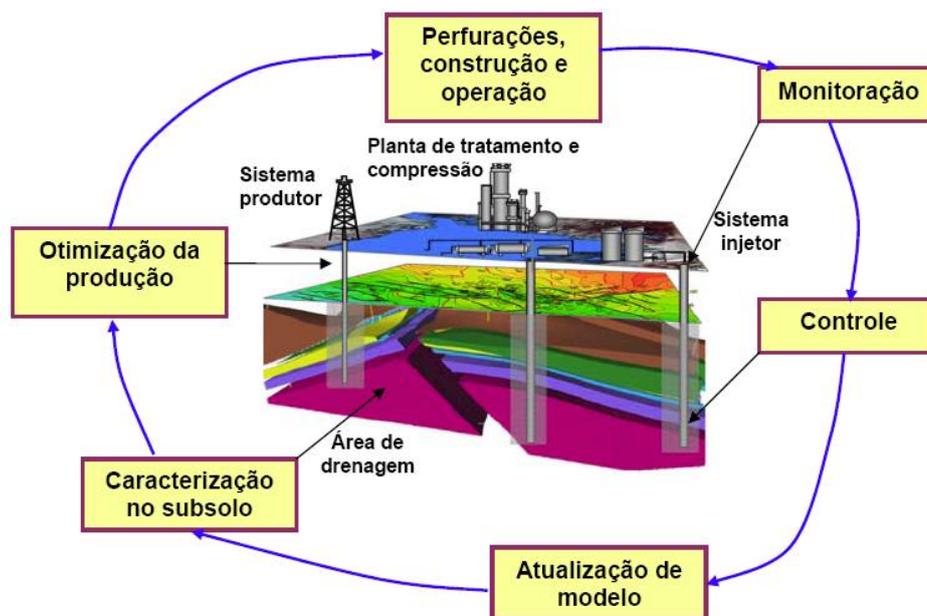


Figura 1 – Ciclo de gerenciamento de reservatórios.

Técnicas de inteligência computacional também têm sido aplicadas ao gerenciamento de reservatórios (Mohaghegh, 1995) (Guyaguler, 2002) (Yeten, 2003) (Mohaghegh, 2005) (Túpac, 2005) (Faletti, 2007) (Messer, 2009). As principais são: algoritmos genéticos (Goldberg, 1989) e redes neurais (Haykin, 2007). Em (Yeten, 2003), por exemplo, são utilizados algoritmos genéticos para a otimização da produção de óleo em poços inteligentes e redes neurais para a construção de uma função de aproximação (*Proxy*) do reservatório; Em (Faletti, 2007) também são utilizados algoritmos genéticos para formular uma estratégia de

controle considerando incertezas técnicas (falhas nas válvulas) e geológicas. Em (Túpac, 2005) propõe-se a utilização de algoritmos genéticos para determinar a alternativa de produção que maximize o Valor Presente Líquido (VPL) e em (Messer, 2009) são utilizados algoritmos evolucionários para resolver o problema de posicionamento de poços de diferentes tipos: verticais, direcionais, horizontais e multilaterais. Redes neurais têm sido empregadas com sucesso na obtenção de modelos de reservatórios (Mohaghegh, 1995) (Mohaghegh, 2000), apresentando aplicações em construção de classificadores e caracterizações de reservatórios. Em (Almeida, Vellasco e Pacheco, 2007) (Almeida, 2008) construiu-se *proxies* de reservatório mediante o uso de redes neurais e de modelo híbrido neuro-fuzzy, denominado *Adaptive-Network-Based Fuzzy Inference System* (ANFIS) (Jang, Sun e Mizutani, 1997) (Jang e Sun, 1995).

