



# CONTROLE PREDITIVO NÃO LINEAR PARA O GERENCIAMENTO DE ENERGIA DE UM VEÍCULO ELÉTRICO HÍBRIDO A CÉLULA A COMBUSTÍVEL

Derick Furquim Pereira

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Elétrica.

Orientador: Edson Hirokazu Watanabe

Rio de Janeiro  
Junho de 2020

CONTROLE PREDITIVO NÃO LINEAR PARA O GERENCIAMENTO DE  
ENERGIA DE UM VEÍCULO ELÉTRICO HÍBRIDO A CÉLULA A  
COMBUSTÍVEL

Derick Furquim Pereira

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO  
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA  
DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS  
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR  
EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Orientador: Edson Hirokazu Watanabe

Aprovada por: Prof. Edson Hirokazu Watanabe

Dr. Francisco da Costa Lopes

Prof. Luis Guilherme Barbosa Rolim

Prof. Paulo Emílio Valadão de Miranda

Prof. Mauricio Barbosa de Camargo Salles

Prof. Júlio Elias Normey Rico

RIO DE JANEIRO, RJ – BRASIL

JUNHO DE 2020

Pereira, Derick Furquim

Controle Preditivo Não Linear para o Gerenciamento de Energia de um Veículo Elétrico Híbrido a Célula a Combustível/Derick Furquim Pereira. – Rio de Janeiro: UFRJ/COPPE, 2020.

XXII, 125 p.: il.; 29, 7cm.

Orientador: Edson Hirokazu Watanabe

Tese (doutorado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2020.

Referências Bibliográficas: p. 96 – 106.

1. Controle Preditivo Não Linear. 2. Veículos Elétricos Híbridos. 3. Células a Combustível. I. Watanabe, Edson Hirokazu. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

*Para minha esposa Deborah,  
meus pais Catarina e Amauri,  
e minha irmã Dandara.*

# Agradecimentos

Gostaria de agradecer ao professor Edson Hirokazu Watanabe pela orientação e pelos valiosos ensinamentos que, ao longo destes anos, contribuíram significativamente para a minha formação como pesquisador. Agradeço por sua disponibilidade, por suas críticas e sugestões e, principalmente, por sua dedicação e pela inspiração. Agradeço ainda ao pesquisador Francisco da Costa Lopes pela inestimável supervisão durante o meu trabalho no Laboratório de Células a Combustível. Obrigado por me apresentar as células a combustível e por compartilhar o seu vasto conhecimento.

Gostaria de agradecer também à Universidade Federal do Rio de Janeiro e ao Centro de Pesquisas de Energia Elétrica (Cepel), pelo suporte e pelo financiamento necessário ao desenvolvimento deste trabalho. Agradeço também aos colegas do Cepel: Dickson Silva de Souza e André Tomaz de Carvalho, pela ajuda com o LabView e a bancada *hardware-in-the-loop*; Carlos Frederico Trotta Matt, pelas sugestões e discussões técnicas; e ao Marcelo Carreiro de Saboia, pelo apoio no laboratório, pela amizade e pelas discussões sobre futebol. Obrigado à todos que contribuíram direta ou indiretamente com o sucesso deste trabalho.

Agradeço especialmente à minha família, pelo apoio irrestrito. À minha esposa Deborah Senna Canongia, por nunca me deixar desistir, pela paciência, pelo amor e pelo carinho. Aos meus pais, Catarina Terezinha Furquim Pereira e Amauri Rodrigues Pereira, por todo o sacrifício feito. À minha irmã, Dandara Furquim Pereira, pelo apoio e pela torcida. Amo vocês!

Finalmente, agradeço à todos meus amigos, que sempre torceram por mim.

Obrigado.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

## CONTROLE PREDITIVO NÃO LINEAR PARA O GERENCIAMENTO DE ENERGIA DE UM VEÍCULO ELÉTRICO HÍBRIDO A CÉLULA A COMBUSTÍVEL

Derick Furquim Pereira

Junho/2020

Orientador: Edson Hirokazu Watanabe

Programa: Engenharia Elétrica

Este trabalho propõe um sistema de gerenciamento de energia (SGE) para um veículo elétrico híbrido a célula a combustível (VEHCC). Este sistema é baseado no controle preditivo baseado em modelo (CPBM) não linear e emprega uma rede neural recorrente (RNR) para modelar uma célula a combustível (CaC) do tipo PEM (*Proton Exchange Membrane*). O CPBM não linear possibilita a formulação de objetivos de controle que não seriam possíveis com o CPBM linear, como o rastreamento do ponto de eficiência máxima da CaC. Adicionalmente, em comparação com os modelos eletroquímicos tradicionais, a RNR prevê com maior precisão a dinâmica não linear da CaC. O SGE foi implementado em um computador de placa única de baixo custo, e os experimentos para validação do controlador foram realizados em uma bancada de testes *hardware-in-the-loop* (HiL) equipada com uma CaC real de 3 kW. Os resultados experimentais demonstram que o SGE proposto é capaz de atender à demanda de energia do veículo, onde faz a sustentação de carga da bateria, e é capaz operar a CaC em sua região mais eficiente. Além disso, também foi realizado um estudo comparativo entre o CPBM não linear proposto, um CPBM linear e um controle por banda de histerese. Os resultados desta comparação demonstram que o controle preditivo não linear oferece uma economia maior de combustível e contribui para redução da degradação da CaC.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

## NONLINEAR MODEL PREDICTIVE CONTROL FOR THE ENERGY MANAGEMENT OF A FUEL CELL HYBRID ELECTRIC VEHICLE

Derick Furquim Pereira

June/2020

Advisor: Edson Hirokazu Watanabe

Department: Electrical Engineering

This work proposes an energy management system (EMS) for a fuel cell hybrid electric vehicle (FCHEV). This system is based on nonlinear model predictive control (NMPC) and employs a recurrent neural network (RNN) to model a proton exchange membrane (PEM) fuel cell (FC). With NMPC, it is possible to formulate control objectives that would not be possible with linear model predictive control (MPC), such as maximum efficiency point tracking (MEPT) of the FC. In addition, compared to traditional electrochemical models, the RNN can predict the FC's nonlinear dynamics with better accuracy. The EMS was implemented on a low-cost single board computer, and the experiments for controller validation were performed on a hardware-in-the-loop (HiL) test bench equipped with a real 3 kW FC stack. The experimental results demonstrate that the proposed EMS can meet the vehicle's energy demand, where it performs the battery's charge sustaining battery, and can operate the FC in its most efficient region. In addition, a comparative study was also carried out between the proposed NMPC, a linear MPC and a hysteresis band control. The results of this comparative study demonstrate that the NMPC provides a better fuel economy and can reduce the FC degradation.

# Sumário

|                                                                                                  |            |
|--------------------------------------------------------------------------------------------------|------------|
| <b>Lista de Figuras</b>                                                                          | <b>xi</b>  |
| <b>Lista de Tabelas</b>                                                                          | <b>xiv</b> |
| <b>Lista de Símbolos</b>                                                                         | <b>xv</b>  |
| <b>Lista de Abreviaturas</b>                                                                     | <b>xx</b>  |
| <b>1 Introdução</b>                                                                              | <b>1</b>   |
| 1.1 Motivação . . . . .                                                                          | 1          |
| 1.2 Veículos Elétricos . . . . .                                                                 | 2          |
| 1.2.1 Veículos Elétricos Puros . . . . .                                                         | 2          |
| 1.2.2 Veículos Elétricos Híbridos . . . . .                                                      | 3          |
| 1.2.3 Veículos Elétricos Híbridos a Célula a Combustível . . . . .                               | 3          |
| 1.3 Células a Combustível . . . . .                                                              | 5          |
| 1.3.1 Fundamentos Básicos . . . . .                                                              | 5          |
| 1.3.2 Tipos de Células a Combustível . . . . .                                                   | 7          |
| 1.3.3 Controle de Sistemas de Células a Combustível . . . . .                                    | 9          |
| 1.4 Gerenciamento de Energia em Veículos Elétricos Híbridos a Células<br>a Combustível . . . . . | 12         |
| 1.5 Identificação do Problema . . . . .                                                          | 15         |
| 1.6 Objetivos do Trabalho . . . . .                                                              | 19         |
| 1.7 Publicações . . . . .                                                                        | 20         |
| 1.8 Organização do Documento . . . . .                                                           | 20         |
| <b>2 Veículo Elétrico Híbrido a Célula a Combustível</b>                                         | <b>22</b>  |
| 2.1 Arquitetura do Sistema de Propulsão . . . . .                                                | 22         |
| 2.2 Demanda de Energia Mecânica do Veículo . . . . .                                             | 24         |
| 2.2.1 Dinâmica Longitudinal . . . . .                                                            | 24         |
| 2.2.2 Modelo Quase-Estático . . . . .                                                            | 25         |
| 2.2.3 Ciclos de Condução . . . . .                                                               | 27         |
| 2.3 Caixa de Câmbio . . . . .                                                                    | 28         |

|          |                                                                                                 |           |
|----------|-------------------------------------------------------------------------------------------------|-----------|
| 2.4      | Motor Elétrico . . . . .                                                                        | 29        |
| 2.5      | Conversores cc/ca e cc/cc . . . . .                                                             | 30        |
| 2.6      | Bateria . . . . .                                                                               | 31        |
| 2.7      | Empilhamento de Células a Combustível do Tipo PEM . . . . .                                     | 33        |
| 2.7.1    | Tensão de Operação . . . . .                                                                    | 33        |
| 2.7.2    | Capacitância de Dupla Camada de Carga . . . . .                                                 | 37        |
| 2.7.3    | Vazão de Gases Reagentes . . . . .                                                              | 38        |
| 2.7.4    | Cálculo da Eficiência . . . . .                                                                 | 39        |
| 2.8      | Modelo Completo do VEHCC para o Estudo de Sistemas de Gerenciamento de Energia . . . . .        | 40        |
| 2.9      | Modelagem de Empilhamentos de Células a Combustível PEM por Redes Neurais . . . . .             | 41        |
| 2.9.1    | Redes Neurais <i>Feedforward</i> . . . . .                                                      | 42        |
| 2.9.2    | Modelagem por Redes Neurais Recorrentes . . . . .                                               | 44        |
| 2.10     | Resumo do Capítulo . . . . .                                                                    | 46        |
| <b>3</b> | <b>Sistema de Gerenciamento de Energia Preditivo Neural</b>                                     | <b>49</b> |
| 3.1      | Controle Preditivo Baseado em Modelo . . . . .                                                  | 49        |
| 3.2      | Controle Preditivo Generalizado . . . . .                                                       | 52        |
| 3.2.1    | Formulação do Controle Preditivo Generalizado . . . . .                                         | 52        |
| 3.2.2    | Controle Preditivo Generalizado com Restrições . . . . .                                        | 55        |
| 3.2.3    | Aplicação do Controle Preditivo Generalizado como Sistema de Gerenciamento de Energia . . . . . | 57        |
| 3.3      | Controle Preditivo Baseado em Modelo Não Linear . . . . .                                       | 60        |
| 3.3.1    | Fundamentos do Controle Preditivo Baseado em Modelo Não Linear . . . . .                        | 60        |
| 3.3.2    | Estabilidade do Controle Preditivo Baseado em Modelo Não Linear . . . . .                       | 62        |
| 3.4      | Sistema de Gerenciamento de Energia Preditivo Neural . . . . .                                  | 65        |
| 3.4.1    | Objetivos do Sistema de Controle . . . . .                                                      | 65        |
| 3.4.2    | Arquitetura do Sistema de Controle . . . . .                                                    | 66        |
| 3.4.3    | Modelo de Predição Não Linear . . . . .                                                         | 66        |
| 3.4.4    | Função de Custo . . . . .                                                                       | 67        |
| 3.4.5    | Indicadores de Desempenho . . . . .                                                             | 68        |
| 3.4.6    | Restrições do Sistema . . . . .                                                                 | 69        |
| 3.5      | Resumo do Capítulo . . . . .                                                                    | 69        |
| <b>4</b> | <b>Resultados e Discussões</b>                                                                  | <b>71</b> |
| 4.1      | Bancada de Testes <i>Hardware-in-the-Loop</i> . . . . .                                         | 71        |
| 4.2      | Identificação Experimental do Modelo do Empilhamento Tipo PEM . . . . .                         | 73        |

|          |                                                                                             |            |
|----------|---------------------------------------------------------------------------------------------|------------|
| 4.2.1    | Dados Experimentais . . . . .                                                               | 73         |
| 4.2.2    | Identificação do Modelo Neural da Tensão . . . . .                                          | 74         |
| 4.2.3    | Identificação do Modelo de Vazão Média de Hidrogênio . . . . .                              | 79         |
| 4.3      | Resultados Experimentais . . . . .                                                          | 80         |
| 4.3.1    | Validação do Controlador Proposto . . . . .                                                 | 80         |
| 4.3.2    | Tempo de Cálculo do CPBM não linear . . . . .                                               | 84         |
| 4.3.3    | Estudo Comparativo . . . . .                                                                | 86         |
| 4.4      | Resumo do Capítulo . . . . .                                                                | 90         |
| <b>5</b> | <b>Conclusão</b>                                                                            | <b>92</b>  |
| 5.1      | Considerações Finais . . . . .                                                              | 92         |
| 5.2      | Trabalhos Futuros . . . . .                                                                 | 95         |
|          | <b>Referências Bibliográficas</b>                                                           | <b>96</b>  |
| <b>A</b> | <b>Linearização do Modelo de Predição</b>                                                   | <b>107</b> |
| <b>B</b> | <b>Códigos Fonte do MATLAB</b>                                                              | <b>110</b> |
| B.1      | Algoritmo de Treinamento da Rede NARX . . . . .                                             | 110        |
| B.2      | Algoritmo do Sistema de Gerenciamento de Energia Preditivo Neural                           | 112        |
| B.3      | Algoritmo do Método dos Conjuntos Ativos para Programação Qua-<br>drática Convexa . . . . . | 116        |
| B.4      | Algoritmo do Sistema de Gerenciamento de Energia Preditivo Linear                           | 119        |
| <b>C</b> | <b>Outros Resultados Experimentais</b>                                                      | <b>122</b> |
| C.1      | Controle Preditivo Não Linear . . . . .                                                     | 122        |
| C.2      | Controle Preditivo Generalizado . . . . .                                                   | 124        |
| C.3      | Controle por Banda de Histerese . . . . .                                                   | 124        |

# Lista de Figuras

|      |                                                                                                                                                                                              |    |
|------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 1.1  | Estrutura de uma célula a combustível de hidrogênio. . . . .                                                                                                                                 | 6  |
| 1.2  | Representação gráfica de um empilhamento de células a combustível de (a) anodo de fluxo contínuo e (b) anodo fechado. . . . .                                                                | 11 |
| 1.3  | Ilustração de um ciclo de descarga típico de um veículo elétrico híbrido <i>plug-in</i> (VEHP). . . . .                                                                                      | 13 |
| 1.4  | Diagrama de um sistema de controle para rastrear a eficiência máxima de um empilhamento de células a combustível (CaC's). . . . .                                                            | 18 |
| 2.1  | Configuração do sistema de propulsão do veículo elétrico a célula a combustível (VEHCC) mostrando o fluxo de energia. . . . .                                                                | 23 |
| 2.2  | Diagrama de forças que atuam em um veículo em movimento. . . . .                                                                                                                             | 25 |
| 2.3  | (a) Relação entrada (força $F$ ) e saída (velocidade $v$ e aceleração $a$ ) em um veículo real (modelo dinâmico) e (b) relação entrada-saída no modelo quase-estático de um veículo. . . . . | 26 |
| 2.4  | Perfil de velocidade do ciclo NEDC ( <i>New European Driving Cycle</i> ). . . . .                                                                                                            | 28 |
| 2.5  | Perfil de velocidade do ciclo FTP ( <i>Federal Test Procedure</i> , da Agência de Proteção Ambiental dos Estados Unidos). . . . .                                                            | 28 |
| 2.6  | Mapa de eficiência de um motor elétrico (ME) com potência nominal de 10,5 kW e conjugado máximo de 70 Nm. . . . .                                                                            | 30 |
| 2.7  | Curva de eficiência de um conversor de acordo com (2.15). . . . .                                                                                                                            | 31 |
| 2.8  | Circuito equivalente da bateria. . . . .                                                                                                                                                     | 31 |
| 2.9  | Curva de descarga típica de uma bateria. . . . .                                                                                                                                             | 32 |
| 2.10 | Circuito equivalente de uma célula a combustível unitária. . . . .                                                                                                                           | 37 |
| 2.11 | Diagrama de blocos do modelo do veículo elétrico a célula a combustível (VEHCC). . . . .                                                                                                     | 41 |
| 2.12 | Diagrama representando a estrutura de um neurônio artificial (NA). . . . .                                                                                                                   | 42 |
| 2.13 | Rede neural <i>feedforward</i> com três entradas, duas camadas ocultas com dois neurônios artificiais em cada uma e duas saídas. . . . .                                                     | 44 |
| 2.14 | Representação gráfica das redes neurais NARX e NOE. . . . .                                                                                                                                  | 45 |
| 3.1  | Princípio do horizonte retrocedente (PHR). . . . .                                                                                                                                           | 51 |

|      |                                                                                                                                                                               |    |
|------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 3.2  | Diagrama de blocos de um sistema de controle preditivo generalizado (CPG). . . . .                                                                                            | 55 |
| 3.3  | Diagrama de blocos do sistema de controle preditivo generalizado (CPG) para o gerenciamento de energia de um veículo elétrico híbrido a célula a combustível (VEHCC). . . . . | 58 |
| 3.4  | Diagrama de blocos do sistema de gerenciamento de energia (SGE) proposto. . . . .                                                                                             | 66 |
| 4.1  | Bancada de testes <i>hardware-in-the-loop</i> (HiL). . . . .                                                                                                                  | 72 |
| 4.2  | Diagrama da bancada de testes <i>hardware-in-the-loop</i> (HiL). . . . .                                                                                                      | 72 |
| 4.3  | Empilhamento de CaC's tipo PEM modelo H3000. . . . .                                                                                                                          | 73 |
| 4.4  | Dados experimentais de corrente da CaC para o treinamento do modelo neural. . . . .                                                                                           | 74 |
| 4.5  | Dados experimentais de tensão da CaC para o treinamento do modelo neural. . . . .                                                                                             | 74 |
| 4.6  | Medições dos valores instantâneo e médio da vazão hidrogênio para o perfil de corrente da Figura 4.4. . . . .                                                                 | 74 |
| 4.7  | Decimação das medições de tensão. . . . .                                                                                                                                     | 75 |
| 4.8  | Espectros de frequências do perfil de tensão da Figura 4.5 amostrado com (a) 100 ms e (b) 1 s. . . . .                                                                        | 76 |
| 4.9  | Série de tensão diferencial. . . . .                                                                                                                                          | 76 |
| 4.10 | Autocorrelação parcial da série de tensão diferencial. . . . .                                                                                                                | 77 |
| 4.11 | (a) Predições de tensão do modelo neural NARX e (b) erros de predição durante a etapa de treinamento. . . . .                                                                 | 78 |
| 4.12 | (a) Predições de tensão do modelo neural NARX e (b) erros de predição durante a etapa de validação. . . . .                                                                   | 79 |
| 4.13 | Vazão média de hidrogênio experimental e estimada em função da corrente da célula a combustível (CaC). . . . .                                                                | 80 |
| 4.14 | Ciclo de condução (fase dois do ciclo FTP). . . . .                                                                                                                           | 82 |
| 4.15 | Potências de tração, da bateria e da CaC no elo cc para o caso A do CPBM não linear. . . . .                                                                                  | 82 |
| 4.16 | Potências de tração, da bateria e da CaC no elo cc para o caso B do CPBM não linear. . . . .                                                                                  | 82 |
| 4.17 | Potências de tração, da bateria e da CaC no elo cc para o caso C do CPBM não linear. . . . .                                                                                  | 83 |
| 4.18 | Medições experimentais da corrente da CaC real para os casos A, B e C do CPBM não linear. . . . .                                                                             | 83 |
| 4.19 | EdC da bateria simulado em tempo real usando o controlador PXIe-8880 para os casos A, B e C do CPBM não linear. . . . .                                                       | 83 |

|      |                                                                                                                                                                                        |     |
|------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| 4.20 | Eficiência experimental da CaC real para os casos A, B e C do CPBM não linear. . . . .                                                                                                 | 84  |
| 4.21 | Tempo de execução do algoritmo de controle durante as 200 primeiras amostras do caso C do CPBM não linear considerando diferentes tamanhos do horizonte de predição. . . . .           | 85  |
| 4.22 | Comparação do EdC da bateria simulado em tempo real usando o controlador PXIe-8880 para o caso C do CPBM não linear considerando diferentes tamanhos do horizonte de predição. . . . . | 86  |
| 4.23 | Comparação do EdC da bateria simulado em tempo real pelo controlador PXIe-8880 para o caso C do CPN, o CPG e o CBH. . . . .                                                            | 87  |
| 4.24 | Comparação das medições experimentais de corrente da CaC real para o caso C do CPN, o CPG e o CBH. . . . .                                                                             | 87  |
| 4.25 | Eficiência experimental da CaC real para o caso C do CPN, o CPG e o CBH. . . . .                                                                                                       | 88  |
| C.1  | Medições experimentais da tensão da CaC real para os casos A, B e C do CPBM não linear. . . . .                                                                                        | 122 |
| C.2  | Medições experimentais da vazão de hidrogênio da CaC real para o caso A do CPBM não linear. . . . .                                                                                    | 123 |
| C.3  | Medições experimentais da vazão de hidrogênio da CaC real para o caso B do CPBM não linear. . . . .                                                                                    | 123 |
| C.4  | Medições experimentais da vazão de hidrogênio da CaC real para o caso C do CPBM não linear. . . . .                                                                                    | 123 |
| C.5  | Medições experimentais da corrente da CaC real para o caso C do CPBM não linear com horizonte de predição de 5 e 15 amostras. . . .                                                    | 123 |
| C.6  | Medições experimentais da tensão da CaC real para o caso C do CPBM não linear com horizonte de predição de 5 e 15 amostras. . . .                                                      | 124 |
| C.7  | Medições experimentais da vazão de hidrogênio da CaC real para o caso C do CPBM não linear com horizonte de predição de 5 amostras. . . .                                              | 124 |
| C.8  | Medições experimentais da vazão de hidrogênio da CaC real para o caso C do CPBM não linear com horizonte de predição de 15 amostras. . . .                                             | 124 |
| C.9  | Medições experimentais da tensão da CaC real para o CPG. . . . .                                                                                                                       | 125 |
| C.10 | Medições experimentais da vazão de hidrogênio da CaC real para o CPG. . . . .                                                                                                          | 125 |
| C.11 | Medições experimentais da tensão da CaC real para o CBH. . . . .                                                                                                                       | 125 |
| C.12 | Medições experimentais da vazão de hidrogênio da CaC real para o CBH. . . . .                                                                                                          | 125 |

