

6 Conclusões e Trabalhos Futuros

Neste capítulo são apresentadas as conclusões gerais e as possibilidades de continuação deste trabalho de pesquisa.

6.1. Conclusões

Este trabalho teve como objetivo central o desenvolvimento e a implementação de um modelo de controle preditivo com aprendizado por reforço MPC-RL. Aplicou-se tal modelo no controle da produção de óleo de um reservatório petrolífero. Para viabilizar o modelo MPC-RL foram utilizadas duas técnicas da inteligência computacional: redes neurais para a construção de um modelo aproximado do reservatório (*Proxy*) e aprendizado por reforço (RL) para encontrar a configuração ótima das válvulas para atingir o objetivo de controle.

O *Proxy* implementado cumpriu duas funções: a primeira de prever a resposta futura da planta no sentido de controle preditivo, e a segunda de ajudar ao ϵ -*greddy* a encontrar as ações ótimas.

O modelo MPC-RL apresentou bons resultados, controlando a saída da produção de óleo no poço produtor frente a outros *setpoints* que não fizeram parte do treinamento. Também se testou o modelo frente a perturbações (falhas) não previstas em camadas do poço produtor, apresentando igualmente boas respostas.

O modelo MPC-RL apresentou melhores resultados que o RL, isto devido a que o MPC-RL considera previsões da planta utilizando um *Proxy*. Essa estratégia permite ao controlador estimar como o sistema reagirá no futuro e fazer as modificações necessárias. Além disso, o custo computacional do RL é maior, devido à falta de um *Proxy* para acelerar o treinamento.

O modelo MPC-RL com previsão de três passos a frente apresenta melhores resultados que um MPC-RL com um passo a frente. Isso se deve ao fato de que o modelo MPC-RL considera o somatório acumulado das previsões no algoritmo de

aprendizado *Q-learning*, e assim, quanto mais somatórios acumulados, maior é o conhecimento do ambiente.

Uma vantagem considerável do modelo MPC-RL proposto é que não precisa rodar seu otimizador cada vez que se deseje controlar o processo em um novo *setpoint*. Ao contrário dos modelos MPC convencionais, o MPC-RL só utiliza a base de conhecimento proporcionada pelo RL. Esta é a vantagem principal de utilizar uma tecnologia de controle (MPC) e um aprendizado de máquina (RL).

Para fins de generalização, o modelo proposto utiliza o erro relativo do *setpoint* como o estado do aprendizado por reforço. Dessa maneira pode-se aproveitar o conhecimento do MPC-RL para outros *setpoints*.

Uma generalização no modelo é que o estado do aprendizado por reforço seja o erro relativo ou qualquer outra métrica mais geral possível, desta maneira pode-se aproveitar o conhecimento do MPC-RL para outros *setpoint*.

O modelo MPC-RL proposto pode ser aplicado a plantas não-lineares, com certo grau de complexidade, podendo ser multivariáveis, já que o tratamento da não linearidade dependerá do modelo da *Proxy* e a busca da política ótima de controle dependerá da boa modelagem do aprendizado por reforço.

6.2. Trabalhos Futuros

As oportunidades de trabalhos futuros podem ser listadas aqui abaixo:

1. Desenvolvimento de uma nova estratégia para obter mais episódios no aprendizado do MPC-RL nos passos iniciais. Dessa maneira, se poderá descobrir melhores políticas de controle para diminuir o sobre sinal máximo (*overshoot*).
2. Desenvolver uma *Proxy* utilizando projeto de experimentos fatoriais fracionado para reduzir o número de amostras necessárias para a construção do modelo.
3. Construir uma *Proxy* com mais passos de previsão. Isto ajudará no desempenho do MPC-RL, preenchendo a tabela com valores *Q-learning* mais confiáveis.

4. Construir uma *Proxy* que seja treinada para um horizonte de previsão dos passos desejados, sem utilizar a realimentação da rede para a previsão.
5. Construção de uma *Proxy* para atender às incertezas de natureza geológica, fazendo com que a *Proxy* seja capaz de aprender variações das características geológicas do reservatório.
6. Projetar um MPC Multi-Agente (Negenborn, 2007), onde se tem um gerenciador MPC e vários RL associados a seus respectivos poços injetores e produtores, para assim poder controlar simultaneamente a produção de óleo no reservatório com vários poços injetores e produtores, como em (Faletti, 2007).
7. Considerar outros tipos de perturbações, tais como perturbações geológicas.