Entretanto a maioria dos trabalhos encontrados na bibliografia literatura não considera um controle para um determinado *setpoint*, se limitando a maximizar o valor presente líquido (VPL) ou a taxa de produção de óleo. O benefício de se obter um controle em malha fechada é que se pode estender o tempo de vida de um reservatório. Trabalhos como (Saputelli, 2003) apresentam um controle preditivo baseado em modelo ou *Model Predictive Control* (MPC) (Camacho e Bordons, 1999) (Badgwell e Qin, 2001), o qual se refere a uma classe de algoritmos computacionais de controle que se baseia em um modelo explícito de processo para obter previsões da resposta futura da planta. O MPC é muito utilizado na indústria e, ultimamente, em aplicações na produção de óleo (Nikolaou, Cullick e Saputelli, 2006) por solucionar problemas em processos com retardo, com múltiplas variáveis de entrada e saída (MIMO), e admitir restrições na solução.

Um dos grandes desafios na construção de um MPC é o de obter modelos da planta (*proxy*) para que seja possível realizar previsões precisas do seu comportamento. No entanto, isso é uma tarefa complexa devido ao reservatório ser altamente não-linear, incerto e multivariável. Em (Saputelli, 2003) (Nikolaou, Cullick e Saputelli, 2006) (Saputelli, Nikolaou e Economides, 2003) as *proxies* são desenvolvidas como uma combinação de modelos lineares e não-lineares, e a minimização da função custo é feita mediante técnicas de programação quadrática (PQ) (Dostál, 2009). Porém, o emprego dessas estratégias de modelagem e a utilização de PQ são computacionalmente custosas.

Aprendizado por reforço (Sutton e Barto, 1998) ou *reinforcement learning* (RL), por sua vez, aprende uma estratégia de controle mediante sua interação com o ambiente (Proxy). RL consegue melhores resultados que PQ em situações onde não se tenha um modelo determinístico da planta e onde o grau de complexidade da planta seja elevado. Aprendizado por reforço tem como sua principal área de aplicação a área de controle de sistemas dinâmicos (Riedmiller, 1996) (Schoknecht e Riedmiller, 1999) (Doya, 2000) (Matarić, 1994) (Gerhardus ten Hagen, 2001) (Figueiredo, 2003).

A proposta deste trabalho é, portanto, utilizar aprendizado por reforço para resolver o problema de otimização de um MPC onde não se tem um modelo explícito da planta e o espaço de busca pode ser não-convexo. Além disso, o aprendizado por reforço aprende as políticas de controle ótimas; deste modo, para novas referências (*setpoints*) não será necessário executar novamente o otimizador da função custo.

No setor petrolífero encontra-se também a aplicação de RL através de programação dinâmica para a manutenção de tarefas (Aissani, Beldjilali e Trentesaux, 2009), mas não no controle da produção de óleo em um reservatório, que é fator decisivo na rentabilidade do reservatório conforme mencionado anteriormente.

1.2. Objetivos

O principal objetivo deste trabalho é a modelagem e a implementação de um sistema de controle MPC em malha fechada que permita controlar, de forma robusta, a produção de óleo ante perturbações ou falhas nas válvulas dos poços produtores de um reservatório e que possa aprender estratégias de controle para diferentes *setpoint*.

Deste modo, propõe-se um controle preditivo baseado em aprendizado por reforço que seja responsável por aprender uma estratégia de política ótima de controle que possa ser utilizada para atingir outros *setpoints* de forma eficiente. Para obter este aprendizado utilizou-se como aproximador de reservatório (*Proxy*), um modelo baseado em técnica computacional inteligente como as Redes

Neurais Artificiais do tipo *multi layer perceptron* (MLP), que apresentam bom desempenho como se descreveu na seção anterior.

1.3. Descrição do trabalho

Esta pesquisa foi elaborada nas seguintes etapas:

- Estudo sobre a área de exploração de petróleo, as características do desenvolvimento de reservatórios petrolíferos e poços inteligentes;
- Estudo sobre o simulador de reservatórios petrolíferos IMEX 2000, utilizado nos estudos de casos desenvolvidos;
- Estudo sobre controle preditivo baseado em modelo (MPC);
- Estudo de redes neurais artificiais para a construção de aproximadores, principalmente utilizando as redes *Multi-Layer Perceptron* (MPL) (Haykin, 2007) com algoritmo de aprendizado *Back Propagation*;
- Estudo de modelos de aprendizado por reforço para aplicação em controle em malha fechada;
- Modelagem e implementação do controle preditivo com aprendizado por reforço para o controle da produção de óleo; e
- Estudos de casos.