# Lista de Tabelas

|     |                                                                                                                                    |    |
|-----|------------------------------------------------------------------------------------------------------------------------------------|----|
| 4.1 | Coeficientes de ponderação da função de custo para cada caso de estudo do CPBM não linear. . . . .                                 | 80 |
| 4.2 | Parâmetros do modelo do veículo. . . . .                                                                                           | 81 |
| 4.3 | Parâmetros dos modelo da bateria. . . . .                                                                                          | 81 |
| 4.4 | Parâmetros das curvas de eficiência dos conversores. . . . .                                                                       | 81 |
| 4.5 | Consumo de hidrogênio, degradação da CaC, energia gerada pela CaC e eficiência total para os controladores CPN, GPC e HBC. . . . . | 88 |
| 4.6 | Parâmetros da função de degradação da CaC. . . . .                                                                                 | 89 |

# Lista de Símbolos

|           |                                                                                            |
|-----------|--------------------------------------------------------------------------------------------|
| $A_f$     | Área frontal do veículo (m <sup>2</sup> ), p. 24                                           |
| $B$       | Constante da queda de tensão por concentração (V), p. 37                                   |
| $E$       | Tensão de circuito aberto de uma célula a combustível (V), p. 33                           |
| $F$       | Constante de Faraday (96485 C/mol), p. 34                                                  |
| $F_a$     | Força de arrasto aerodinâmico (N), p. 24                                                   |
| $F_r$     | Força de atrito (N), p. 24                                                                 |
| $F_t$     | Força de tração (N), p. 24                                                                 |
| $I_0$     | Corrente de troca (A), p. 35                                                               |
| $I_n$     | Corrente que atravessa o eletrólito sem realizar trabalho elétrico (A), p. 35              |
| $I_{lim}$ | Corrente limite (A), p. 37                                                                 |
| $K_1$     | Tensão de polarização da bateria (V), p. 32                                                |
| $K_2$     | Amplitude da zona exponencial da bateria (V), p. 32                                        |
| $K_3$     | Inverso da constante de tempo da zona exponencial da bateria ((A.h) <sup>-1</sup> ), p. 32 |
| $M$       | Número de amostras atrasadas do sinal de entrada, p. 45                                    |
| $M_{H_2}$ | Massa molar do hidrogênio (2,016·10 <sup>-3</sup> kg/mol), p. 38                           |
| $N$       | Número de amostras atrasadas do sinal de saída, p. 45                                      |
| $N_1$     | Horizonte de predição mínimo, p. 51                                                        |
| $N_2$     | Horizonte de predição máximo, p. 51                                                        |

|             |                                                                                                      |
|-------------|------------------------------------------------------------------------------------------------------|
| $N_i$       | Força normal nos pneus (N), p. 24                                                                    |
| $N_u$       | Horizonte de controle, p. 51                                                                         |
| $N_{start}$ | Número de partidas da CaC, p. 88                                                                     |
| $P(z^{-1})$ | Polinômio no operador de atraso unitário $z^{-1}$ , p. 52                                            |
| $P_x$       | Componente da força gravitacional na direção $x$ (N), p. 24                                          |
| $P_y$       | Componente da força gravitacional na direção $y$ (N), p. 24                                          |
| $P_{AS}$    | Potência consumida pelos sistemas auxiliares do veículo elétrico de células a combustível (W), p. 23 |
| $P_{BT}$    | Potência da bateria (W), p. 23                                                                       |
| $P_{EM}$    | Potência do motor elétrico (W), p. 23                                                                |
| $P_{FC}$    | Potência da célula a combustível (W), p. 23                                                          |
| $P_{nom}$   | Potência nominal da CaC, p. 88                                                                       |
| $Q$         | Carga elétrica por mol de $H_2$ consumido (C), p. 34                                                 |
| $Q_{BT}$    | Capacidade da bateria (A.h), p. 32                                                                   |
| $R$         | Constante universal dos gases ideais (8,3143 J/mol/K), p. 34                                         |
| $R_c$       | Resistência de contato ( $\Omega$ ), p. 36                                                           |
| $R_e$       | Resistência dos eletrodos ( $\Omega$ ), p. 36                                                        |
| $R_m$       | Resistência da membrana polimérica ( $\Omega$ ), p. 36                                               |
| $R_{BT}$    | Resistência interna da bateria ( $\Omega$ ), p. 32                                                   |
| $R_{ohm}$   | Resistência elétrica interna de uma CaC ( $\Omega$ ), p. 36                                          |
| $T$         | Temperatura (K), p. 34                                                                               |
| $T_m$       | Conjugado mecânico no eixo do motor (Nm), p. 29                                                      |
| $T_t$       | Conjugado da transmissão mecânica (N.m), p. 40                                                       |
| $T_w$       | Conjugado da roda (N.m), p. 40                                                                       |
| $T_w$       | Conjugado mecânico nas rodas (Nm), p. 26                                                             |
| $U_{BT}^0$  | Tensão constante da bateria (V), p. 32                                                               |

|                      |                                                                         |
|----------------------|-------------------------------------------------------------------------|
| $W_0$                | Bias do neurônio na camada de saída, p. 45                              |
| $W_i$                | Peso do neurônio da camada de saída, p. 45                              |
| $\Delta u$           | Incremento do sinal de controle, p. 49                                  |
| $\Delta \bar{g}_f$   | Variação da energia livre de Gibbs (J/mol), p. 34                       |
| $\Delta \bar{g}_f^0$ | Variação da energia livre de Gibbs a pressão atmosférica (J/mol), p. 34 |
| $\Delta \bar{h}_f$   | Entalpia de formação (J), p. 39                                         |
| $\Delta_{start}$     | Coeficiente de degradação devido às partidas e paradas da CaC, p. 88    |
| $\alpha_L$           | Coeficiente de carga, p. 88                                             |
| $\alpha_c$           | Coeficiente de transferência de carga (adimensional), p. 35             |
| $\alpha_t$           | Aceleração angular da transmissão mecânica (rad/s <sup>2</sup> ), p. 40 |
| $\alpha_w$           | Aceleração angular nas rodas (rad/s <sup>2</sup> ), p. 26, 40           |
| $\delta$             | Coeficiente de penalização do erro de rastreamento da referência, p. 51 |
| $\delta_L$           | Coeficiente de carga, p. 88                                             |
| $\dot{n}_{H_2}$      | Vazão estequiométrica molar (mol/s), p. 38                              |
| $\eta_v$             | Eficiência de tensão (%), p. 39                                         |
| $\eta_b$             | Eficiência do conversor cc/cc, p. 23                                    |
| $\eta_i$             | Eficiência do inversor, p. 23                                           |
| $\frac{1}{z}$        | Operador de atraso unitário, p. 45                                      |
| $\gamma$             | Relação de transmissão, p. 29                                           |
| $\hat{v}_{FC}$       | Predição de tensão do empilhamento feita pela rede neural (V), p. 45    |
| $\lambda$            | Coeficiente de penalização do esforço de controle, p. 51                |
| $\omega_m$           | Velocidade angular do motor (rad/s), p. 29                              |
| $\omega_t$           | Velocidade angular da transmissão mecânica (rad/s), p. 40               |

|                    |                                                                           |
|--------------------|---------------------------------------------------------------------------|
| $\omega_w$         | Velocidade angular nas rodas (rad/s), p. 26, 40                           |
| $\rho_a$           | Densidade do ar (kg/m <sup>3</sup> ), p. 24                               |
| $\theta$           | Ângulo de inclinação da via (rad), p. 24                                  |
| $v_j$              | Saída do bloco somador de um neurônio artificial, p. 43                   |
| $\varphi_i$        | Sinal de entrada de um neurônio artificial, p. 43                         |
| $\varphi_j$        | Nó de entrada, p. 45                                                      |
| $\hat{\mathbf{y}}$ | Vetor de predições da saída, p. 52                                        |
| $\mathbf{f}$       | Vetor de predições da resposta livre do sistema, p. 53                    |
| $\mathbf{r}$       | Vetor com sequência de amostras da trajetória de referência futura, p. 53 |
| $\mathbf{u}$       | Vetor de incrementos de controle futuros, p. 52                           |
| $\xi_{BT}$         | Estado de carga da bateria (%), p. 32                                     |
| $a$                | Aceleração (m/s <sup>2</sup> ), p. 26                                     |
| $b_j$              | <i>Bias</i> de um neurônio artificial, p. 43                              |
| $c_d$              | Coefficiente de arrasto aerodinâmico (adimensional), p. 24                |
| $c_i$              | Coefficientes da curva de eficiência do conversor (adimensional), p. 31   |
| $c_r$              | Coefficiente de atrito (adimensional), p. 24                              |
| $d$                | Atraso de transporte do sistema ( <i>dead-time</i> ), p. 52               |
| $e(k)$             | Ruído branco de média nula, p. 52                                         |
| $f_j$              | Função de ativação de um neurônio artificial, p. 43                       |
| $g$                | Aceleração gravitacional (m/s <sup>2</sup> ), p. 24                       |
| $h$                | Intervalo de amostragem (s), p. 26, 32                                    |
| $i_{FC}$           | Corrente da célula a combustível (A), p. 23, 35                           |
| $k$                | Instante de amostragem, p. 26, 48                                         |
| $m_V$              | Massa total do veículo (kg), p. 24                                        |

|               |                                                                                     |
|---------------|-------------------------------------------------------------------------------------|
| $n$           | Número de células em um empilhamento de células a combustível (adimensional), p. 33 |
| $n_{\varphi}$ | Número de nós de entrada, p. 45                                                     |
| $n_h$         | Número de neurônios na camada oculta, p. 45                                         |
| $n_{H_2}$     | Número de moles de hidrogênio, p. 38                                                |
| $p_{H_2O}$    | Pressão parcial da água (bar), p. 34                                                |
| $p_{H_2}$     | Pressão parcial do hidrogênio (bar), p. 34                                          |
| $p_{O_2}$     | Pressão parcial do oxigênio (bar), p. 34                                            |
| $r$           | Trajectoria de referência, p. 49                                                    |
| $r_w$         | Raio das rodas (m), p. 26                                                           |
| $t$           | Tempo contínuo (s), p. 24                                                           |
| $u$           | Variável de entrada (sinal de controle), p. 48                                      |
| $v$           | Velocidade do veículo (m/s), p. 24                                                  |
| $v_{BT,oc}$   | Tensão de circuito aberto da bateria (V), p. 32                                     |
| $v_{BT}$      | Tensão terminal da bateria (V), p. 32                                               |
| $v_{FC}$      | Tensão da célula a combustível (V), p. 33                                           |
| $v_{act}$     | Sobrepotencial de ativação (V), p. 33                                               |
| $v_{con}$     | Sobrepotencial de concentração (V), p. 33                                           |
| $v_{ohm}$     | Sobrepotencial ôhmico (V), p. 33                                                    |
| $w_{H_2}$     | Vazão média de gás hidrogênio (kg/s), p. 39                                         |
| $w_{i0}$      | Bias de um neurônio na camada oculta, p. 45                                         |
| $w_{ij}$      | Peso de um neurônio na camada oculta, p. 45                                         |
| $w_{j,i}$     | Peso atribuído ao sinal de entrada de um neurônio artificial, p. 43                 |
| $y$           | Variável de saída, p. 48                                                            |
| $y_j$         | Sinal de saída de um neurônio artificial, p. 43                                     |
| $z^{-1}$      | Operador de atraso unitário, p. 52                                                  |

# Lista de Abreviaturas

|          |                                                          |
|----------|----------------------------------------------------------|
| AFC      | <i>Alkaline Fuel Cell</i> , p. 8                         |
| AIE      | Agência Internacional de Energia, p. 2                   |
| BBB      | BeagleBone Black, p. 70                                  |
| BdP      | Balanco de Planta, p. 4                                  |
| CAM      | Controle Algorítmico do Modelo, p. 50                    |
| CARIMA   | <i>Controller Auto-Regressive Moving Average</i> , p. 52 |
| CBH      | Controle por Banda de Histerese, p. 14                   |
| CMD      | Controle por Matriz Dinâmica, p. 50                      |
| CPBM     | Controle Preditivo Baseado em Modelo, p. 14, 48          |
| CPG      | Controle Preditivo Generalizado, p. 50                   |
| CPN      | Controle Preditivo Neural, p. 86                         |
| CaC      | Célula a Combustível, p. 4                               |
| DENATRAN | Departamento Nacional de Trânsito, p. 2                  |
| EPA      | <i>U.S. Environmental Protection Agency</i> , p. 28      |
| EdC      | Estado de Carga, p. 12                                   |
| FTP      | <i>Federal Test Procedure</i> , p. 28                    |
| GEE      | Gases de Efeito Estufa, p. 1                             |
| HiL      | <i>Hardware-in-the-Loop</i> , p. 19                      |
| MCFC     | <i>Molten Carbonate Fuel Cell</i> , p. 9                 |
| MLP      | <i>Multilayer Perceptron</i> , p. 43                     |

|        |                                                               |
|--------|---------------------------------------------------------------|
| NARX   | <i>Nonlinear AutoRegressive with eXogenous input</i> , p. 44  |
| NA     | Neurônio Artificial, p. 42                                    |
| NEDC   | <i>New European Drive Cycle</i> , p. 27                       |
| NOE    | <i>Nonlinear Output Error</i> , p. 44                         |
| PAFC   | <i>Phosphoric Acid Fuel Cell</i> , p. 8                       |
| PCI    | Poder Calorífico Inferior, p. 39                              |
| PCS    | Poder Calorífico Superior, p. 39                              |
| PEMFC  | <i>Proton Exchange Membrane Fuel Cell</i> , p. 7              |
| PEM    | <i>Proton Exchange Membrane</i> , p. 7                        |
| PHR    | Princípio do Horizonte Retrocedente, p. 49                    |
| PQS    | Programação Quadrática Sequencial, p. 60                      |
| PQ     | Programação Quadrática, p. 56                                 |
| P&O    | Perturbar e Observar, p. 85                                   |
| QSS-TB | <i>Quasi-Static Simulation Toolbox</i> , p. 27                |
| RNR    | Rede Neural Recorrente, p. 44                                 |
| SGE    | Sistema de Gerenciamento de Energia, p. 19                    |
| SISO   | <i>Single Input Single Output</i> , p. 52                     |
| SOFC   | <i>Solid Oxid Fuel Cell</i> , p. 8                            |
| VEB    | Veículo Elétrico a Bateria, p. 2                              |
| VECC   | Veículo Elétrico a Célula a Combustível, p. 4                 |
| VEHCCP | Veículo Elétrico a Célula a Combustível <i>Plug-in</i> , p. 5 |
| VEHCC  | Veículo Elétrico Híbrido a Célula a Combustível, p. 4         |
| VEHP   | Veículo Elétrico Híbrido <i>Plug-in</i> , p. 3                |
| VEH    | Veículo Elétrico Híbrido, p. 3                                |
| VE     | Veículo Elétrico, p. 2                                        |

|      |                                              |
|------|----------------------------------------------|
| VMCI | Veículo com Motor de Combustão Interna, p. 2 |
| ca   | Corrente Alternada, p. 23                    |
| cc   | Corrente Contínua, p. 23                     |

# Capítulo 1

## Introdução

Este capítulo expõe primeiramente a motivação deste trabalho e, em seguida, apresenta alguns conceitos relacionados aos veículos elétricos e às células a combustível, que servirão de base para o entendimento do restante deste documento. Na sequência, é feita uma revisão bibliográfica sobre sistemas de controle com foco em células a combustível e aplicações veiculares, com especial atenção para os sistemas de gerenciamento de energia. Ao final, são levantados alguns dos problemas identificados e apresentados os objetivos e as principais contribuições deste trabalho.

### 1.1 Motivação

O setor de transportes é um dos grandes causadores das emissões de gases de efeito estufa (GEE) no mundo. Em 2016, 72% das emissões de CO<sub>2</sub> na Europa foram de veículos terrestres, tendo os carros contribuído com 60,7% desse valor [1]. No caso do Brasil, se consideradas apenas as emissões provenientes do uso de energia<sup>1</sup>, os transportes foram responsáveis por 45,8% das emissões de CO<sub>2</sub> durante ano de 2017 [2]. Nesse mesmo ano, somente o transporte rodoviário foi responsável por 30,6% do consumo total de energia no país [3], sendo grande parte consumida na forma de derivados do petróleo [4].

Apesar dos impactos negativos, o transporte desempenha um papel fundamental no desenvolvimento econômico de um país. Esse setor é essencial para o deslocamento de pessoas, bens e serviços, possibilitando também a geração de empregos [4]. Além disso, é comprovado que um aumento de renda da população leva a um aumento da demanda por mobilidade [5]. Em um estudo divulgado pela Agência Internacional de Energia (AIE) [6], estima-se que entre 2012 e 2035 a frota mundial de veículos leves deve crescer de 900 milhões para mais de 1,7 bilhões. Apenas no Brasil, de 1998 a 2018, a frota de automóveis registrados no Departamento Nacional

---

<sup>1</sup>Desconsiderando as emissões por mudança de uso da terra e florestas, que incluem o desmatamento.

de Trânsito (DENATRAN) aumentou de cerca de 17 milhões para 54,7 milhões no período [7].

Diante deste cenário, o desenvolvimento de novas tecnologias como os veículos elétricos é essencial para a redução dos danos ambientais e do consumo de combustíveis fósseis. Ao mesmo tempo, é evidente que o consumo energético dos automóveis de passageiros deve ser reduzido substancialmente, seja essa energia proveniente de algum combustível ou puramente elétrica. É neste tipo de abordagem que está focado este trabalho.

## 1.2 Veículos Elétricos

Um veículo elétrico (VE) é todo aquele que possui pelo menos um motor elétrico para tração, seja ela total ou parcial [8]. Todo VE possui ao menos uma fonte de energia eletroquímica (bateria) ou eletrostática (supercapacitor), e pode ser categorizado como puro ou híbrido (e subclassificações).

### 1.2.1 Veículos Elétricos Puros

Um VE puro é constituído essencialmente de um banco de baterias (que pode estar associado a um banco de supercapacitores ou não), um motor elétrico e seu controlador, sendo chamado também de veículo elétrico a bateria (VEB) [8]. Tais veículos possuem diversas vantagens quando comparados aos veículos com motor de combustão interna (VMCI).

Os VEB's normalmente dispensam componentes típicos de VMCI's como caixa de marchas, motor de arranque, equipamentos de exaustão (escapamento, catalisador), e são portanto menos complexos [9]. Adicionalmente, motores elétricos possuem um rendimento típico superior a 90% e permitem frenagem regenerativa, com baixo nível de ruído e de vibração [9]. Por fim, do ponto de vista ambiental, os VEB's permitem zero emissão local<sup>2</sup> de GEE's, pois a energia elétrica para a tração é fornecida integralmente pelas baterias.

As vantagens dos puramente elétricos vem ao custo de atributos como tempo de recarga e autonomia, devido principalmente às restrições tecnológicas dos diferentes tipos de baterias mais usados nos VEB's [8, 9]. A título de exemplo, o Hyundai Kona Electric em uma recarga rápida leva cerca de 40 minutos para levar a sua carga de 20% até 80% do total e, dependendo do método e do carregador, o tempo para uma carga completa pode levar de 10 a 29 horas [10]. A autonomia prometida<sup>3</sup> pelo

---

<sup>2</sup>São desconsideradas as possíveis emissões da geração de energia para abastecer o veículo e para fabricação do veículo.

<sup>3</sup>A quilometragem real varia de acordo com vários fatores (condições do veículo e da bateria, hábitos de direção, etc).

fabricante é de 415 km com as baterias completamente carregadas [11]. Aumentar a autonomia de um VEB exigiria um maior espaço ocupado, além de um aumento de peso, pois seria necessário aumentar o banco de baterias.

### 1.2.2 Veículos Elétricos Híbridos

Um veículo elétrico híbrido (VEH), por definição, possui ao menos duas fontes de energia de tipos diferentes, ou ainda dois ou mais tipos de motores para tração [8]. Neste trabalho, o termo VEH refere-se estritamente aos veículos híbridos “convencionais”, que são aqueles que utilizam um motor de combustão interna em conjunto com um motor elétrico. Em contraste com os VEB’s, os VEH’s costumam exigir mais potência do que energia das baterias [9].

Nos VEH’s, o uso do motor elétrico é tipicamente priorizado nas baixas rotações, onde o motor de combustão interna apresenta menor rendimento. Dessa forma, o motor de combustão interna pode operar por mais tempo nas regiões onde seu rendimento é ótimo. O emprego de um motor elétrico também permite frenagem regenerativa, recuperando parte da energia cinética do veículo. Portanto, a principal vantagem dos VEH’s consiste na economia de combustível [12]. Contudo, em tais veículos há apenas uma redução parcial das emissões locais de GEE e não total como no caso dos VEB’s.

Um outro tipo de veículo híbrido, que propõe um meio termo entre os VEB’s e os VEH’s, é o VEH *plug-in* (VEHP). Este tipo de veículo possui quase todas as características de um VEH convencional, exceto pela bateria que possui maior capacidade de armazenamento de energia e pode ser carregada diretamente pela rede elétrica. Assim, um VEHP pode funcionar por mais tempo usando propulsão puramente elétrica, resultando em reduções mais significativas de emissão em comparação com os VEH’s convencionais.

Como exemplo, o alcance da versão *plug-in* do Toyota Prius no modo elétrico puro é da ordem de 50 km [13]. Este alcance permite normalmente dispensar o uso do motor de combustão interna em cidades, onde costuma-se conduzir por trechos de no máximo poucas dezenas de quilômetros. Vantagens como esta, fazem do VEHP uma solução de transição atraente para renovação da frota de veículos por uma mais limpa. Porém, não são uma solução de longo prazo, visto que os VEHP’s ainda dependem do motor de combustão interna para percorrer longas distâncias, da ordem de centenas de quilômetros.

### 1.2.3 Veículos Elétricos Híbridos a Célula a Combustível

Células a combustível fornecem energia sob forma elétrica e, por esta razão, o sistema de propulsão de um veículo elétrico a célula de combustível (VECC) é similar ao

de um VEB. No entanto, enquanto as baterias são dispositivos que armazenam energia, uma célula a combustível (CaC) é um dispositivo que converte a energia química de um combustível diretamente em energia elétrica. Além disso, baterias são recarregáveis e independentes, enquanto as CaC's requerem que o combustível esteja armazenado em algum outro dispositivo.

A operação de CaC's requer subsistemas auxiliares encarregados do balanço de planta (BdP) – que pode incluir componentes como compressores, circuitos de recirculação, sistema de ventilação, trocadores de calor, umidificadores, etc. Devido a fenômenos termodinâmico e mecânicos, a resposta destes sistemas é lenta quando comparada a demanda por energia elétrica no sistema de propulsão [14]. Por esta razão, a resposta de potência dos VECC's costuma ser melhorada com a adição de um sistema de armazenamento de curto prazo, como baterias ou supercapacitores, resultando em um veículo elétrico híbrido a célula a combustível (VEHCC) [8].

A conversão de energia química em energia elétrica em uma CaC se dá através de uma reação eletroquímica e, portanto, não há uma etapa intermediária de conversão em energia térmica. Desta maneira, a eficiência da CaC não fica limitada pela eficiência de Carnot como no caso dos motores de combustão interna [8, 15]. O tipo de combustível utilizado depende do tipo de CaC, sendo o gás hidrogênio ( $H_2$ ) o mais comum e tipicamente usado em aplicações veiculares. Nas CaC's a hidrogênio, apenas água e calor são gerados como resíduos e, por esta razão, juntamente com os VEB's, os VEHCC's são considerados veículos de emissão local zero. Mas ao contrário dos puramente elétricos, os VEHCC's apresentam um menor tempo de reabastecimento e autonomia, semelhantes aos dos VMCI's. O Hyundai Nexu, por exemplo, um modelo de SUV<sup>4</sup> (mesma categoria do Kona Electric), leva em torno de 5 minutos para o reabastecimento completo de seus tanques de hidrogênio, e tem uma autonomia prometida pelo fabricante de 611 km com os tanques cheios [16].

Os VEHCC's também são considerados um dos pilares da economia do futuro, na qual o hidrogênio é apontado como principal vetor energético [17, 18]. O hidrogênio pode ser obtido de maneira limpa por eletrólise, utilizando energia elétrica proveniente de fontes renováveis, como hidroeletricidade, eólica e solar [19, 20]. No caso das fontes eólica e solar, o armazenamento local de hidrogênio pode servir para atenuar a intermitência dessas fontes [21]. Graças às vantagens como essas, em vários locais ao redor do mundo, diversas iniciativas foram lançadas com o objetivo de fazer uma transição de uma economia e indústria baseada em combustíveis fósseis para uma renovável e mais limpa, baseada em hidrogênio.

A Alemanha, por exemplo, vem explorando a sinergia entre os setores de transporte e elétrico para viabilizar a transição de sua matriz energética [22]. Esta transição, batizada de *Energiewende*, consiste em uma iniciativa que visa a substituição

---

<sup>4</sup>*Sport Utility Vehicle*. Sigla em inglês para veículos utilitários esportivos.

quase completa de combustíveis fósseis por energias renováveis até 2050. O Energiewende possui metas ambiciosas, como um corte de no mínimo 80% das emissões de GEE até 2050 (tendo como base o ano de 1990) e uma redução de 40% do consumo de energia pelo setor de transportes (comparado ao ano de 2005) [23]. Nesse contexto, o governo alemão já investiu cerca de 1,4 bilhões de euros em projetos relacionados à CaC e hidrogênio em aplicações de transporte [24]. Um estudo apresentado em [22] conclui que a meta de redução dos GEE no setor de transportes deve ser atendida com a difusão dos VEHCC's e outros VE's.

No caso dos Estados Unidos, no começo da década de 1990, o governo do estado da Califórnia iniciou um programa de incentivo aos veículos não poluentes [25]. Assim, o estado vem construindo uma infraestrutura para permitir o abastecimento de VEHCC's, e exige que, até 2030, ao menos metade do hidrogênio usado nos veículos seja produzido a partir de fontes renováveis [26]. Atualmente, a Califórnia conta com 41 estações de abastecimento de gás hidrogênio em funcionamento, com expectativa de abertura de mais 18 até 2021 [27].

Uma outra variação das opções atuais de veículos elétricos é o VEHCC *plug-in* (VEHCCP), isto é, um VEHCC com a capacidade de recarga do seu banco de baterias através da rede elétrica, como o VEHP. O VEHCCP combina as características atraentes dos demais tipos de VE's discutidos acima. Assim como os VEHP, ele também possui uma bateria com mais capacidade que a sua versão não *plug-in*, capaz de cobrir a maioria dos trajetos em um perímetro urbano por exemplo. Além disso, a CaC garante um aumento da autonomia do veículo e a conveniência de um reabastecimento rápido, como nos VMCI's. Por fim, os VEHCCP's também exigiriam menos estações de reabastecimento de hidrogênio e a dependência de estações de carregamento rápido para as baterias é menor do que a dos VEB's, devido ao sistema com hidrogênio [28].

## 1.3 Células a Combustível

### 1.3.1 Fundamentos Básicos

Uma CaC é composta por dois eletrodos (anodo e catodo) separados por um eletrólito, como mostra a Figura 1.1. Através da oxidação<sup>5</sup> de um combustível no anodo, e da redução<sup>6</sup> do gás oxigênio ( $O_2$ ) no catodo, uma CaC é capaz de converter a energia química desse combustível diretamente em energia elétrica.

Usualmente, o combustível utilizado é o gás hidrogênio ( $H_2$ ), e um catalisador presente no anodo faz com que esse gás seja ionizado, liberando elétrons e criando

---

<sup>5</sup>Perda de elétrons.

<sup>6</sup>Ganho de elétrons.





Figura 1.1: Estrutura de uma célula a combustível de hidrogênio.

íons  $H^+$ :



Conforme ilustrado na Figura 1.1, os elétrons liberados alcançam o catodo através de um circuito conectando os dois eletrodos, e os íons  $H^+$  atravessam o eletrólito. No catodo, o oxigênio reage com os elétrons e o hidrogênio ionizado formando água:



De uma forma mais simplificada, (1.1) e (1.2) podem ser combinadas, resultando em:



como se estivesse sendo feita a combustão do hidrogênio, porém produzindo eletricidade ao invés de liberar calor [29]. É importante ressaltar que as CaC's também geram calor, mas é devido às irreversibilidades das reações eletroquímicas.

O termo CaC é comumente usado para se referir a um empilhamento de várias células individuais. No entanto, estritamente falando, esse termo se refere apenas a uma célula unitária, capaz de produzir apenas alguns watts de potência elétrica e tensão na ordem de 1 volt, enquanto um empilhamento é capaz de fornecer energia elétrica na ordem de quilowatts.

### 1.3.2 Tipos de Células a Combustível

Existem diferentes tipos de CaC's, classificadas de acordo com o tipo de material que é empregado como eletrólito [29]. O tipo de material, por sua vez, determina a temperatura de operação da célula, assim como o tipo de íon que o atravessa e o limite de potência nominal dos empilhamentos. No entanto, é importante notar que as aplicações de diferentes tipos de CaC's não são limitadas por esta potência nominal, uma arranjos multi-empilhamento poder ser utilizados para aumentar a potência nominal e possibilitar a alimentação de cargas de potência mais elevada [30]. São as diferentes características, como o material do eletrólito, temperatura de operação e o combustível utilizado, tornam cada tipo de CaC adequado para diferentes aplicações. A seguir são apresentados os principais tipos de CaC's existentes e suas diferenças.

#### **Célula de membrana trocadora de prótons ou PEMFC (*Proton Exchange Membrane Fuel Cell* ou *PEM Fuel Cell*)**

Este tipo de célula possui como eletrólito uma membrana polimérica (politetrafluoretileno), que permite somente a passagem de prótons (íons  $H^+$ ) [29]. Suas principais vantagens são o eletrólito sólido e uma baixa temperatura de operação (inferior a  $100^{\circ}C$ ), que fazem das células PEM o tipo de CaC mais simples e com a maior variedade de aplicações [31].

Por outro lado, devido à relativa baixa temperatura de operação, a cinética da reação química fica prejudicada e, por este motivo, nestas CaC's são tipicamente utilizados catalisadores de metais preciosos em seus eletrodos [32]. Estes materiais fazem com que as CaC's do tipo PEM ainda não sejam competitivas em termos de custo. Porém, pesquisas recentes, com catalisadores de metais não preciosos, têm relatado resultados capazes de atender à requisitos de aplicações comerciais com esse tipo de célula [33].

Empilhamentos de CaC's tipo PEM podem ser produzidos desde pequenas unidades, com poucos watts de potência, até unidades maiores, com 100 kW [32, 34]. As aplicações mais comuns deste tipo de CaC são geração distribuída com cogeração<sup>7</sup> (onde o calor é aproveitado principalmente para o aquecimento de água em residências), fontes de alimentação ininterruptas e, principalmente, em veículos [32]. Para aplicações veiculares, as CaC's do tipo PEM são consideradas a tecnologia mais adequada, pois possuem alta densidade de potência e são, portanto, mais compactas [29, 35].

#### **Célula alcalina ou AFC (*Alkaline Fuel Cell*)**

Este tipo de célula utiliza uma solução alcalina como eletrólito e, portanto, permite

---

<sup>7</sup>Produção e utilização combinada de eletricidade e calor.

a locomoção de íons  $\text{OH}^-$  [31]. A principal vantagem das células alcalinas é o seu baixo custo em comparação aos outros tipos de CaC's, devido aos materiais que a compõem, como a solução de hidróxido de potássio (KOH) tipicamente usada como eletrólito, e seus eletrodos que podem ser feitos de metais não preciosos [29]. Além disso, as CaC's alcalinas, assim como as do tipo PEM, operam em temperaturas consideradas baixas (menores que  $100^\circ\text{C}$ ).

A principal desvantagem das células alcalinas é a sua susceptibilidade ao envenenamento por  $\text{CO}_2$ , que reage com o eletrólito mesmo em pequenas concentrações e faz com que a eficiência da CaC diminua [32]. Por este motivo, o hidrogênio e o oxigênio devem ser fornecidos puros a este tipo de célula. As células alcalinas foram o primeiro tipo de CaC desenvolvido, ainda no final da década de 1930, e foram utilizadas principalmente em aplicações espaciais [29]. Em geral, a potência típica de empilhamentos desse tipo de CaC varia de 1 a 5 kW [31].

### **Célula de óxido sólido ou SOFC (*Solid Oxide Fuel Cell*)**

Nas CaC's de óxido sólido, o eletrólito é constituído de um material cerâmico, a base de zircônia, que permite a condução de íons  $\text{O}^{2-}$  [31]. Este tipo de célula opera em altas temperaturas, tipicamente entre  $800\text{-}1000^\circ\text{C}$  [32]. A temperatura elevada garante a CaC de óxido sólido altas taxas de reação sem necessidade de catalisadores caros. Além disso, ela também permite que o gás natural seja usado diretamente como combustível, sem a necessidade de um reformador para produção do gás hidrogênio [29].

Os materiais cerâmicos dos quais as CaC's de óxido sólido são feitas são caros de fabricar, e esse tipo de célula requer um grande número de equipamentos auxiliares para criar um sistema completo funcional, como pré-aquecedores de ar e de combustível [29]. Além disso, devido à operação em altas temperaturas o sistema de refrigeração destas células é mais complexo.

Os empilhamentos de CaC's de óxido sólido podem ser fabricados com uma potência nominal de centenas de kW [32]. Por esta razão, as principais aplicações para esse tipo de célula são geração distribuída com cogeração, pois a operação em temperaturas elevadas favorece o aumento da eficiência nesses casos, e geração centralizada de grandes quantidades de energia [31]. Em aplicações com cogeração, aproveita-se o calor dos gases de exaustão, o calor não é retirado da CaC, portanto seu desempenho não é afetado.

### **Célula de ácido fosfórico ou PAFC (*Phosphoric Acid Fuel Cell*)**

Nestas células, o eletrólito é de ácido fosfórico ( $\text{H}_3\text{PO}_4$ ) puro e, assim como nas CaC's tipo PEM, permite a locomoção dos íons  $\text{H}^+$  [29]. As CaC's de ácido fosfórico operam com temperaturas intermediárias (da ordem de  $200^\circ\text{C}$ ) e, por este motivo,

podem ser supridas com outros tipos de combustível além do hidrogênio, como o gás natural liquefeito (GNL) e o óleo diesel [31]. Outra vantagem deste tipo de células é uma maior tolerância a impurezas no combustível, uma vez que o eletrólito ácido não reage com o  $\text{CO}_2$  [32].

As CaC's de ácido fosfórico, contudo, possuem baixa densidade de energia e, portanto, são maiores e mais pesadas se comparadas com outros tipos de células com a mesma capacidade de potência [31]. Além disso, devido à alta temperatura de operação, o início do PAFC é mais lento. As principais aplicações deste tipo de célula consiste principalmente em geração distribuída, uma vez que sua temperatura operacional está em uma faixa adequada para cogeração e para sistemas de refrigeração por absorção [32].

### **Célula de carbonatos fundidos ou MCFC (*Molten Carbonate Fuel Cell*)**

Neste tipo de célula, o eletrólito consiste em uma mistura de carbonatos de metais alcalinos, como o lítio, o sódio e o potássio, fundidos a alta temperatura (entre 600 e 700°C), e que permite a locomoção de íons  $\text{CO}_3^{2-}$  [29, 34]. Sua principal vantagem é a capacidade de operar com gases obtidos a partir da reforma de gás natural, ou mesmo do carvão, devido à sua tolerância ao monóxido e dióxido de carbono [32].

A alta temperatura das CaC's de carbonatos fundidos permite o uso de níquel como catalisador, que é relativamente barato em comparação com catalisadores de platina usado nas CaC's PEM por exemplo. Como desvantagem, as temperaturas mais altas destas CaC's impõem exigências severas à estabilidade à corrosão e à vida útil dos componentes, principalmente devido ao ambiente agressivo do eletrólito, que é uma mistura quente e corrosiva, como apresentado em [29, 32].

Assim como os empilhamentos de CaC's de óxido sólido, os de carbonatos fundidos também podem ser fabricados com uma potência nominal de centenas de kW ou mesmo MW [32, 34]. Portanto, as principais aplicações para esse tipo de célula são geração distribuída (cogeração) e geração centralizada de grandes quantidades de energia [31].

### **1.3.3 Controle de Sistemas de Células a Combustível**

Como mencionado anteriormente, as CaC's do tipo PEM são consideradas a tecnologia mais adequada para aplicações veiculares. Doravante, neste trabalho cujo foco são os VEHCC's, o termo CaC será usado para se referir indistintamente às células ou empilhamento de células deste tipo.

Para que seja viabilizado o seu funcionamento, as CaC's precisam ser integradas a diversos subsistemas auxiliares. Um sistema de geração com CaC requer no mínimo um sistema de abastecimento de hidrogênio para o anodo e um sistema de

abastecimento de ar<sup>8</sup> para o catodo. Em alguns casos, dependendo do tipo de CaC, ainda podem ser necessários um sistema de arrefecimento com água deionizada e um sistema umidificador de hidrogênio [36]. Uma resposta eficiente do sistema com CaC's depende do controle apropriado destes sistemas BdP, satisfazendo padrões de desempenho, confiabilidade e segurança.

Considerando o abastecimento de hidrogênio, as CaC's PEM podem ser de anodo de fluxo contínuo ou de anodo fechado. Na Figura 1.2 é mostrada uma representação gráfica ilustrando esses dois modos de operação. No modo anodo de fluxo contínuo (Figura 1.2a), o hidrogênio flui continuamente através do canal anódico do empilhamento e não há bloqueio na saída do gás. No modo anodo fechado (Figura 1.2b), há uma válvula na saída do canal do ânodo que fica normalmente fechada, mas deve ser aberta periodicamente para eliminar o excesso de água e gases inertes dentro do canal. O modo anodo fechado costuma ser mais eficiente e vantajoso pois requer menos componentes auxiliares que adicionam peso, volume e custo ao sistema, enquanto o anodo de fluxo contínuo depende de um circuito de recirculação para manter uma alta utilização de hidrogênio [37].

Tipicamente, no modo anodo fechado as CaC's são alimentadas com hidrogênio puro e a sua operação depende do controle da pressão na entrada do anodo. Com a válvula de saída fechada, um controlador local garante uma pressão constante na entrada do anodo e, desta maneira, garante-se que a pressão no seu interior permaneça constante mantendo-se a estequiometria da reação [36]. Nas CaC's que operam com anodo de fluxo contínuo, uma válvula é usada para controlar o fluxo de massa de hidrogênio na entrada do anodo. Em alguns sistemas, o fluxo de hidrogênio pode ser umidificado antes de entrar na CaC.

Em uma CaC de anodo fechado, o intervalo e a duração das purgas na saída do anodo podem ser controlados para haver uma perda mínima de hidrogênio. No caso ideal, não seriam necessárias as purgas e nenhum hidrogênio seria desperdiçado. Porém, durante a operação da CaC ocorre um acúmulo de nitrogênio (N<sub>2</sub>) e água líquida no anodo, o que pode causar danos a célula [37]. Portanto, deve-se estabelecer um compromisso entre evitar a degradação e a minimização das perdas de hidrogênio durante a purga. Um intervalo menor entre as purgas e um maior tempo de abertura da válvula na saída tendem a melhorar o funcionamento do sistema, evitando a degradação [37]. Por outro lado, intervalos maiores entre as purgas e menor tempo de abertura da válvula, reduzem as perdas de hidrogênio [37].