A seguir é apresentada uma breve descrição de cada uma das etapas realizadas.

O estudo sobre a área de gerenciamento de um reservatório petrolífero envolveu uma pesquisa bibliográfica sobre a área de reservatórios em geral, além da aplicação das técnicas de inteligência computacional na otimização e controle da produção de óleo.

O estudo sobre o simulador de reservatório IMEX foi de grande importância para a implementação deste trabalho. Esta etapa também abordou o estudo das configurações dos poços injetores e produtores do reservatório estudado. Além disso, esta etapa compreendeu o estudo sobre a integração do IMEX 2000 ao Matlab R2007.

O estudo do controle preditivo baseado em modelo, que é onde se fundamenta a plataforma de controle deste trabalho, envolveu a pesquisa do

estado da arte em controle preditivo linear e não-linear em aplicações na produção de petróleo. Realizou-se também uma pesquisa bibliográfica sobre a implementação de MPC utilizando técnicas de inteligência computacional.

O estudo de redes neurais para o desenvolvimento de *Proxies* do modelo do reservatório petrolífero concentrou-se nas redes *Multi-Layer Perceptron* (MLP) com algoritmo *Back Propagation*, por serem aproximadores universais (Cybenko, 1989). Na etapa de modelagem foram analisadas as variáveis mais relevantes (pressão, óleo, gás, água e *water-cut*) para a construção da rede.

Na etapa seguinte fez-se uma extensa pesquisa bibliográfica sobre os diferentes modelos de aprendizado por reforço. Apesar de não ter se encontrado aplicações de RL em predição de óleo, optou-se pelo algoritmo de aprendizado *Q-learning*, por ser ele um dos mais usados na literatura.

Na etapa de modelagem e implementação do MPC-RL, desenvolveu-se o controle preditivo baseado em modelo. O modelo da planta (IMEX) foi construído através de uma rede neural, de forma a se obter as previsões sobre a saída da planta. As redes neurais, além de serem aproximadores universais, têm um custo computacional bastante baixo, após a etapa de treinamento. Já o aprendizado por reforço se encarrega de maximizar a função custo, através do aprendizado da política ótima de controle.

Na etapa de estudo de casos foram realizados diversos experimentos, sobre um mesmo reservatório, com diferentes *setpoints* e frente a falhas no poço produtor.

1.4. Estrutura da Dissertação

Esta dissertação está dividida em cinco capítulos adicionais, conforme descrito a seguir.

O Capítulo 2 descreve a teoria de aprendizado de máquina, apresentando os tipos de aprendizado existentes e aprofundando-se nas redes neurais e nos modelos de aprendizado por reforço.

O Capítulo 3 descreve a técnica de controle preditivo baseado em modelo (MPC). O capítulo apresenta a técnica de controle MPC de horizonte finito com uma abordagem Markoviano, abrindo o caminho para a teoria de programação

dinâmica em processos markovianos. Em seguida, apresenta-se a teoria sobre aprendizado por reforço, relacionando-a com a teoria de programação dinâmica e justificando, assim, o modelo híbrido proposto. Por fim, descreve-se a teoria de poços inteligentes e de gerenciamento de reservatórios petrolíferos.

No Capítulo 4 apresenta-se o modelo híbrido proposto MPC-RL para o controle da produção de óleo. Nesse capítulo são abordadas características do reservatório estudado, a modelagem da *Proxy*, as configurações do controle preditivo e do aprendizado por reforço. Por último apresenta-se o funcionamento do algoritmo proposto explicando detalhadamente cada etapa.

No Capítulo 5 são apresentados todos os experimentos realizados sobre o reservatório descrito no capítulo anterior. Além disso, apresentam-se os estudos comparativos de MPC-RL com outras configurações do próprio modelo e com um aprendizado por reforço sem MPC.

Finalmente, no Capítulo 6, são apresentadas as conclusões e possíveis trabalhos futuros.