Além do subsistema de abastecimento de hidrogênio, o subsistema que fornece oxigênio ao catodo é um dos principais componentes controlados em uma CaC. Considerando a sua operação quanto ao tipo de catodo, as CaC's podem ser de catodo aberto ou fechado. As CaC's de catodo aberto possuem os canais do catodo

---

<sup>8</sup>O oxigênio necessário para a reação é proveniente do ar ambiente.

expostos ao ambiente e, portanto, sua pressão de operação é em torno da pressão atmosférica, com o ar sendo fornecido por um sistema de ventilação de baixa potência ou por convecção. Nas CaC's de catodo fechado por sua vez, o ar é fornecido por um compressor a pressões tipicamente mais altas que a atmosférica.

A operação das CaC's com pressões mais altas possibilita um melhor desempenho e tensões terminais mais elevadas [36]. Contudo, tal benefício vem ao custo de um aumento da complexidade do sistema e da introdução de equipamentos que representam cargas parasitas (compressor, sistema de arrefecimento e umidificador, por exemplo). As CaC's de catodo aberto, por outro lado, tem como vantagem possuir um subsistema de abastecimento de ar simplificado. Por fim, nas CaC's de catodo aberto, o sistema de ventilação que sopra o ar para o seu interior também possuem a dupla função de controle de temperatura, e pode soprar mais ar para manter a temperatura dentro de um limite de segurança [38].

Para um funcionamento apropriado e seguro da CaC, o controle do sistema de abastecimento de ar deve garantir que a quantidade de oxigênio no catodo atenda a estequiometria da reação (1.3). Caso contrário, a CaC pode sofrer degradação devido a um fenômeno chamado “inanição por oxigênio” [36]. Este fenômeno ocorre quando a pressão parcial do oxigênio cai abaixo de um nível crítico dentro do catodo, reduzindo a tensão terminal da CaC e também a sua vida útil.




Figura 1.2: Representação gráfica de um empilhamento de células a combustível de (a) anodo de fluxo contínuo e (b) anodo fechado.

Na literatura, diversos estudos tratam do problema de inanição, onde propõem o controle fator de excesso de oxigênio [38–44], que consiste na razão entre o fluxo de oxigênio que entra no catodo e fluxo efetivamente consumido pela reação. O desafio neste caso é que quando há um aumento da corrente extraída da CaC, o oxigênio no catodo é consumido instantaneamente, enquanto a taxa na qual é fornecido é limitada pelas restrições operacionais do compressor no caso das CaC de alta pressão, ou do sistema de ventilação no caso das CaC's de baixa pressão [36]. Alguns autores propõem o uso de um governador de carga [44], que controla a corrente da CaC tornando sua resposta mais lenta para garantir que as restrições no nível de oxigênio sejam atendidas. Uma outra solução consiste em utilizar a CaC em conjunto com uma outra fonte de corrente auxiliar e recarregável (como supercapacitores ou baterias), capaz de responder rapidamente aos transitórios da carga [43]. A fonte auxiliar pode ser recarregada pela CaC e tem a função de atenuar os picos de corrente da carga.

Além da inanição de oxigênio, um segundo problema relacionado ao sistema de abastecimento de ar das CaC's do tipo PEM é redução da eficiência. O sistema de abastecimento de ar é o componente responsável pelo maior consumo energia elétrica, principalmente nas CaC's cujo abastecimento de ar é feito por um compressor acionado por um motor elétrico [42]. Assim, ao considerar o balanço energético global do sistema, a energia “líquida” gerada pela CaC diminui caso o compressor precise ser acionado com mais potência para manter a vazão de ar. Por esta razão, os trabalhos de pesquisa que tratam do problema da inanição buscam ao mesmo tempo otimizar o uso sistema de abastecimento de ar, para garantir uma maior eficiência do sistema [38–42].

Nos sistemas de propulsão com CaC's, um sistema de gerenciamento de energia é encarregado do controle da energia que deve ser gerada pela CaC. A corrente da CaC pode ser considerada como uma perturbação, pois impacta diretamente os subsistemas de BdP [36]. Quando uma CaC é utilizada em conjunto com outra fonte de energia, o gerenciamento de energia entre as fontes pode ser feito através do controle da corrente, usada como variável de controle. Na próxima seção é feita uma revisão bibliográfica e são descritos com mais detalhes os sistemas de gerenciamento de energia em VEHCC's.

## 1.4 Gerenciamento de Energia em Veículos Elétricos Híbridos a Células a Combustível

O caso mais geral de gerenciamento de energia em VE's é o dos VEHP's, e por este motivo é descrito brevemente a seguir. Tipicamente, o gerenciamento de energia em

um VEHP compreende uma fase de depleção de carga e uma fase de sustentação de carga, como ilustrado na Figura 1.3 (adaptada de [45]). Essas duas fases funcionam da seguinte forma:

- **Depleção de Carga:** Neste modo, a energia para a propulsão é fornecida integralmente pelas baterias. Neste caso, o veículo funciona como um VEB e o estado de carga (EdC) da bateria decresce até atingir um nível mínimo definido pelo controlador.
- **Sustentação de Carga:** Neste modo, o EdC da bateria é controlado para permanecer dentro de uma faixa definida pelo controlador. Assim, o combustível consiste na principal fonte de energia do veículo, e a bateria pode atuar durante a frenagem regenerativa, as acelerações ou nas zonas de baixa eficiência da outra fonte de energia. O modo sustentação de carga é o modo no qual os VEH's convencionais costumam operar.

A alocação dos recursos energéticos em sistemas de propulsão híbridos pode ser realizada com métodos de otimização *offline* (não-causais) ou controladores *online* (causais) [8]. Os métodos não-causais são ferramentas úteis que garantem um desempenho ideal do veículo, desde que o ciclo de condução seja conhecido antecipadamente. Por sua vez, os controladores causais gerenciam os recursos energéticos com base nas informações passadas e atuais disponíveis no sistema. Originalmente, esses esquemas (*offline* e *online*) foram desenvolvidos para VEH's convencionais, mas os mesmos princípios podem ser aplicados aos VEHCC's.

Em geral, as técnicas de otimização *offline* são usadas como referência para a avaliação de controladores *online*, como em [35, 46]. As aplicações típicas podem ser veículos de transporte público ao longo de rotas fixas ou veículos de competição em um determinado circuito de corrida [8], onde o ciclo de condução já é conhecido.




Figura 1.3: Ilustração de um ciclo de descarga típico de um veículo elétrico híbrido *plug-in* (VEHP).

Caso contrário, seria necessário um método para prevê-lo [47]. Quando há pouco ou nenhum conhecimento das condições futuras de direção, os controladores *online* são usados, como na maioria das aplicações reais. Tais controladores podem ser divididos entre aqueles baseados em métodos heurísticos e os baseados na teoria de controle ótimo [8].

Os métodos heurísticos consistem em estratégias baseadas em regras que podem mudar o modo de operação do sistema de propulsão com base no estado atual das variáveis veiculares. No caso de VEHCC's, algumas diretrizes são normalmente seguidas, como priorizar o uso da CaC apenas na sua zona de eficiência máxima e manter o estado de carga da bateria dentro de limites predefinidos (sustentação de carga). Dentre os métodos heurísticos, o controle por banda de histerese (CBH) se destaca como o mais popular para gerenciar diferentes fontes de energia e unidades de armazenamento [48, 49]. Tipicamente, no CBH, são definidos diferentes modos de operação da CaC, como eficiência máxima e potência máxima [49]. As regras de transição entre esses modos, por sua vez, bem como as larguras das bandas de histerese costumam ser definidas em função do EdC da bateria para garantir a sustentação de carga. Por outro lado, os limites que separam os diferentes modos de operação da CaC também podem ser definidos pelo uso de controladores *fuzzy* [35, 50]. Alguns trabalhos também propõem melhorias nas estratégias heurísticas, e fazem o rastreamento de ponto de eficiência máxima e rastreamento de ponto de potência máxima da CaC usando identificação adaptativa [51], modelagem por redes neurais [52] e busca extremal [53].

Controladores heurísticos, como o CBH, são intuitivos de se conceber com base nas especificações de controle [8]. Ademais, possuem outras vantagens como confiabilidade e a capacidade de proteger as baterias contra sobrecargas [48]. Entretanto, eles não exploram necessariamente o desempenho ótimo do veículo [8] e, em sistemas híbridos mais complexos, pode operar a planta de maneira ineficiente [48, 54]. E apesar de trabalhos como [51–53] aprimorarem os métodos de rastreamento dos pontos de máxima potência e de máxima eficiência, eles ainda dependem de regras heurísticas para executar o gerenciamento de energia entre diferentes fontes e unidades de armazenamento. Por fim, controladores como o CBH proporcionam um número frequente de ciclos de partida e parada da CaC, contribuindo para o processo de degradação do equipamento [55].

Além de métodos heurísticos de gerenciamento de energia, em um contexto mais atual, novos controladores causais baseados na teoria de controle ótimo tem ganhando popularidade. Esses controladores também são chamados de controladores sub-ótimos, pois fornecem um desempenho quase ideal. Dentre eles, o controle preditivo baseado em modelo (CPBM) se destaca devido à sua capacidade de lidar com muitas restrições do sistema, mesmo que ainda sejam simultâneas [43, 56–63]. Para

o gerenciamento de energia em sistemas de propulsão híbridos, o CPBM permite a possibilidade de lidar com um problema multi-variável, realizando o balanço energético de várias fontes de energia. Nesse sentido, o CPBM resolve um problema de otimização com múltiplos objetivos, cuja solução consiste em um ponto ótimo da alocação de recursos do sistema híbrido. Ou seja, os recursos energéticos do sistema de propulsão são alocados de uma maneira na qual seria impossível melhorar um objetivo individual, sem piorar pelo menos um outro objetivo.

## 1.5 Identificação do Problema

Na literatura especializada, trabalhos que empregam CPBM em aplicações reais de sistemas com CaC's são menos comuns, em oposição aos que utilizam os métodos heurísticos bem estabelecidos [59]. Além disso, em diversas aplicações encontradas [43, 56–60, 62], são utilizados modelos físicos de CaC's, elaborados a partir de fenômenos eletroquímicos e termodinâmicos que regem o seu comportamento. Contudo, estes modelos costumam ser baseados em premissas que nem sempre são válidas para empilhamentos reais de CaC's, e que negligenciam fenômenos importantes.

Em um empilhamento de CaC's, a tensão terminal é dada pela soma das tensões individuais de cada uma das células conectadas em série. Sob a hipótese de que todas as células são idênticas, costuma-se calcular a tensão terminal de maneira aproximada, a partir da multiplicação da tensão de cada célula unitária pelo número total de células em série [64, 65]. Em trabalhos com CPBM aplicado a sistemas com CaC's [39, 43], também é recorrente que a modelagem do fluxo de massa dos gases nos canais do anodo e do catodo seja feita baseada em princípios de conservação de massa. Para que esta abordagem seja válida, são normalmente estabelecidas algumas premissas [36], por exemplo:

1. Temperatura constante e distribuída uniformemente por todo o empilhamento;
2. Canais do anodo e do catodo são considerados, cada um, como um volume único (parâmetro concentrado), ou seja, não é levada em conta a geometria;
3. Toda água sob forma líquida é expelida dos canais dos eletrodos.

Porém, na prática não se pode garantir que, em um empilhamento, todas as células sejam idênticas e tampouco que todas operem nas mesmas condições de umidade, temperatura e distribuição de pressões parciais em seu interior. Gradientes de temperatura são formados ao longo do empilhamento [66] e até mesmo, internamente, em células unitárias [67]. Ademais, como demonstrado em [68], as pressões dos gases reagentes não são distribuídas uniformemente no interior de empilhamento. Final-

mente, modelos como o apresentado em [36] não levam em conta os efeitos da água sob forma líquida que se acumula nos eletrodos.

Em empilhamentos de CaC's do tipo PEM, o balanço de água é um aspecto crítico no que diz respeito à sua capacidade de geração de energia e tempo de vida útil. A resistência da membrana polimérica à passagem dos prótons varia consideravelmente em função do seu grau de hidratação [69]. Uma membrana bem hidratada apresenta melhor condutividade e, conseqüentemente, as perdas são diminuídas. Entretanto, água em excesso pode causar o alagamento dos eletrodos, acarretando no bloqueio dos poros por onde passam normalmente os gases reagentes ( $H_2$  e  $O_2$ ) [70].

Idealmente, a água produzida pela reação (1.3) e o vapor presente no ar atmosférico seriam o suficientes para manter a membrana hidratada quando passam do catodo para o anodo em difusão reversa, e qualquer excedente seria removido do catodo pelo ar fornecido por um soprador ou compressor externo [69]. Porém, não se pode garantir que isso aconteça em empilhamentos reais. Além disso, em altas correntes, o arrasto eletro-osmótico excede a difusão reversa de água do cátodo para o ânodo [36], podendo levar ao ressecamento da membrana no lado do anodo. A operação de células secas durante um longo período de tempo pode causar danos sérios e irreversíveis à membrana [70].

Uma consequência comum aos incidentes de alagamento e ressecamento das CaC's é uma queda na sua tensão terminal [71], o que reduz a sua capacidade de geração de energia. Dessa forma, o projeto e análise de sistemas de controle que buscam otimizar a performance energética de sistemas com CaC's ficam comprometidos, uma vez que potência e eficiência de empilhamentos de CaC's alteram-se com as variações de condições de operação.

Além dos modelos eletroquímicos clássicos, também são encontrados modelos mais elaborados, que representam de maneira mais completa os diversos fenômenos no interior das CaC's. Em [68], por exemplo, é proposto um modelo de duas dimensões (2D) que abrange características fluídicas e eletroquímicas da CaC, e que consideram, em particular, a forma geométrica dos canais do anodo e do catodo. Desta maneira, o modelo pode calcular com precisão a distribuição da pressão dos gases reagentes na superfície dos eletrodos do empilhamento. Em [65], Luna et al. propõem em um modelo da área da superfície eletroquimicamente ativa, que corresponde a uma medida da área total de platina<sup>9</sup> disponível na região do catodo. A área de superfície ativa está diretamente ligada à eficiência da CaC, quanto maior for a área, maior a eficiência.

Modelos como os propostos em [68] e [65] são difíceis de serem usados em aplicações de controle em tempo real devido à sua complexidade, com muitos parâmetros e variáveis a serem considerados, alguns dos quais são de difícil medição. Em apli-

---

<sup>9</sup>Nas CaC's do tipo PEM, a platina é comumente utilizada como catalisador.

cações reais é desejável minimizar a instrumentação incorporada, especialmente em aplicações veiculares onde peso e volume são críticos. Além disso, a complexidade do modelo também aumenta consideravelmente o esforço computacional em aplicações de CPBM. Em [65], por exemplo, o modelo proposto é usado em uma aplicação de CPBM não linear, cujo objetivo é a maximização da área ativa. A validação do CPBM não linear é feita através de simulações no MATLAB e o trabalho mostra que, em alguns instantes, o tempo de cálculo do controlador ultrapassa o tempo de amostragem, o que não é viável para aplicações em tempo real.

Para contornar os problemas levantados acima, Lopes propõe em [69] o uso de redes neurais recorrentes para modelar o comportamento dinâmico de empilhamentos de CaC's do tipo PEM. Essa estratégia de modelagem é justificada pelo fato de que mudanças nas condições internas de um empilhamento de CaC's afetam diretamente sua tensão terminal [72]. As redes neurais recorrentes são modelos auto-regressivos, ou seja, a variável predita é calculada em função de seus valores passados [73]. Portanto, a precisão do modelo neural é mantida porque suas previsões dependem dos valores passados da tensão usada na entrada, o que leva em consideração todas as variações internas. Em comparação com os modelos eletroquímicos tradicionalmente usados em aplicações de CPBM para sistemas com CaC's [43, 56–58, 60, 62], as redes neurais recorrentes podem reproduzir com mais exatidão o comportamento não-linear das CaC's.

A modelagem por redes neurais recorrentes foi proposta em [69] com vistas a aplicações de CPBM, um tipo de controle no qual um modelo do processo é usado explicitamente na obtenção do sinal de controle [74]. Nestes controladores, o modelo realiza previsões do comportamento futuro do processo sobre um intervalo de tempo finito, e o sinal de controle é obtido através da solução de um problema de otimização baseado nessas previsões. Por este motivo, o projeto do CPBM necessita o melhor modelo possível, para capturar completamente a dinâmica do processo e permitir o cálculo das previsões [74].

Nos últimos anos, o CPBM se popularizou para aplicações de gerenciamento energético em VEHCC's [39, 43, 56–58, 60–62, 65]. Entretanto, nestas aplicações mencionadas (exceto em [61, 65]) são usadas técnicas de CPBM linear, que empregam modelos físicos e linearizados dos empilhamentos de CaC's. Conforme mencionado anteriormente, os modelos eletroquímicos clássicos são geralmente estabelecidos através de certas suposições e simplificações que nem sempre são válidas para empilhamentos reais. Ademais, representações lineares de sistemas não-lineares podem fornecer previsões imprecisas quando o sistema não está operando na vizinhança de um ponto de operação. Este é o caso de aplicações veiculares, onde nem sempre a CaC estará em regime estacionário pois o veículo deve responder aos comandos de aceleração do motorista.

As abordagens de controle reportadas na literatura são, na sua maioria, testadas apenas em simulação, como no caso dos trabalhos apresentados em [43, 56–58, 63, 65]. No CPBM, a cada instante de amostragem, o controlador deve resolver um problema de otimização, o que geralmente requer um grande esforço computacional. Por esta razão, há dificuldade em encontrar validações experimentais do controlador preditivo em tempo real. Em [39], para contornar esse problema e garantir um tempo de execução rápido o suficiente, Arce et al. propõem o uso de um CPBM explícito. Neste caso, todas as regiões de operação do controlador são calculadas *offline*, durante o seu projeto. Assim, o controlador apenas faz uma busca sequencial nessas regiões de operação para escolher a melhor solução, e não há necessidade de resolver o problema de otimização a cada amostragem.

Apesar de [39] validar experimentalmente o CPBM com resultados experimentais em tempo real, no esquema proposto ainda é empregada a linearização de um modelo físico do empilhamento de CaC's. Além disso, como o trabalho utiliza um CPBM explícito, não haverá garantias de que a solução do problema de otimização encontrada *offline* ainda será válida quando a CaC estiver em operação, devido às variações nas suas condições internas. Na literatura são poucos os trabalhos experimentais encontrados, e são mais restritos a aplicações estacionárias [48, 59, 75, 76]. De qualquer maneira, mesmo estes utilizam modelos físicos linearizados.

Lopes, em [69], propõe a modelagem de empilhamentos de CaC's por redes neurais recorrentes para aplicações em CPBM, e sugere um esquema de controle como o da Figura 1.4 para rastrear a eficiência máxima de um empilhamento de CaC's do tipo PEM. Entretanto, apesar da validação do modelo com dados experimentais, não há uma implementação do controlador, nem mesmo em simulação. Além disso, rastrear a eficiência máxima usando um esquema como o da Figura 1.4 é inviável. A implementação deste esquema requereria um conhecimento prévio do valor máximo da eficiência para ser usado como referência ( $\eta_{ref}$ ), e também implica que ela tenha um valor fixo. Porém, como mencionado anteriormente, e defendido por Lopes em [69], não é possível conhecer esse valor exato, tampouco considerá-lo fixo.




Figura 1.4: Diagrama de um sistema de controle para rastrear a eficiência máxima de um empilhamento de células a combustível (CaC's).

## 1.6 Objetivos do Trabalho

O objetivo principal deste trabalho consiste no desenvolvimento de um sistema de gerenciamento de energia (SGE) para um VEHCC. O SGE proposto é baseado no CPBM não linear e emprega uma rede neural recorrente para modelar um empilhamento de CaC's do tipo PEM. O CPBM não linear possibilita a formulação de objetivos de controle que não seriam possíveis com o CPBM linear, como o rastreamento de ponto de eficiência máxima do empilhamento de CaC's. Ao mesmo tempo, a modelagem por redes neurais permite prever com mais precisão a dinâmica não linear do empilhamento.

Neste trabalho, o sistema de controle proposto tem como função principal gerenciar efetivamente a energia no veículo, usando um empilhamento de CaC's e uma bateria. Como objetivo adicional, o controle proposto também deve ter a função de rastrear o ponto de eficiência máxima do empilhamento, mesmo que ele seja desconhecido e variante no tempo. O SGE proposto é implementado em uma placa controladora de baixo custo, e são realizados experimentos em tempo real em uma bancada de teste de *hardware-in-the-loop* (HiL) equipada com um empilhamento de CaC's real.

Neste sentido, o presente trabalho tem como objetivos específicos:

1. Apresentar uma revisão e análise crítica dos principais sistemas de gerenciamento de energia encontrados na literatura, destacando suas limitações com foco nas aplicações em veículos elétricos híbridos a células a combustível (VEHCC's);
2. Descrever a modelagem quase-estática de um VEHCC para uso em simulações e testes HiL, tipicamente feitos durante a fase de validação de controladores em tempo real que fazem o gerenciamento de energia em tempo real de VEHCC's;
3. Apresentar uma revisão sobre os fundamentos do controle preditivo baseado em modelo linear e não linear;
4. Propor um sistema de gerenciamento de energia (SGE) baseado no controle preditivo baseado em modelo não linear e que emprega uma rede neural recorrente para modelar um empilhamento de células a combustível (CaC's) do tipo PEM;
5. Testar e validar experimentalmente o sistema de controle proposto.

As principais contribuições deste trabalho consistem em: 1) aplicação prática do controle preditivo baseado em modelo não linear; 2) uso uma rede neural recorrente como modelo de um empilhamento de CaC's PEM em uma aplicação de CPBM; e

3) proposta de uma função de custo com um termo para o rastreamento da eficiência máxima do empilhamento de CaC's PEM.

## 1.7 Publicações

Os artigos publicados durante o período de realização deste trabalho de doutorado são listados a seguir.

### Artigo publicado em periódico internacional

1. Pereira, D. F., Lopes, F. C., Watanabe, E. H. "Nonlinear Model Predictive Control for the Energy Management of Fuel Cell Hybrid Electric Vehicles in Real Time", *IEEE Transactions on Industrial Electronics*, DOI 10.1109/TIE.2020.2979528, Mar. 2020.

### Artigos completos publicados em anais de congressos

1. Pereira, D. F., Lopes, F. C., Watanabe, E. H. "Neural Generalized Predictive Control for Tracking the Maximum Efficiency and Maximum Power Points of PEM Fuel Cell Stacks", *IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society*, DOI 10.1109/IECON.2018.8591290, Oct. 2018.
2. Pereira, D. F., Lopes, F. C., Watanabe, E. H. "Prediction of PEMFC Stack Efficiency Using Recurrent Neural Networks", *2017 IEEE 26th International Symposium on Industrial Electronics (ISIE)*, DOI 10.1109/ISIE.2017.8001385, Jun. 2017.

## 1.8 Organização do Documento

Este trabalho está organizado em cinco capítulos, referências bibliográficas e apêndices. O escopo de cada um dos cinco capítulos é detalhado a seguir.

### Capítulo 1: Introdução

Neste primeiro capítulo são apresentados os problemas que motivaram a elaboração deste trabalho e os principais objetivos do mesmo. São revisados alguns conceitos relacionados aos veículos elétricos e às CaC's, e também é feita uma revisão bibliográfica sobre os sistemas de controle de CaC's e sistemas de gerenciamento de energia em VEH's e VEHCC's.

## **Capítulo 2: Veículo Elétrico Híbrido a Célula a Combustível**

O segundo capítulo descreve a arquitetura do sistema de propulsão do VEHCC proposto, bem como a modelagem de seus principais componentes. Os modelos desenvolvidos no Capítulo 2 são usados tanto como modelos de predição no CPBM para o gerenciamento de energia de um VEHCC, proposto no Capítulo 3, quanto na implementação da bancada de testes HiL, apresentada no Capítulo 4.

## **Capítulo 3: Sistema de Gerenciamento de Energia Preditivo Neural**

O terceiro capítulo trata do CPBM não linear aplicado ao gerenciamento de energia de VEHCC's usando uma rede neural recorrente como modelo de predição de um empilhamento de CaC's do tipo PEM. Inicialmente é feita uma revisão de fundamentos da teoria do CPBM onde são apresentadas duas formulações, uma considerando CPBM linear e outra o caso não-linear. Em seguida, é proposta uma metodologia de gerenciamento de energia de um VEHCC com CPBM não linear.

## **Capítulo 4: Resultados e Discussões**

No quarto capítulo são apresentados os resultados obtidos nos experimentos com a bancada HiL, para validar e demonstrar o funcionamento do sistema de gerenciamento de energia proposto.

## **Capítulo 5: Conclusão**

O quinto e último capítulo faz um resumo do trabalho desenvolvido, com destaque para as contribuições desta tese de doutorado. Ao final, são apresentadas sugestões de trabalho que podem ser desenvolvidos futuramente, para dar continuidade ao estudo dos temas relacionados a este trabalho.

## Capítulo 2

# Veículo Elétrico Híbrido a Célula a Combustível

Neste capítulo é feita uma descrição da arquitetura do sistema de propulsão do VEHCC utilizado neste trabalho e são apresentados os modelos dos seus principais componentes. O capítulo faz inicialmente uma exposição da modelagem da dinâmica do movimento longitudinal do veículo e, em seguida, descreve o método de aproximação quase-estática desse modelo. O modelo quase-estático é usado no cálculo da demanda de energia mecânica do veículo para que ele siga uma determinada velocidade em um ciclo de condução. Ainda seguindo uma abordagem quase-estática, o cálculo da potência elétrica que deve ser fornecida pelas fontes de energia do VEHCC é feito levando em consideração as perdas no motor elétrico e nos conversores que integram o sistema de propulsão. Posteriormente, o capítulo apresenta o modelo da bateria empregado nas simulações em tempo real do VEHCC.

O capítulo apresenta ainda alguns fundamentos de eletroquímica, de termodinâmica e de fenômenos de transportes nos quais se baseiam o funcionamento e os modelos das CaC's tipo PEM. O objetivo é mostrar as principais dificuldades associadas à representação da CaC por meio de modelos físicos, que são complexos e dependem de variáveis de difícil medição. No CPBM não linear proposto nesta tese, cuja formulação é descrita no Capítulo 3, um modelo da CaC's do tipo PEM baseado em redes neurais recorrentes é utilizado. A técnica de modelagem de CaC's por redes neurais é descrita ao final deste capítulo.

### 2.1 Arquitetura do Sistema de Propulsão

Um diagrama com os principais elementos do VEHCC empregado neste estudo é mostrado na Figura 2.1. Neste trabalho foi considerada uma arquitetura em série [8, 12] para o VEHCC, onde o empilhamento de CaC's do tipo PEM consiste na




Figura 2.1: Configuração do sistema de propulsão do veículo elétrico a célula a combustível (VEHCC) mostrando o fluxo de energia.

fonte de energia primária e uma bateria opera como *buffer* de energia. Como mostra a Figura 2.1, a CaC, a bateria e o motor elétrico são conectados através de um elo de corrente contínua (cc). Um conversor cc/cc elevador de tensão do tipo *boost* faz a interface da bateria com o elo cc que, por sua vez, é formado pela bateria e alimenta o motor através de um inversor, que converte a tensão de cc para corrente alternada (ca). Nesta configuração, a CaC pode carregar a bateria através do conversor cc/cc, enquanto a potência elétrica demandada pelo motor age como uma perturbação.

Neste trabalho, é considerada a hipótese que subsistemas auxiliares da CaC, como os subsistemas de abastecimento de hidrogênio e de ar, possuem um controlador local e embutido no balanço de planta (BdP, descrito na seção 1.3.3) da Figura 2.1. Portanto, na arquitetura proposta, apenas a corrente do empilhamento  $i_{FC}$  pode ser controlada diretamente pelo conversor cc/cc e corresponde ao único grau de liberdade do sistema de gerenciamento de energia proposto nesta tese.

A potência  $P_{EM}$  demandada pelo motor elétrico atua como uma perturbação no elo cc da Figura 2.1, enquanto a potência da bateria  $P_{BT}$  é dada pela diferença entre  $P_{EM}$  e a potência fornecida pelo empilhamento  $P_{FC}$ . Dessa maneira, o balanço de potências no elo cc é dado por

$$\eta_b P_{FC} + P_{BT} - \frac{P_{EM}}{\eta_i} - P_{AS} = 0, \quad (2.1)$$

onde  $\eta_b$  é a eficiência do conversor cc/cc e  $\eta_i$  é a eficiência do inversor. O termo  $P_{AS}$  foi omitido na Figura 2.1 para facilitar a visualização, mas foi adicionado em (2.1) para representar o consumo de cargas que não são representadas no diagrama, como por exemplo ar condicionado (se houver) e faróis, entre outros acessórios.

## 2.2 Demanda de Energia Mecânica do Veículo

### 2.2.1 Dinâmica Longitudinal

A Figura 2.2 apresenta um diagrama com as principais forças que atuam em um veículo terrestre que se movimenta em uma via inclinada. Nesta figura, o veículo é representado por um corpo de massa total  $m_V$ , sujeito à aceleração gravitacional  $g$  e que se move com velocidade  $v$  em função do tempo  $t$ . De acordo com a Segunda Lei de Newton, a dinâmica longitudinal deste corpo é descrita por

$$m_V \frac{dv}{dt} = F_t(t) - F_a(t) - F_r(t) - P_x(t), \quad (2.2)$$

onde  $F_t$  é a força de tração do veículo,  $F_a$  corresponde à força de arrasto aerodinâmico,  $F_r$  é a força devido ao atrito de rolamento e  $P_x$  é a componente da força gravitacional na direção  $x$  paralela a via com ângulo de inclinação  $\theta$ . A força  $P_y$  corresponde a componente da força gravitacional na direção  $y$  perpendicular ao plano da via onde circula o veículo e que é anulada pelo somatório das forças normais ( $N_1, N_2, N_3$  e  $N_4$ ) que o plano exerce em cada um dos pneus. Por esta razão,  $P_y$  e o somatório das forças normais não aparecem em (2.2). De acordo com a convenção adotada neste trabalho,  $F_t$  possui valor positivo durante as acelerações e valor negativo durante as frenagens.

A força de arrasto aerodinâmico  $F_a$  é causada pelo atrito viscoso do veículo com o ar e pela diferença de pressão entre as partes da frente e de trás do veículo [8]. Seu valor pode ser aproximado em função da velocidade  $v$  do veículo por

$$F_a(v) = \frac{1}{2} \rho_a A_f c_d v^2, \quad (2.3)$$

onde  $\rho_a$  é a densidade do ar,  $A_f$  a área frontal do veículo e  $c_d$  é o coeficiente de arrasto aerodinâmico, que depende do formato do veículo [8]. O coeficiente  $c_d$  também pode variar em função da velocidade  $v$  [8], mas, neste trabalho, foi considerado constante.

A força devido ao atrito de rolamento  $F_r$  pode ser calculada por

$$F_r(\theta) = c_r m_V g \cos \theta, \quad (2.4)$$

onde  $c_r$  é o coeficiente de atrito,  $m_V$  a massa total do veículo,  $g$  a aceleração da gravidade e o termo  $\cos \theta$  leva em conta a inclinação da via. O coeficiente  $c_r$  depende de vários fatores como, por exemplo, a velocidade  $v$  e a pressão dos pneus do veículo [8], mas, neste trabalho, foi considerado constante.

A componente da força gravitacional na direção  $x$  paralela a via é induzida pela gravidade quando o veículo transita por uma via com inclinação  $\delta$ . Seu valor pode




Figura 2.2: Diagrama de forças que atuam em um veículo em movimento.

ser obtido através da relação

$$P_x(\theta) = m_V g \sin \theta, \quad (2.5)$$

onde  $m_V$  é a massa total do veículo,  $g$  a aceleração da gravidade e  $\theta$  é a inclinação da via.

### 2.2.2 Modelo Quase-Estático

Em um modelo quase-estático as relações habituais de causa e efeito em sistemas dinâmicos são invertidas. No caso da dinâmica longitudinal de um veículo por exemplo, em vez de se calcular a velocidade baseada na força aplicada como em (2.2), no método quase-estático determina-se qual a força necessária para que se tenha uma determinada velocidade. Essa relação de causalidade nos modelos dinâmico e quase-estático é ilustrada na Figura 2.3. Em um sistema físico real, uma força deve ser aplicada a um corpo para que ele seja acelerado até uma determinada velocidade, como mostra a Figura 2.3a onde a força  $F$  é a entrada do sistema e a velocidade  $v$  e a aceleração  $a$  são as saídas. No modelo quase-estático, por sua vez, a força  $F$  é calculada a partir das informações de velocidade  $v$  e aceleração  $a$  como mostrado na Figura 2.3b.

Supondo uma velocidade  $v$  constante por um curto intervalo de tempo  $h$ , a aceleração do veículo  $a$  no instante de amostragem  $k$  pode ser aproximada pela diferença finita regressiva da velocidade dada por:

$$a(k) = \frac{v(k) - v(k-1)}{h}. \quad (2.6)$$

Dada a dinâmica descrita por (2.2), a força de tração  $F_t$  necessária para a propulsão




Figura 2.3: (a) Relação entrada (força  $F$ ) e saída (velocidade  $v$  e aceleração  $a$ ) em um veículo real (modelo dinâmico) e (b) relação entrada-saída no modelo quase-estático de um veículo.

do veículo no instante de amostragem  $k$  pode ser então calculada a partir de:

$$F_t(k) = m_V a(k) + F_a(k) + F_r(k) + P_x(k), \quad (2.7)$$

onde  $m_V$  é a massa total do veículo,  $F_a$  a força arrasto aerodinâmico,  $F_r$  a força de atrito e  $P_x$  a componente da força gravitacional na direção  $x$  paralela ao plano. Substituindo (2.3), (2.4) e (2.5) em (2.7):

$$F_t(k) = m_V a(k) + \frac{1}{2} \rho_a A_f c_d v(k)^2 + c_r m_V g \cos \theta + m_V g \sin \theta. \quad (2.8)$$

A partir de (2.8) é calculada a força de tração que atua nas rodas do veículo para que ele siga um determinado ciclo de condução em função dos seus principais parâmetros ( $A_f$ ,  $c_d$ ,  $c_r$ ,  $m_V$ ).

O conjugado mecânico  $T_w$  nas rodas, necessário para a tração, é calculado através da multiplicação de (2.8) pelo raio das rodas  $r_w$ :

$$T_w(k) = r_w \left( m_V a(k) + \frac{1}{2} \rho_a A_f c_d v(k)^2 + c_r m_V g \cos \theta + m_V g \sin \theta \right). \quad (2.9)$$

A velocidade angular  $\omega_w$  e aceleração angular das rodas  $\alpha_w$  são obtidas dividindo-se a velocidade longitudinal  $v$  e a aceleração longitudinal  $a$  pelo raio  $r_w$ :

$$\omega_w(k) = \frac{v(k)}{r_w}, \quad (2.10)$$

$$\alpha_w(k) = \frac{a(k)}{r_w}. \quad (2.11)$$

Como o modelo quase estático usa um perfil de velocidade conhecido e faz uma aproximação da aceleração usando (2.6), apenas equações estáticas/algébricas são resolvidas durante a simulação. Além disso, este método dispensa o uso de um modelo para o motorista, ou seja, um controlador, para rastrear uma determinada trajetória de velocidade (ciclo de condução) [77]. Portanto, os modelos quase-estáticos possuem como vantagens a simplicidade e um tempo de simulação reduzido quando

comparada com modelos dinâmicos completos.

Os modelos quase-estáticos permitem levar em consideração o ciclo de condução do veículo com um esforço numérico relativamente baixo [8]. Por esta razão, tais modelos são bem adequados para o estudo e o projeto de sistemas de controle supervisório que buscam otimizar os fluxos de energia em um sistema de propulsão, que é o objetivo deste trabalho. Este método é bem difundido na literatura especializada sendo inclusive utilizado em bibliotecas de código aberto, voltadas para este tipo de estudo, como o *Advisor* [78] e a *Quasi-Static Simulation Toolbox* (QSS-TB) [79], ambos desenvolvidos em Simulink [80].

A principal desvantagem do método de modelagem quase-estático é que ele não respeita a causalidade dos sistemas físicos e, portanto, o ciclo de condução do veículo deve ser conhecido previamente [8]. Por este motivo, em estudos para se avaliar o consumo de energia nos veículos, geralmente são usados ciclos de condução padrão, estabelecidos por agências reguladoras.

### 2.2.3 Ciclos de Condução

Ciclos de condução são perfis de velocidade e elevação utilizados para avaliar as emissões de gases poluentes e o consumo de combustível de veículos [8]. Tipicamente são usados em testes com dinamômetros de chassi, um dispositivo usado para emular a condução do veículo em um ambiente controlado, e podem ser empregados também em simulações. Existem diversos ciclos que representam os diferentes cenários de condução aos quais os veículos podem estar sujeitos, como a condução em cidades ou autoestradas. Dois exemplos de ciclos de condução são mostrados nas Figuras 2.4 e 2.5.

O ciclo da Figura 2.4 corresponde a um ciclo de condução europeu conhecido como NEDC (sigla para termo em inglês *New European Drive Cycle*) [81]. Este ciclo é dividido em duas partes, onde a primeira representa um ciclo de condução urbano e a segunda parte corresponde a um ciclo extra-urbano (condução na estrada). A parte urbana do ciclo NEDC está traçada na Figura 2.4 de 0 s a 780 s, enquanto a parte extra-urbana é plotada de 780 s a 1180 s.

A Figura 2.5 mostra um exemplo de ciclo de condução americano, proposto pela Agência de Proteção Ambiental dos Estados Unidos (*U.S. Environmental Protection Agency* - EPA) [82]. Este ciclo, chamado de FTP (sigla para termo em inglês *Federal Test Procedure*), é usado para representar o padrão de condução de um veículo leve somente em perímetro urbano. Nos testes de emissões de VMCI's, o ciclo FTP costuma ser dividido em três partes. A primeira, traçada na Figura 2.5 de 0 s a 505 s, representa uma etapa de partida com o motor do carro ainda frio. A segunda vai de 505 s a 1369 s e é chamada de fase transitória. A terceira e última começa a




Figura 2.4: Perfil de velocidade do ciclo NEDC (*New European Driving Cycle*).




Figura 2.5: Perfil de velocidade do ciclo FTP (*Federal Test Procedure*, da Agência de Proteção Ambiental dos Estados Unidos).

partir de 1369 s e vai até o final do ciclo, considerando a partida do veículo com o motor do carro já quente (após ter sido usado recentemente).

## 2.3 Caixa de Câmbio

Em um veículo, a caixa de câmbio<sup>1</sup> é um dispositivo usado para transmitir o trabalho mecânico do motor para o diferencial ou diretamente para as rodas. Tanto os motores a combustão nos VMCI's quanto os motores elétricos nos VE's operam em velocidades superiores às das rodas e possuem um conjugado nominal inferior ao necessário para tracionar o veículo. Por esta razão, a caixa de câmbio é necessária para reduzir a velocidade de rotação do motor para as rodas, aumentando proporcionalmente o conjugado aplicado.

Neste trabalho, foi considerada uma caixa de câmbio com relação de transmissão fixa, ou seja, que possui uma relação fixa entre os valores de conjugado e os valores de velocidade angular. Desconsiderando-se as perdas de energia mecânica na caixa de velocidades, a relação de transmissão  $\gamma$  é dada por

$$\gamma = \frac{\omega_m}{\omega_w} = \frac{T_w}{T_m} \quad (2.12)$$

<sup>1</sup>Também chamada de caixa de velocidades, caixa de marchas ou caixa de transmissão

onde  $\omega_m$  é a velocidade angular do motor,  $\omega_w$  a velocidade angular das rodas,  $T_m$  é o conjugado mecânico do motor e  $T_w$  o conjugado nas rodas. Seguindo uma abordagem quase-estática, o modelo da caixa de velocidades possui como entradas a velocidade angular  $\omega_w$  e o conjugado  $T_w$  das rodas, e possui como saída a velocidade angular  $\omega_m$  e o conjugado  $T_m$  do motor elétrico [8].

## 2.4 Motor Elétrico

Em simulações quase-estáticas, o modelo do motor elétrico possui como variáveis de entrada o conjugado  $T_m$  e a velocidade angular  $\omega_m$  no seu eixo, e como variável de saída a potência elétrica demandada  $P_{EM}$  [8]. A potência  $P_{EM}$  é obtida a partir de um mapa estacionário da eficiência do motor  $\eta_m$  em função do conjugado  $T_m$  [83] e, portanto, não há necessidade de se usar um modelo detalhado do motor. A precisão do modelo depende então da precisão dos valores no mapa de eficiência do motor [84], que são normalmente obtidos experimentalmente.

Uma máquina elétrica pode operar nos quatro quadrantes do plano  $\omega_m \times T_m$ . Na convenção adotada neste trabalho, quando  $\omega_m$  e  $T_m$  possuem o mesmo sinal (quadrantes 1 e 3, portanto  $P_{EM} \geq 0$ ), a máquina funciona como motor e o veículo está acelerando (conjugado  $T_m$  atua no sentido de aumentar o módulo da velocidade). Quando os sinais de  $\omega_m$  e  $T_m$  são diferentes (quadrantes 2 e 4, portanto  $P_{EM} < 0$ ), a máquina funciona como gerador e o veículo está freando (conjugado  $T_m$  atua no sentido de diminuir o módulo da velocidade). Do ponto de vista do cálculo do consumo energético de um veículo, não importa se o veículo está acelerando ou freando com velocidade negativa, isto é, mesmo com  $\omega_m < 0$ ,  $P_{EM}$  será positiva nas acelerações e negativa nas frenagens. Portanto, apenas o primeiro e o quarto quadrantes são considerados ( $\omega_m \geq 0$ ,  $T_m > 0$  ao acelerar e  $T_m < 0$  ao frear). Além disso, considera-se que a máquina opera sempre com fator de potência unitário.

Ao operar no primeiro quadrante ( $T_m \geq 0$ ) a potência elétrica  $P_{EM}$  demandada pelo motor é expressa por

$$P_{EM} = \frac{1}{\eta_m(\omega_m, T_m)} T_m \omega_m, \quad (2.13)$$

onde  $\eta_m(\omega_m, T_m)$  é a eficiência do motor tabelada em função de  $T_m$  e  $\omega_m$ ,  $T_m$  é o conjugado e  $\omega_m$  a velocidade angular. De maneira análoga, no quarto quadrante ( $T_m < 0$ ), a potência elétrica  $P_{EM}$  é expressa por

$$P_{EM} = \eta_m(\omega_m, T_m) T_m \omega_m. \quad (2.14)$$

Um exemplo de mapa de eficiência para um motor com potência nominal de 10,5

kW e conjugado máximo de 70 Nm é mostrado na Figura 2.6. Esta figura foi traçada no Matlab a partir de dados obtidos em [83].

## 2.5 Conversores cc/ca e cc/cc

As perdas nos conversores variam em função do seu ponto de operação. Quando operam em baixa potência em relação a sua potência nominal, predominam as perdas nos circuitos de disparo (*drivers*) das chaves semicondutoras [85]. Na medida em que a potência vai aumentando, as perdas por comutação e por condução nas chaves semicondutoras e perdas por efeito joule nos elementos passivos começam a ficar mais significativas [85]. A análise das perdas em conversores costuma ser feita traçando-se uma curva da sua eficiência (relação entre a potência de saída e potência de entrada) em função da potência de operação em regime permanente. Portanto, neste trabalho, de maneira similar ao modelo quase-estático do motor elétrico, as perdas nos conversores cc/cc e cc/ca são levadas em conta através das suas curvas de eficiência.

Em [86] é proposto um modelo matemático aplicável aos inversores comerciais e que em [85] também é usado para representar a eficiência de um conversor cc/cc *boost*. No modelo proposto em [86], as perdas no conversor são representadas por um polinômio de segundo grau. Assim, a curva de eficiência dos conversores em função da potência de operação  $p$ , segundo [86], é dada por

$$\eta_{i,b}(p) = \frac{p}{p + (c_0 + c_1p + c_2p^2)}, \quad (2.15)$$

onde os coeficientes  $c_0$ ,  $c_1$  e  $c_2$  podem ser obtidos através de um ajuste de curva




Figura 2.6: Mapa de eficiência de um motor elétrico (ME) com potência nominal de 10,5 kW e conjugado máximo de 70 Nm.




Figura 2.7: Curva de eficiência de um conversor de acordo com (2.15).

com dados experimentais [87], e o polinômio de segundo grau entre parênteses no denominador representa as perdas no conversor.

A Figura 2.7 mostra uma curva de eficiência traçada a partir de (2.15). Os valores dos coeficientes  $c_0$ ,  $c_1$  e  $c_2$  usados para traçar a curva de eficiência da Figura 2.7 não representam nenhuma topologia específica, tecnologia de semicondutores ou montagem de um determinado conversor. De qualquer maneira, uma curva como esta é suficiente para levar em consideração a influência das perdas nos conversores no funcionamento do controlador proposto nesta tese.

## 2.6 Bateria

Neste trabalho, o modelo apresentado em [88] é usado para reproduzir o comportamento dinâmico da bateria. O modelo em questão foi escolhido devido a sua simplicidade e capacidade de representar o comportamento de diferentes tipos de baterias usadas em VE's.

O modelo é apresentado na Figura 2.8 e consiste em um circuito equivalente com uma resistência interna  $R_{BT}$  em série com uma fonte de tensão controlada  $v_{BT,oc}$ , cujo valor é função do EdC da bateria. A partir do circuito da Figura 2.8, a tensão



Figura 2.8: Circuito equivalente da bateria.

do terminal da bateria  $v_{BT}$  é expressa por

$$v_{BT}(k) = v_{BT,oc}(k) - R_{BT}i_{BT}(k), \quad (2.16)$$

onde  $i_{BT}$  é a corrente da bateria.

A tensão interna da bateria  $v_{BT,oc}$  é calculada em função do EdC da bateria  $\xi_{BT}$  por [88]:

$$v_{BT,oc}(k) = U_{BT}^0 - \frac{K_1}{\xi_{BT}(k)} + K_2 e^{-K_3 Q_{BT}(\xi_{BT}(k)-1)}, \quad (2.17)$$

onde  $U_{BT}^0$  é uma tensão constante da bateria,  $K_1$  é a tensão de polarização,  $Q_{BT}$  é a capacidade da bateria,  $K_2$  é a amplitude da zona exponencial da curva da tensão na curva de descarga da bateria e  $K_3$  é o inverso de constante de tempo da zona exponencial mencionada anteriormente. A título de exemplo, a Figura 2.9 mostra uma curva de descarga típica para uma célula de uma bateria de níquel hidreto-metálico de 1,2 V e 6,5 Ah. Esta curva foi traçada para uma corrente de 1,3 A, que corresponde a 20% da capacidade nominal desta bateria. Os parâmetros do modelo usado para traçar a curva são mostrados na própria figura. A zona exponencial, de onde são extraídos os parâmetros  $K_2$  e  $K_3$  está indicada pela área em azul e com contorno tracejado na Figura 2.9.

O EdC da bateria  $\xi_{BT}$ , que indica o nível de carga, é calculado em função da corrente da bateria por:

$$\xi_{BT}(k+1) = \xi_{BT}(k) - \frac{h}{Q_{BT}} i_{BT}(k), \quad (2.18)$$

onde  $h$  é o intervalo de amostragem.




Figura 2.9: Curva de descarga típica de uma bateria.

## 2.7 Empilhamento de Células a Combustível do Tipo PEM

Nesta seção é descrita a modelagem de empilhamentos de CaC's do tipo PEM baseada nos fenômenos eletroquímicos que descrevem o seu comportamento. O objetivo é mostrar as principais dificuldades associadas à representação da CaC por meio de modelos físicos, que são complexos e dependem de variáveis de difícil medição. No final deste capítulo, é apresentada uma outra técnica de modelagem de empilhamentos PEM, baseada em redes neurais. Este modelo neural é usado no algoritmo de CPBM não linear apresentado no próximo capítulo.

### 2.7.1 Tensão de Operação

A tensão de operação de uma CaC do tipo PEM é tipicamente modelada através de formulações físicas e empíricas que descrevem os fenômenos eletroquímicos, termodinâmicos e de transporte de massa no interior da célula [29, 36]. O seu cálculo é feito em função da corrente, das pressões parciais dos gases reagentes, da temperatura da célula e do grau de hidratação da membrana trocadora de prótons (eletrólito).

Nesta abordagem fundamentada na eletroquímica, a tensão de circuito aberto de uma CaC é calculada a partir do balanço de energia entre as energias químicas dos reagentes e a energia elétrica de uma célula. Porém, parte dessa energia química é convertida em calor de forma irreversível. Esta irreversibilidade se manifesta sob forma de diferentes quedas de tensão (também chamados sobrepotenciais), que são divididos em três tipos: ativação, ôhmico e concentração. Os sobrepotenciais são subtraídos da tensão de circuito aberto, causando uma queda na tensão terminal da célula e, conseqüentemente, diminuindo a sua eficiência de conversão de energia.

Ao combinar todas as quedas de tensão associadas às irreversibilidades mencionadas nas seções anteriores, a tensão terminal de operação  $v_{FC}$  de um empilhamento de CaC's é escrita como

$$v_{FC} = n(E - v_{act} - v_{ohm} - v_{con}), \quad (2.19)$$

onde  $n$  corresponde ao número de células que compõem o empilhamento,  $E$ ,  $v_{act}$ ,  $v_{ohm}$  e  $v_{con}$  correspondem, respectivamente, à tensão de circuito aberto e aos sobrepotenciais de ativação, ôhmico e de concentração de uma CaC unitária. Em um empilhamento de CaC's, a tensão total é dada pela soma das tensões individuais de cada uma das células. Portanto, em (2.19) considera-se que todas as células do empilhamento são idênticas e a tensão do total do empilhamento é calculada de forma aproximada ao multiplicar a tensão terminal de uma célula unitária pelo número de células no empilhamento.

## Tensão de Circuito Aberto

A tensão de circuito aberto de uma CaC pode ser calculada a partir do trabalho elétrico realizado para movimentar os elétrons que percorrem o circuito entre o anodo e o catodo. Se o processo em uma CaC fosse reversível, toda a energia química liberada na reação seria convertida diretamente em energia elétrica necessária para a circulação dos elétrons. A energia química de uma reação é dada pela variação da energia livre de Gibbs  $\Delta\bar{g}_f$ , calculada a partir da diferença entre as energias livres de Gibbs dos produtos e dos reagentes [29].

A variação da energia livre de Gibbs pode ser definida como sendo a “energia disponível para realizar trabalho externo, desconsiderando qualquer trabalho realizado por variações de pressão e/ou temperatura” [29]. O seu valor varia tanto com temperatura como com a pressão, e para o caso dos gases ideais pode ser calculado por [36]

$$\Delta\bar{g}_f = \Delta\bar{g}_f^0 - RT \ln \left( \frac{p_{H_2} p_{O_2}^{\frac{1}{2}}}{p_{H_2O}} \right), \quad (2.20)$$

onde  $\Delta\bar{g}_f^0$  é a variação da energia livre de Gibbs a pressão atmosférica,  $R$  é a constante universal dos gases ideais,  $T$  é a temperatura em que ocorre a reação, e  $p_{H_2}$ ,  $p_{O_2}$  e  $p_{H_2O}$  são, respectivamente, as pressões parciais do hidrogênio, oxigênio e da água. O valor de  $\Delta\bar{g}_f^0$  também varia com a temperatura e é sempre negativo, o que significa que a energia é liberada pela reação [29, 36].

Conforme ilustrado na Figura 1.1 e descrito por (1.1), (1.2) e (1.3), para cada molécula de hidrogênio consumida na reação, dois elétrons são liberados e percorrem o circuito conectado entre o anodo e o catodo. Dessa forma, para cada mol<sup>2</sup> de hidrogênio consumido, dois moles de elétrons são liberados, e a carga  $Q$  que percorre o circuito dada por

$$Q = -2F, \quad (2.21)$$

onde  $F$  é a constante de Faraday (96485 C/mol), que corresponde a carga de um mol de elétrons [29].

Sendo  $E$  o potencial elétrico entre os eletrodos de uma CaC, o trabalho elétrico realizado para movimentar a carga  $Q$  pelo circuito é igual ao produto entre  $Q$  e  $E$ . Em um processo sem perdas, esse trabalho é igual a energia livre de Gibbs. Dessa forma, pode-se estabelecer a equação

$$\Delta\bar{g}_f = -2FE. \quad (2.22)$$

Por fim, substituindo (2.20) em (2.22), a tensão de circuito aberto de uma CaC pode

---

<sup>2</sup>Quantidade de uma substância que contém sempre o mesmo número de partículas:  $6,022 \times 10^{23}$ .

ser escrita como

$$E = -\frac{\Delta\bar{g}_f^0}{2F} + \frac{RT}{2F} \ln \left( \frac{p_{H_2} p_{O_2}^{\frac{1}{2}}}{p_{H_2O}} \right). \quad (2.23)$$

A tensão  $E$  em (2.23) é conhecida como potencial reversível ou Potencial de Nernst, e consiste em um potencial reversível teórico que existiria a uma dada temperatura e pressão. Entretanto, na prática, o processo das CaC's não é reversível, e parte da energia química é convertida em calor de forma irreversível. Os fenômenos que acarretam nesta transformação de energia química em calor são tratados separadamente nos parágrafos a seguir.

### Sobrepotencial de Ativação

A queda tensão por ativação está relacionada com a velocidade mais lenta em que são desencadeadas as reações químicas nas superfícies dos eletrodos da CaC, decorrentes da necessidade de mover elétrons e quebrar e formar ligações químicas [36]. Neste processo, uma parte da energia disponível é convertida em calor de forma irreversível durante a ativação da reação química de transferência de elétrons nos eletrodos [29]. Esta queda de tensão é altamente não-linear, e seu efeito é mais considerável em baixos valores de densidade de corrente.

Apesar deste tipo de irreversibilidade ocorrer tanto no anodo quanto no catodo, a reação de redução do oxigênio no catodo é consideravelmente mais lenta que a reação de oxidação do hidrogênio no anodo [36]. Consequentemente, a queda de tensão devido à perda por ativação é dominada pelas condições de reação do catodo. Assim, desconsiderando o efeito do anodo, a relação entre a queda tensão por ativação  $v_{act}$  e a corrente  $i_{FC}$  é descrita pela equação de Tafel [29]

$$v_{act} = \frac{RT}{2\alpha_c F} \ln \left( \frac{i_{FC} + I_n}{I_0} \right), \quad (2.24)$$

onde  $i_{fc}$  é a corrente da CaC,  $\alpha_c$  é o coeficiente de transferência de carga,  $I_0$  é a corrente de troca e  $I_n$  representa as perdas devidas aos elétrons que passam pelo eletrólito sem realizar trabalho elétrico e ao hidrogênio não reagido que também atravessa o eletrólito.

O coeficiente de transferência de carga  $\alpha_c$  representa a proporção da energia elétrica aplicada que é aproveitada na mudança da taxa de uma reação eletroquímica [29]. Podendo variar entre 0 e 1, o seu valor depende do material do eletrodo e da reação envolvida, além de sofrer influência da temperatura [69]. A corrente  $I_0$  pode ser definida como a corrente a partir da qual a sobretensão começa a se mover de zero [29], e funciona como um indicativo do quão facilmente as reações ocorrem na superfície do eletrodo. O seu valor depende da temperatura, da área efetiva dos eletrodos, do tipo de catalisador e da forma como o mesmo é distribuído sobre a

superfície dos eletrodos [69].

### Sobrepotencial Ôhmico

A queda de tensão ôhmica ocorre devido às diferentes perdas resistivas na estrutura de uma CaC. Este tipo de irreversibilidade está associada à resistência elétrica da membrana polimérica ao fluxo de íons e à resistência dos eletrodos e da placa coletora ao fluxo de elétrons [36]. Assim, pode-se relacionar a queda de tensão ôhmica  $v_{ohm}$  (V) com a corrente  $i_{fc}$  (A) através da Lei de Ohm

$$v_{ohm} = R_{ohm}i_{FC}, \quad (2.25)$$

onde  $R_{ohm}$  representa a resistência elétrica interna equivalente da CaC. Seu valor pode ser obtido experimentalmente através da “técnica de interrupção de corrente”, descrita por Larminie e Dicks em [29].

A resistência  $R_{ohm}$  representa a soma de todas as resistências internas de uma CaC [69] conforme

$$R_{ohm} = R_m + R_e + R_c, \quad (2.26)$$

onde  $R_m$  é a resistência da membrana polimérica,  $R_e$  é a resistência dos eletrodos e  $R_c$  é a resistência de contato. Além de sofrer influência da temperatura, a resistência  $R_m$  varia consideravelmente em função da hidratação da membrana, que depende tanto da quantidade de água produzida como subproduto quanto da umidificação forçada dos gases reagentes (caso haja) [69]. Mais especificamente, o teor de água da membrana e a temperatura influenciam diretamente na condutividade da mesma. As resistências dos eletrodos  $R_e$  e de contato  $R_c$ , por sua vez, não variam com as condições operacionais da CaC e podem ser consideradas constantes [69].

### Sobrepotencial de Concentração

A queda de tensão por concentração é decorrente da diminuição na concentração dos reagentes à medida em que são consumidos na reação. Como a taxa de consumo dos reagentes é proporcional à corrente na célula, esse tipo de irreversibilidade é mais pronunciado em altos valores de densidade de corrente. Nesta condição há uma queda nas pressões parciais do hidrogênio e do oxigênio, acarretando em uma rápida queda de tensão na célula de forma não-linear [69].

Baseando-se na equação de Nernst, e em função da variação das pressões parciais dos gases reagentes, pode-se definir uma densidade de corrente limiar na qual a taxa de consumo dos mesmos atinge o seu máximo valor possível [29]. Este limiar não pode ser ultrapassado, pois nesta condição a pressão na tubulação de fornecimento é próxima de zero, e o fluxo de reagentes não pode ser mais aumentado para compensar o consumo [69]. Assim, o sobrepotencial de concentração  $v_{con}$  pode ser expresso por

[29]

$$v_{con} = B \ln \left( 1 - \frac{i_{FC}}{I_{lim}} \right), \quad (2.27)$$

onde  $B$  é uma constante que depende do tipo de CaC e do seu estado de operação e  $I_{lim}$  é a corrente limiar na qual a queda de tensão se torna mais acentuada.

### 2.7.2 Capacitância de Dupla Camada de Carga

Na interface entre o eletrodo e o eletrólito de uma CaC, elétrons se acumulam na superfície do eletrodo e fazem com que os íons  $H^+$  presentes no eletrólito sejam atraídos, formando assim uma dupla camada de carga [29]. O acúmulo de cargas produz um campo elétrico e faz com que essa dupla camada se comporte como um capacitor, acumulando energia. Dessa maneira, quando ocorrem variações repentinas de corrente, há um atraso na resposta de tensão de operação da célula.

A diferença de potencial gerada por esse efeito capacitivo corresponde a uma combinação das quedas de tensão por ativação e por concentração [36]. Porém, enquanto essas quedas de tensão levam um tempo para seguir a mudança na corrente, a queda de tensão ôhmica responde instantaneamente. Assim, o comportamento dinâmico de uma CaC pode ser modelado pelo circuito equivalente apresentado na Figura 2.10. Usando (2.24) e (2.27), os resistores  $R_{act}$  e  $R_{con}$  [36] podem ser definidos como

$$R_{act} = \frac{v_{act}}{i_{FC}} \quad (2.28a)$$

$$R_{con} = \frac{v_{con}}{i_{FC}}. \quad (2.28b)$$

Através da análise do circuito da Figura 2.10, o comportamento dinâmico de




Figura 2.10: Circuito equivalente de uma célula a combustível unitária.

uma CaC pode ser descrito por

$$C \frac{dv_C}{dt} + \frac{v_C}{R_{act} + R_{con}} = i_{FC}, \quad (2.29a)$$

$$v_{FC} = E - v_C - R_{ohm} i_{FC}. \quad (2.29b)$$

### 2.7.3 Vazão de Gases Reagentes

Conforme descrito anteriormente, para cada mol de hidrogênio consumido por uma CaC, dois moles de elétrons são liberados para circular pelo circuito externo, e a carga que percorre o circuito é dada por (2.21). Portanto, para  $n_{H_2}$  moles de hidrogênio, a carga correspondente em módulo será

$$q = 2F n_{H_2}. \quad (2.30)$$

Derivando (2.30) em função do tempo,

$$\frac{dq}{dt} = 2F \frac{dn_{H_2}}{dt} \quad (2.31)$$

onde a variação da carga no tempo  $dq/dt$  corresponde à corrente elétrica fornecida pela CaC  $i_{FC}$  e  $dn_{H_2}/dt$  é a vazão teórica de hidrogênio (em mol/s) necessária para produzir essa corrente em uma CaC unitária.

Considerando um empilhamento de  $n$  CaC's conectadas em série e usando a variável  $\dot{n}_{H_2}$  para representar a vazão molar teórica, pode-se rearranjar (2.31) de forma a obter

$$\dot{n}_{H_2} = \frac{n i_{FC}}{2F}, \quad (2.32)$$

que corresponde a vazão molar mínima de hidrogênio necessária para que a reação ocorra, também chamada de “vazão estequiométrica molar” [69]. A vazão mássica pode ser obtida através da multiplicação de (2.32) pela massa molar do hidrogênio  $M_{H_2}$ , assim

$$\dot{m}_{H_2} = \frac{M_{H_2} n i_{FC}}{2F}. \quad (2.33)$$

Na prática, o hidrogênio é fornecido a uma taxa maior que a dada por (2.32) para evitar que o empilhamento sofra degradação devido à inanição de combustível. A razão entre a taxa na qual o hidrogênio é fornecido e a vazão estequiométrica é chamada de “fator de excesso” [69]. Desta maneira, a taxa na qual o hidrogênio é

fornecido ao empilhamento  $w_{H_2}$  pode ser aproximada por

$$w_{H_2} = W_1 i_{FC} + W_2, \quad (2.34)$$

onde os parâmetros  $W_1$  e  $W_2$  podem ser identificados através de um algoritmo de mínimos quadrados entre a corrente do empilhamento e a vazão média de gás hidrogênio fornecida. Estes parâmetros não têm um significado físico preciso porque (2.34) consiste em uma aproximação da vazão média. No entanto,  $W_1$  pode ser interpretado como um valor aproximado dos coeficientes em (2.32), e  $W_2$  corresponde a uma vazão mínima de hidrogênio necessária para manter a tensão do circuito aberto no empilhamento e pode ser determinada empiricamente. No caso dos empilhamentos PEM de anodo fechado, o valor de  $W_2$  também depende da frequência dos intervalos entre as purgas.

## 2.7.4 Cálculo da Eficiência

Tipicamente, a eficiência teórica de uma CaC é calculada comparando a energia elétrica que é gerada pela célula com o calor que seria produzido caso o hidrogênio fosse queimado. Esse calor consiste em uma forma de energia química, que pode ser chamado de poder calorífico ou mais corretamente entalpia de formação  $\Delta \bar{h}_f$  [29]. Existem dois modos de se considerar o poder calorífico de um combustível: um denominado poder calorífico inferior (PCI), caso a água produzida na reação de combustão esteja na forma de vapor, e outro denominado poder calorífico superior (PCS), caso essa água seja condensada para o estado líquido [29]. Na temperatura de 25 °C e pressão de 1 bar, o PCI do hidrogênio vale -241,83 kJ/mol e o PCS -285,84 kJ/mol, e a diferença entre esses dois valores consiste na entalpia molar de vaporização<sup>3</sup> da água [29].

Se todo o poder calorífico do hidrogênio fosse transformado em energia elétrica, a tensão terminal de uma CaC seria dada por [29]

$$E = -\frac{\Delta \bar{h}_f}{2F} = \begin{cases} 1,25 \text{ V}, & \text{se for utilizado o PCI} \\ 1,48 \text{ V}, & \text{se for utilizado o PCS.} \end{cases} \quad (2.35)$$

Assim, pode-se definir uma “eficiência de tensão”  $\eta_v$  [69] de um empilhamento de CaC’s, relacionando a sua tensão terminal  $v_{FC}$  com a tensão ideal definida em (2.35), através da relação [29]

$$\eta_v = 100 \frac{v_{FC}}{1,25n}, \quad (2.36)$$

---

<sup>3</sup>Energia necessária para a mudança de fase.

se for utilizado o PCI, ou

$$\eta_v = 100 \frac{v_{FC}}{1,48n}, \quad (2.37)$$

se for utilizado o PCS, onde  $n$  corresponde ao número de células no empilhamento.

A eficiência de tensão considera que todo hidrogênio fornecido à CaC é usado na reação. Entretanto, como costuma-se fornecer hidrogênio a uma taxa maior do que a vazão estequiométrica, (2.36) e (2.37) não levam em conta a quantidade de hidrogênio total fornecida ao empilhamento, apenas a parte que é usada na reação. Portanto, de maneira mais usual, a eficiência é calculada através da razão entre a energia elétrica gerada e a energia química fornecida ao empilhamento em um dado intervalo de tempo, como em

$$\eta_{FC} = 100 \frac{v_{FC} i_{FC}}{(\Delta \bar{h}_f / M_{H_2}) w_{H_2}}, \quad (2.38)$$

onde  $v_{FC}$  é a tensão do empilhamento,  $i_{FC}$  a corrente,  $\Delta \bar{h}$  representa o poder calorífico,  $M_{H_2}$  a massa molar do hidrogênio e  $w_{H_2}$  a vazão mássica total de hidrogênio fornecida ao empilhamento. Como pode ser notado, o numerador em (2.38) representa a potência elétrica gerada pelo empilhamento e o denominador representa a taxa na qual energia química é fornecida ao empilhamento.

## 2.8 Modelo Completo do VEHCC para o Estudo de Sistemas de Gerenciamento de Energia

Um diagrama de blocos com o modelo completo do VEHCC em malha aberta é mostrado na Figura 2.11. O ciclo de condução determina o perfil de velocidade  $v$ , aceleração  $a$  e inclinação  $\delta$  que deve ser seguido pelo veículo. Por sua vez, o bloco do veículo consiste no modelo quase-estático descrito neste capítulo, que calcula qual deve ser a força necessária para que seja seguido o ciclo de condução. No modelo da Figura 2.11 é considerado o movimento das partes rotativas, por isso as saídas do veículo consistem no conjugado  $T_w$ , aceleração angular  $\alpha_w$  velocidade angular  $\omega_w$  das rodas. Os blocos de transmissão mecânica e do motor elétrico, representam as perdas nesses componentes, conforme descrito neste capítulo. Finalmente, a potência que atua como perturbação no elo cc do sistema consiste na potência requerida pelo motor elétrico  $P_{EM}$  mais as perdas do inversor (inverso da eficiência  $\eta_i$  na Figura 2.11).

O modelo da Figura 2.11 é usado nas simulações cujos resultados são apresentados no Capítulo 4. O modelo em malha aberta tem como entrada a corrente do empilhamento  $i_{FC}$ , que nas simulações é calculada pelo sistema de gerenciamento de energia. Este modelo não leva em conta a dinâmica do conversor *boost* e do inversor




Figura 2.11: Diagrama de blocos do modelo do veículo elétrico a célula a combustível (VEHCC).

e das suas malhas de controle de corrente, pois seus tempos de resposta são bem mais rápidos quando comparados com as outras dinâmicas envolvidas. Por esta razão, nas simulações, a corrente  $i_{FC}$  é a própria corrente de referência  $i_{FC}^*$  calculada pelo controlador que faz o gerenciamento energético da planta.

Na etapa de validação do sistema de controle proposto nesta teste com uma bancada de testes HiL, o modelo do empilhamento PEM na Figura 2.11 é substituído por um empilhamento real. Mais detalhes do funcionamento da bancada HiL são apresentados no Capítulo 4.

## 2.9 Modelagem de Empilhamentos de Células a Combustível PEM por Redes Neurais

Na Seção 2.7 foi apresentada a modelagem física de um empilhamento de CaC's do tipo PEM, baseada em fenômenos eletroquímicos. Nesta seção é apresentada a modelagem de empilhamentos PEM baseada em redes neurais. O modelo neural é utilizado neste trabalho para o cálculo de predições no algoritmo de CPBM que será apresentado no Capítulo 3.

Conforme relatado em [69, 72, 89, 90], modelos físicos com parâmetros fixos, muitas vezes não são capazes de representar o comportamento dinâmico de empilhamentos de CaC's do tipo PEM em aplicações práticas de controle. Os empilhamentos estão sujeitos a variações de suas condições internas de pressão, temperatura e umidade que, geralmente, modelos físicos elaborados para aplicações de controle não são capazes de prever e que levam a alterações na tensão do empilhamento [69]. Portanto, para contornar o problema, em [69] é proposto o uso de redes neurais para modelagem do comportamento dinâmico da tensão em função da corrente. Nessa metodologia proposta, são utilizados modelos neurais autoregressivos, isto é, mo-

delos cuja saída no instante atual depende de valores passados da própria saída. Essa estratégia se baseia na ideia de que a própria tensão reflete as mudanças nas condições internas do empilhamento [72].

É importante salientar que o modelo neural do empilhamento de CaC's não é um modelo adaptativo ou variante no tempo. A principal vantagem da rede neural consiste em usar a tensão da CaC como uma “memória”, que varia em função das condições internas não observáveis diretamente. Portanto, o modelo baseado em redes neurais permite calcular a tensão dos próximos passos com base em tensões do passado, obtendo uma predição mais próxima da realidade para este futuro próximo quando comparada com aquela feita por um modelo físico [72]

### 2.9.1 Redes Neurais *Feedforward*

Redes neurais são estruturas matemáticas inspiradas nas redes de neurônios em um cérebro, e que são constituídas por unidades de processamento mais simples chamadas de neurônios artificiais (NA's). Os NA's executam uma soma ponderada de seus sinais de entrada e usam o resultado como o argumento de uma função chamada função de ativação, que limita o valor do sinal saída do neurônio [73]. Assim, os NA's funcionam de forma semelhante aos neurônios em um cérebro real, respondendo de maneira ponderada a seus estímulos.

Na Figura 2.12 é mostrado um diagrama que representa a estrutura de um NA, composto por um bloco somador  $\Sigma$  e uma função de ativação  $f_j$ , onde o índice  $j$  é usado pra identificar o neurônio. Os sinais de entrada são representados pelas variáveis  $\varphi_1, \dots, \varphi_i$  e para cada um deles é atribuído um peso  $w_{j,i}$ . Cada sinal multiplicado pelo seu peso é aplicados ao bloco somador junto com um sinal de *bias*  $b_j$ , cuja função é aumentar ou diminuir a sensibilidade do neurônio aos sinais de entrada. O resultado do somatório  $v_j$  é usado como argumento da função de ativação  $f_j$ , que calcula o sinal de saída  $y_j$  do neurônio. Matematicamente, o NA




Figura 2.12: Diagrama representando a estrutura de um neurônio artificial (NA).

representado na Figura 2.12 pode ser escrito como

$$y_j = f_j\left(\sum_{i=1}^{N_\varphi} w_{j,i}\varphi_i + b_j\right), \quad (2.39)$$

onde  $N_\varphi$  corresponde ao número de sinais de entrada. A função de ativação  $f_j$  pode assumir qualquer forma, mas frequentemente são usadas funções monótonas, dentre as quais são mais comuns as funções [73]:

- a) linear  $f_j(v_j) = v_j$ ;
- b) tangente hiperbólica  $f_j(v_j) = \tanh(v_j)$ ;
- c) sigmóide  $f_j(v_j) = 1/(1 + \exp(-v_j))$ ; e
- d) sinal  $f_j(v_j) = \text{sign}(v_j)$ .

Os NA's podem ser organizados para formar uma rede de várias formas. No arranjo mais comum os neurônios são ordenados em camadas, onde cada neurônio em uma camada tem como entrada as saídas de neurônios nas camadas anteriores ou sinais externos. Como as conexões são feitas sem realimentações, este tipo de configuração é chamado de rede neural *feedforward*, denominada também de *multi-layer perceptron* (MLP) [73]. Um exemplo deste tipo de rede neural é mostrado na Figura 2.13, onde os pesos e os sinais de *bias* dos NA's foram omitidos para facilitar a visualização.

A rede mostrada na Figura 2.13 possui quatro camadas no total: uma camada de entrada, duas camadas ocultas e uma camada de saída. A primeira camada da esquerda pra direita é chamada de camada de entrada por ser constituída pelos nós de entrada, que nada mais são do que as entradas externas da rede. A última camada chama-se camada de saída pois é nela que são calculadas os sinais de saída (predições) da rede. Finalmente, as camadas ocultas recebem esta denominação pois ficam entre as camadas de entrada e de saída.

O processo de identificação dos modelos neurais é denominado treinamento, e consiste em determinar os pesos e os *bias* dos NA's que compõem a rede. No treinamento, um algoritmo de otimização atualiza iterativamente os valores dos pesos e *bias* de maneira a minimizar o erro entre as predições da rede e os valores das variáveis de saída contidos no conjunto de dados de treinamento (pares de entrada e saída). Além desta etapa de treinamento, o processo de modelagem por redes neurais também engloba uma etapa de validação. Nesta nova etapa, um novo conjunto de pares de entrada e saída, denominado conjunto de validação, é aplicado a rede neural após o treinamento. O objetivo é verificar se a rede neural que foi treinada é capaz de fazer predições dos dados de saída com uma margem de erro aceitável.




Figura 2.13: Rede neural *feedforward* com três entradas, duas camadas ocultas com dois neurônios artificiais em cada uma e duas saídas.

## 2.9.2 Modelagem por Redes Neurais Recorrentes

As redes *feedforward* estabelecem uma relação algébrica entre as variáveis de entrada e de saída. Porém, quando se deseja usar uma rede para reproduzir o comportamento dinâmico de um sistema físico real, a arquitetura da rede é modificada para incluir malhas (ou laços) de realimentação. Assim, os NA's são combinados de maneira a conter uma memória interna, ou seja, passam a exibir um comportamento dinâmico. Nestes casos, a RN é chamada de rede neural recorrente (RNR), uma classe mais geral de arquitetura e que tem, portanto, a rede *feedforward* como um caso especial.

Na metodologia proposta em [69], são empregadas duas RNR's conhecidas como NARX (*Nonlinear AutoRegressive with eXogenous input*) e NOE (*Nonlinear Output Error*) para modelagem do comportamento dinâmico da tensão de um empilhamento PEM. As entradas escolhidas para estes modelos neurais consistem no valor atual e nos valores passados da corrente  $i_{FC}$  do empilhamento, e valores passados da tensão  $v_{FC}$ . As estruturas das redes NARX e NOE são mostradas na Figura 2.14. Ambas possuem apenas uma camada oculta com  $n_h$  neurônios e apenas um neurônio na camada de saída, que corresponde a somente uma variável de saída (predição da tensão  $\hat{v}_{FC}$ ).

Na Figura 2.14a se nota que a rede NARX tem como entrada valores passados de  $v_{FC}$  proveniente da própria planta (nesse caso o empilhamento de CaC's) e, portanto, não há realimentação propriamente dita. A rede NOE, ao contrário, faz o uso recorrente das predições dos valores de tensão que foram calculados nos instantes passados de amostragem ( $\hat{v}_{FC}(k-1), \dots, \hat{v}_{FC}(k-N)$ ) e, portanto, caracteriza-se estritamente como uma RNR. Em ambas estruturas, as variáveis de entrada podem ser agrupadas em uma forma vetorial chamada vetor regressor, que no caso da rede




Figura 2.14: Representação gráfica das redes neurais NARX e NOE.

NARX é representado como

$$\varphi(k) = [i_{FC}(k), i_{FC}(k-1), \dots, i_{FC}(k-M), v_{FC}(k-1), \dots, v_{FC}(k-N)]^T, \quad (2.40)$$

e no caso da rede NOE é dado por

$$\varphi(k) = [i_{FC}(k), i_{FC}(k-1), \dots, i_{FC}(k-M), \hat{v}_{FC}(k-1), \dots, \hat{v}_{FC}(k-N)]^T, \quad (2.41)$$

onde  $i_{FC}$  e  $v_{FC}$  são a corrente e tensão no empilhamento real,  $\hat{v}_{FC}$  é a predição de tensão feita pela rede neural,  $M$  corresponde ao número de amostras passadas da corrente e  $N$  o número de amostras passadas da tensão (ou da predição do valor de tensão, no caso da rede NOE). Os valores de  $M$  e  $N$  podem ser obtidos por uma análise estatística dos dados de treinamento apresentados ao RNN [72].

A equação matemática das estruturas NARX e NOE é dada por

$$\hat{v}_{FC}(k) = \sum_{i=1}^{n_h} W_i \tanh \left[ \sum_{j=1}^{n_\varphi} w_{ij} \varphi_j(k) + w_{i0} \right] + W_0, \quad (2.42)$$

onde  $n_h$  é o número de neurônios na camada oculta,  $W_i$  é o peso que conecta o  $i$ -ésimo neurônio oculto ao neurônio de saída,  $n_\varphi$  é o número de nós de entrada e

corresponde a o número de elementos em (2.40),  $w_{ij}$  é o peso que conecta o  $j$ -ésimo nó de entrada ao  $i$ -ésimo neurônio oculto,  $\varphi_j$  é o  $j$ -ésimo nó de entrada,  $w_{i0}$  é o bias do  $i$ -ésimo nó da camada oculta e  $W_0$  é o bias do neurônio de saída.

O processo de identificação dos modelos neurais é denominado “treinamento”, e consiste em determinar os pesos e os *bias* dos NA’s que compõem a rede. No treinamento, um algoritmo de otimização atualiza iterativamente os pesos e *bias* de maneira a minimizar o erro entre as predições da rede e os valores das variáveis de saída contidos no conjunto de dados de treinamento (pares de entrada e saída). A técnica para a modelagem de empilhamentos PEM utiliza a corrente como variável de entrada e a tensão como variável de saída [69]. Os dados são obtidos experimentalmente e o treinamento é realizado com a estrutura NARX, que proporciona um treinamento mais rápido e predições mais precisas [72]. Em seguida, as predições da rede NARX são utilizadas como entrada, convertendo-a em estrutura NOE, como mostrado na Figura 2.14b, para realização da etapa de validação [72]. Nesta nova etapa, aplica-se um novo conjunto de dados à rede para verificar sua precisão.

Para aplicações de otimização em tempo real, como o sistema de controle preditivo baseado em modelo que será detalhado no capítulo a seguir, a estrutura NARX é a mais indicada, uma vez que ela garante um erro baixo de predição [69]. A rede NARX utiliza informações atuais e passadas da planta a ser controlada para realizar predições considerando um horizonte de apenas um passo de amostragem à frente. Como será mostrado no capítulo seguinte, aplicações de controle preditivo requerem apenas algumas poucas predições, geralmente algo entre 10 e 20 amostras à frente, dependendo do tempo de subida da planta e do tempo de amostragem, o que corresponde a no máximo alguns poucos segundos no futuro no caso de CaC’s. Assim, no próximo capítulo será mostrado como a estrutura NARX é capaz de fazer essa predições, realimentando as predições de saída apenas na medida em que forem sendo necessárias. Contudo, em aplicações *offline*, como a predição da eficiência de um empilhamento de CaC’s [90], a estrutura NOE é que é empregada como modelo, onde não é necessário fornecer ao modelo valores medidos da saída real da planta em instantes passados [69]. A rede NOE permite a predição da saída para vários instantes de amostragem à frente, considerando um horizonte de tempo mais longo, como horas ou dias.

## 2.10 Resumo do Capítulo

A arquitetura do sistema de propulsão do VEHCC objeto de estudo deste trabalho é do tipo série, onde um empilhamento de CaC’s do tipo PEM é utilizado como fonte de energia principal e uma bateria opera como *buffer* de energia. Neste configuração, a CaC é conectada à bateria através de um conversor cc/cc elevador de

tensão. A bateria, por sua vez, alimenta o motor elétrico de propulsão através de um conversor cc/ca. Neste trabalho, considera-se que apenas a corrente da CaC pode ser controlada diretamente pelo sistema de gerenciamento de energia, e que a potência do motor elétrico atua como perturbação no elo cc formado pela bateria.

O cálculo da potência demandada do elo cc pelo motor elétrico de propulsão é feito através de um modelo quase-estático do veículo. Neste tipo de modelagem, as relações de causa e efeito em sistemas dinâmicos são invertidas. Assim, no caso da dinâmica longitudinal de um veículo, a força (e potência) de propulsão necessária pode ser calculada a partir de um perfil de velocidade conhecido. Como os modelos quase-estáticos são compostos apenas por equações algébricas, suas principais vantagens são simplicidade e tempo de simulação reduzido se comparado com modelos dinâmicos. Além disso, este método de modelagem dispensa o uso de um modelo para o motorista (ou controlador, para rastrear a velocidade do ciclo de condução).

Um modelo dinâmico da bateria é utilizado na simulação em tempo real do VEHCC. Este modelo tem como entrada a potência da bateria, que é dada pela diferença entre a potência demandada do elo cc pelo motor elétrico de propulsão (calculada pelo modelo quase-estático) e a potência fornecida pelo CaC. A bancada utilizada para validação experimental do controlador proposto nesta tese, que será apresentada no Capítulo 4, dispõe de um empilhamento real de CaC's. Portanto, não há necessidade de um modelo do mesmo na simulação em tempo real do VEHCC. A potência da CaC, que consiste em uma das entradas do modelo da bateria simulado em tempo real, é a própria potência medida no empilhamento real da bancada. No entanto, neste capítulo foram apresentados dois modelos de CaC's do tipo PEM: um modelo físico e outro baseado em redes neurais.

O modelo físico é baseado nos fenômenos eletroquímicos, termodinâmicos e de fenômenos de transporte nos quais se baseiam o funcionamento das CaC's tipo PEM. A revisão deste tipo de modelo permite a identificação de variáveis e parâmetros que desempenham um papel importante na descrição do comportamento de um empilhamento tipo PEM e que, conseqüentemente, afetam seu desempenho. Por outro lado, a modelagem baseada nos fenômenos físicos que regem o comportamento das CaC's é complexa e muito dependente de variáveis e parâmetros de difícil medição, tornando essa abordagem pouco prática para o projeto de controladores.

Na metodologia baseada em redes neurais, são utilizadas as estruturas NARX e NOE para modelagem da dinâmica da tensão de CaC's tipo PEM. Ambas estruturas possuem como entrada o valor atual e valores passados da corrente da CaC, além de valores passados da tensão da CaC. Porém, enquanto a rede NARX utiliza valores passados de medições de tensão feitas na CaC real, a rede NOE utiliza de forma recorrente suas próprias previsões calculadas em instantes passados. Este método de modelagem, proposto em [69], é baseado na hipótese que a tensão da CaC no

instante atual depende da própria tensão em instantes passados.

O modelo neural apresentado neste capítulo é utilizado para o cálculo das previsões de tensão da CaC, no algoritmo de CPBM que será apresentado no Capítulo 3. Por apresentar o menor erro de previsão, a rede NARX é mais indicada para uso em controladores em tempo real. Nestas aplicações, os valores passados da tensão na entrada podem ser atualizados a cada instante de amostragem do controlador.

## Capítulo 3

# Sistema de Gerenciamento de Energia Preditivo Neural

Este capítulo descreve o sistema de gerenciamento de energia (SGE) preditivo neural proposto nesta tese. O capítulo faz uma revisão dos fundamentos de uma técnica de controle preditivo baseado em modelo (CPBM) linear conhecida como controle preditivo generalizado (CPG) e também do CPBM não linear. A revisão do CPG é importante para o entendimento de alguns fundamentos básicos que são aplicáveis também ao controle preditivo não linear. O capítulo também mostra como o CPG pode ser aplicado para fazer o gerenciamento de energia de um VEHCC, considerando o veículo como um sistema de entrada única e saída única. Ao final, o capítulo apresenta a estratégia de gerenciamento de energia proposta, com CPBM não linear empregando uma RNR como modelo da CaC.

### 3.1 Controle Preditivo Baseado em Modelo

O termo controle preditivo baseado em modelo (CPBM) designa uma família de controladores na qual o sinal de controle é obtido através do uso explícito de um modelo do processo [74]. O seu princípio consiste em prever o comportamento futuro da saída  $y$  do processo para determinar qual deve ser o sinal de entrada  $u$  (também chamado sinal de controle). A predição da saída  $y$  no instante  $k + j$ , calculada no instante  $k$ , é representada por  $\hat{y}(k + j|k)$ . As predições da saída são calculadas sobre um intervalo de tempo finito utilizando o modelo, e dependem de valores conhecidos até o instante atual de amostragem  $k$  (entradas e saídas passadas) e de uma sequência finita de valores futuros da entrada. No CPBM, esta sequência é obtida através da solução de um problema de otimização que, conforme descrito a seguir, deve ser resolvido a cada instante de amostragem do controlador.

Em um dado instante de amostragem  $k$ , o controlador soluciona um problema de

otimização para minimizar uma função de custo. Geralmente, esta função assume uma forma quadrática e contempla parcelas associadas aos erros entre as previsões e uma trajetória de referência  $r$ , além de penalizações no incremento do sinal de controle  $\Delta u$  [74]. A solução desse problema de otimização consiste na sequência de valores futuros da entrada  $u(k|k)$ ,  $u(k+1|k)$ , ...,  $u(k+N_u-1|k)$ <sup>1</sup>, onde  $N_u$  representa o número de amostras do chamado horizonte de controle. Entretanto, apenas o primeiro elemento desta sequência  $u(k|k)$  é aplicado ao processo e os outros elementos da sequência são rejeitados.

Isso ocorre porque, no instante de amostragem seguinte,  $y(k+1)$  será conhecido e, possivelmente, diferente da previsão  $\hat{y}(k+1|k)$  calculada no instante anterior. Dado que, em aplicações reais, o modelo nunca reproduz com 100% de exatidão o comportamento da planta. Assim, em  $k+1$ , o problema de otimização é resolvido novamente e toda as sequências, de previsões da saída e de valores de entrada, são atualizadas. O primeiro elemento da nova sequência de entrada  $u(k+1|k+1)$ , que em princípio será diferente de  $u(k+1|k)$  devido às novas informações disponíveis, é então aplicado a planta.

Esta estratégia é conhecida como Princípio do Horizonte Retrocedente (PHR) e está ilustrada na Figura 3.1, onde  $k$  é o instante de amostragem atual,  $N_2$  é o número de amostras do horizonte de previsão e  $N_u$  é o número de amostras do horizonte de controle,  $r$  é a referência,  $y$  a variável de saída,  $u$  o sinal de entrada e  $\hat{y}$  representa as previsões da saída  $y$ . O horizonte de previsão  $N_2$  corresponde ao número máximo de amostras do intervalo futuro no qual é considerado o comportamento da saída do processo, e o horizonte de controle  $N_u$  representa o número de elementos da sequência de sinais de controle considerados. No intervalo entre  $N_u$  e  $N_2$ , a entrada do sistema é considerada constante. Pode-se definir  $N_u = N_2$ , porém, quanto menor for o valor de  $N_u$  menor será o esforço computacional do algoritmo de controle [74]. Na Figura 3.1, o horizonte de previsão começa em 1, porém, de um modo mais generalizado ele pode começar em valores superiores. Assim, pode-se definir um horizonte de previsão mínimo  $N_1$  [74].

Devido à necessidade de calcular previsões de  $y$  em instantes futuros, o modelo matemático do processo é fundamental na formulação do CPBM. De acordo com [74] (p. 13, tradução do autor),

O projeto do controlador deve incluir os mecanismos necessários para obter o melhor modelo possível, que seja capaz para capturar completamente a dinâmica do processo e permitir o cálculo das previsões, além de ser intuitivo e permitir a análise teórica.

---

<sup>1</sup>A notação  $u(k+j|k)$  segue a mesma representação das previsões dos valores de saída: valores de  $u$  no instante  $k+j$  calculados no instante  $k$ .




Figura 3.1: Princípio do horizonte retrocedente (PHR).

Os modelos podem ser lineares ou não lineares, dependendo da necessidade, e de modo geral, qualquer forma possível de modelagem pode ser usada no CPBM [74]. Dentre os controladores baseados em modelos lineares, os principais são o Controle por Matriz Dinâmica (CMD) [91], o Controle Algorítmico do Modelo (CAM) [92] e o Controle Preditivo Generalizado (CPG) [93, 94]. O CMD e o CAM são formulados de maneira similar. Porém, enquanto o primeiro utiliza um modelo não paramétrico da resposta ao degrau da planta, o segundo é baseado em um modelo não paramétrico da resposta ao impulso [74]. O CPG, por sua vez, utiliza uma função de transferência como modelo para o cálculo das predições. Além disso, diferente dos dois primeiros, o CPG pode lidar com processos instáveis [95].

Além dos modelos mencionados anteriormente, a representação do sistema no espaço de estados também pode ser usada. A derivação do controlador, neste caso, é muito simples, mesmo para o caso multivariável, e por isso seu uso é o mais difundido na comunidade acadêmica [74]. Esse tipo de modelo também é preferível no caso não linear [96], uma vez que a representação no espaço de estados de sistemas

não lineares é facilmente derivada das equações diferenciais que descrevem o modelo, caso sejam conhecidas. Basta convertê-las em um conjunto de equações diferenciais de primeira ordem.

## 3.2 Controle Preditivo Generalizado

A revisão do CPG apresentada a seguir é feita para o caso de sistemas com entrada única e saída única, ou simplesmente SISO (*single-input single-output*). No final da seção é apresentado um exemplo de como o CPG pode ser aplicado para fazer o gerenciamento de energia de um VEHCC como o da Figura 2.11. Este exemplo de aplicação é baseado no trabalho apresentado em [59] e considera o VEHCC como um sistema SISO.

### 3.2.1 Formulação do Controle Preditivo Generalizado

A ideia do CPG consiste em encontrar uma sequência futura de sinais de controle  $u(k)$ ,  $u(k+1)$  ...,  $u(k+N_u-1)$  que minimize uma função de custo da forma [74]:

$$J(N_1, N_2, N_u) = \sum_{j=N_1}^{N_2} \delta [\hat{y}(k+j|k) - r(t+j)]^2 + \sum_{j=1}^{N_u} \lambda [\Delta u(k+j-1)]^2, \quad (3.1)$$

onde  $\hat{y}(k+j|k)$  é a predição ótima da saída  $y$  do sistema no instante  $k+j$  feita no instante  $k$ ,  $r(k+j)$  é a trajetória de referência futura,  $N_1$  e  $N_2$  são, respectivamente os horizontes de predição mínimo e máximo,  $N_u$  é o horizonte de controle,  $\delta$  é o coeficiente de penalização do erro de rastreamento da referência,  $\lambda$  é o coeficiente de penalização do esforço de controle  $\Delta u(k)$ , definido como:

$$\Delta u(k) \triangleq u(k) - u(k-1). \quad (3.2)$$

No CPG, o cálculo das predições da saída do sistema  $\hat{y}$  é feito usando um modelo linear conhecido como CARIMA (do termo em inglês *Controller Auto-Regressive Moving Average*) [74]. Este tipo de modelo descreve a maioria dos processos de entrada única e saída única (SISO), quando se considera a sua operação em torno de um ponto de equilíbrio após a linearização. Um modelo CARIMA é dado pela equação:

$$A(z^{-1})y(k) = B(z^{-1})z^{-d}u(k-1) + C(z^{-1})\frac{e(k)}{1-z^{-1}}, \quad (3.3)$$

onde  $y(k)$  é a saída,  $u(k)$  é a entrada,  $e(k)$  é um ruído branco de média nula,  $d$  é o atraso de transporte do sistema (*dead-time*) e  $A$ ,  $B$  e  $C$  são polinômios no operador

de atraso unitário  $z^{-1}$ :

$$A(z^{-1}) = 1 + a_1 z^{-1} + a_2 z^{-2} + \cdots + a_{n_a} z^{-n_a}, \quad (3.4a)$$

$$B(z^{-1}) = b_0 + b_1 z^{-1} + b_2 z^{-2} + \cdots + b_{n_b} z^{-n_b}, \quad (3.4b)$$

$$C(z^{-1}) = 1 + c_1 z^{-1} + c_2 z^{-2} + \cdots + c_{n_c} z^{-n_c}. \quad (3.4c)$$

Como descrito em [74], através de manipulações de (3.3), a predição de  $y(k+j)$  é dada por uma equação da forma:

$$\hat{y}(k+j|k) = G_j(z^{-1})\Delta u(t+j-d-1) + F_j(z^{-1})y(k), \quad (3.5)$$

onde  $G_j$  e  $F_j$  são polinômios no operador de atraso unitário  $z^{-1}$ , e podem ser obtidos recursivamente usando divisão de polinômios, como demonstrado em [74], ou recorrendo a uma equação Diofantina, como proposto em [93].

Dado um sistema sem atraso de transporte ( $d=0$ ), considerando um horizonte de predição de  $N$  amostras e um horizonte de controle de mesmo tamanho ( $N_u = N_2 = N$  e  $N_1 = 1$ ), o conjunto das predições da variável de saída será dado por:

$$\begin{aligned} \hat{y}(k+1|k) &= G_1 \Delta u(k) + F_1 y(k), \\ \hat{y}(k+2|k) &= G_2 \Delta u(k+1) + F_2 y(k), \\ &\vdots \\ \hat{y}(k+N|k) &= G_N \Delta u(k+N-1) + F_N y(k), \end{aligned}$$

que pode ser escrito sob a forma matricial:

$$\hat{\mathbf{y}} = \mathbf{G}\mathbf{u} + \mathbf{F}(z^{-1})y(k) + \mathbf{G}'(z^{-1})\Delta u(k-1), \quad (3.6)$$

onde

$$\hat{\mathbf{y}} = \begin{bmatrix} \hat{y}(k+1|k) \\ \hat{y}(k+2|k) \\ \vdots \\ \hat{y}(k+N|k) \end{bmatrix}, \quad \mathbf{G} = \begin{bmatrix} g_0 & 0 & \cdots & 0 \\ g_1 & g_0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ g_{N-1} & g_{N-2} & \cdots & g_0 \end{bmatrix},$$

$$\mathbf{u} = \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \vdots \\ \Delta u(k+N-1) \end{bmatrix}, \quad \mathbf{F}(z^{-1}) = \begin{bmatrix} F_1(z^{-1}) \\ F_2(z^{-1}) \\ \vdots \\ F_N(z^{-1}) \end{bmatrix},$$

$$\mathbf{G}'(z^{-1}) = \begin{bmatrix} (G_1(z^{-1}) - g_0)z \\ (G_2(z^{-1}) - g_0 - g_1z^{-1})z^2 \\ \vdots \\ (G_N(z^{-1}) - g_0 - g_1z^{-1} - \dots - g_{N-1}z^{-(N-1)})z^N \end{bmatrix}.$$

Os dois últimos termos de (3.6) dependem apenas de valores passados de  $y$  e  $u$ , e podem ser agrupados em um único vetor  $\mathbf{f}$ . Este vetor corresponde à resposta livre do sistema, ou seja, a parte da resposta que não depende de valores futuros do sinal de controle  $u$ . Em (3.6), o termo  $\mathbf{G}\mathbf{u}$  depende de valores futuros do sinal de controle  $u$  e corresponde, portanto, à resposta forçada. Segundo [74] (p. 18, tradução do autor), “a resposta livre corresponde à evolução do processo devido ao seu estado atual, enquanto a resposta forçada é devida aos valores futuros do sinal de controle”. Ao agrupar os dois últimos termos de (3.6), as previsões da saída  $y$  são escritas sob a forma matricial em função das resposta forçada e livre:

$$\hat{\mathbf{y}} = \mathbf{G}\mathbf{u} + \mathbf{f}. \quad (3.7)$$

Considerando  $\delta = 1$ ,  $\lambda$  um escalar e utilizando (3.7), a função de custo (3.1) pode ser reescrita sob a forma matricial:

$$J = (\mathbf{G}\mathbf{u} + \mathbf{f} - \mathbf{r})^T (\mathbf{G}\mathbf{u} + \mathbf{f} - \mathbf{r}) + \lambda \mathbf{u}^T \mathbf{u}, \quad (3.8)$$

onde

$$\mathbf{r} = \begin{bmatrix} r(k+1) & r(k+2) & \dots & r(k+N) \end{bmatrix}^T$$

é uma sequência de amostras da trajetória de referência futura, a princípio conhecida.

Os termos em (3.8) podem ser rearranjados e a função de custo escrita sob a forma quadrática:

$$J = \frac{1}{2} \mathbf{u}^T \mathbf{H} \mathbf{u} + \mathbf{b}^T \mathbf{u} + f_0, \quad (3.9)$$

onde

$$\begin{aligned} \mathbf{H} &= 2(\mathbf{G}^T \mathbf{G} + \lambda \mathbf{I}), \\ \mathbf{b}^T &= 2(\mathbf{f} - \mathbf{r})^T \mathbf{G}, \\ f_0 &= (\mathbf{f} - \mathbf{r})^T (\mathbf{f} - \mathbf{r}). \end{aligned}$$

Quando não há restrições, o valor de  $\mathbf{u}$  que minimiza  $J$  dado por (3.9) é obtido

igualando o gradiente de  $J$  a zero, o que resulta em:

$$\mathbf{u} = -\mathbf{H}^{-1}\mathbf{b} = (\mathbf{G}^T\mathbf{G} + \lambda\mathbf{I})^{-1}\mathbf{G}^T(\mathbf{r} - \mathbf{f}). \quad (3.10)$$

De acordo com o PHR, como apenas o primeiro elemento de  $\mathbf{u}$  deve ser aplicado ao processo, o cálculo do incremento de controle a cada instante de amostragem será dado por:

$$\Delta u(k) = \mathbf{K}(\mathbf{r} - \mathbf{f}), \quad (3.11)$$

onde  $\mathbf{K}$  corresponde à primeira linha da matriz  $(\mathbf{G}^T\mathbf{G} + \lambda\mathbf{I})^{-1}\mathbf{G}^T$ , e  $(\mathbf{r} - \mathbf{f})$  é o erro futuro. A Figura 3.2 mostra um diagrama de blocos com um sistema de CPG sem restrições, onde o incremento do sinal de controle  $\Delta u(k)$  é obtido a cada instante de amostragem em função das previsões calculadas a partir de informações atuais da planta. No esquema da Figura 3.2, o integrador é o responsável pela soma do valor do incremento de controle obtido no instante presente  $\Delta u(k)$  com o valor da entrada no instante anterior  $u(k-1)$ . Ou seja,  $u(k) = \Delta u(k) + u(k-1) = u(k) - u(k-1) + u(k-1)$ .

### 3.2.2 Controle Preditivo Generalizado com Restrições

A formulação do CPG apresentada na Seção 3.2.1 é feita considerando um sistema sem restrições, isto é, um sistema cujos sinais possuem amplitude ilimitada. Neste caso, a lei de controle, dada por (3.11), é obtida analiticamente através do cálculo da raiz do gradiente de (3.9). Entretanto, na prática, qualquer processo estará sempre sujeito a restrições devido principalmente a limitações físicas. No caso dos VE's, por exemplo, limites mínimo e máximo devem ser impostos ao EdC da bateria, para evitar descarga excessiva ou sobrecarga.

Em CaC's do tipo PEM, a corrente somente pode circular em um único sentido, e sua amplitude deve ser limitada pra evitar fenômenos como inanição dos gases reagentes. Um número elevado de ciclos de partida e parada nas CaC's também




Figura 3.2: Diagrama de blocos de um sistema de controle preditivo generalizado (CPG).

contribui o para o processo de degradação do equipamento [55]. Para limitar estes ciclos, pode-se impor um limite de corrente mínimo (e maior que zero) na operação da CaC [59]. Ainda para proteger a CaC contra os problemas de alagamento dos eletrodos e inanição, também pode-se impor um valor máximo na taxa de variação da corrente [59].

A restrição na amplitude do sinal de entrada, como a corrente da CaC em um sistema como o da Figura 2.11, é descrita pela inequação:

$$\underline{U} \leq u(k) \leq \bar{U}, \quad \forall k, \quad (3.12)$$

onde  $\underline{U}$  é o valor mínimo permitido do sinal de entrada e  $\bar{U}$  o valor máximo. Dado um horizonte de predição de  $N$  amostras futuras, esse tipo de restrição é representado por [74]:

$$\mathbf{1}\underline{U} \leq T\mathbf{u} + u(k-1)\mathbf{1} \leq \mathbf{1}\bar{U}, \quad (3.13)$$

onde  $\mathbf{1}$  é um vetor coluna com  $N$  elementos, todos iguais a 1, e  $T$  é uma matriz triangular inferior cujos elementos não nulos são iguais a 1.

A restrição na taxa de variação do sinal de entrada, por sua vez, é descrita pela inequação:

$$\underline{u} \leq u(k) - u(k-1) \leq \bar{u}, \quad \forall k, \quad (3.14)$$

onde  $\underline{u}$  é o valor mínimo permitido do incremento de controle  $\Delta u(k)$  e  $\bar{u}$  o valor máximo. Dado um horizonte de predição de  $N$  amostras futuras, esse tipo de restrição é representado por:

$$\mathbf{1}\underline{u} \leq \mathbf{u} \leq \mathbf{1}\bar{u}. \quad (3.15)$$

Por fim, a restrição na amplitude do sinal de saída, como o EdC da bateria em um sistema como o da Figura 2.11, é dada por:

$$\underline{y} \leq y(k) \leq \bar{y}, \quad \forall k, \quad (3.16)$$

onde  $\underline{y}$  é o valor mínimo permitido do sinal de saída e  $\bar{y}$  o valor máximo. Dado um horizonte de predição de  $N$  amostras futuras, esse tipo de restrição é representado por:

$$\mathbf{1}\underline{y} \leq \mathbf{G}\mathbf{u} + \mathbf{f} \leq \mathbf{1}\bar{y}. \quad (3.17)$$

As restrições dadas por (3.13), (3.15) e (3.17) podem ser agrupadas em uma única expressão linear, dada por:

$$\mathbf{R}\mathbf{u} \leq \mathbf{c}, \quad (3.18)$$

onde

$$\mathbf{R} = \begin{bmatrix} I_{N \times N} \\ -I_{N \times N} \\ T \\ -T \\ \mathbf{G} \\ -\mathbf{G} \end{bmatrix}, \quad \mathbf{c} = \begin{bmatrix} \mathbf{1}\bar{u} \\ -\mathbf{1}\underline{u} \\ \mathbf{1}\bar{U} - \mathbf{1}u(k-1) \\ -\mathbf{1}\underline{U} + \mathbf{1}u(k-1) \\ \mathbf{1}\bar{y} - \mathbf{f} \\ -\mathbf{1}\underline{y} + \mathbf{f} \end{bmatrix},$$

e  $I_{N \times N}$  corresponde a matriz identidade de dimensão  $N$ .

Quando são consideradas as restrições no CPG, a lei de controle não pode ser obtida analiticamente. Neste caso, para a obtenção da sequência de valores futuros da entrada, é necessário minimizar a função de custo (3.9) sujeita às restrições lineares dadas por (3.18). Este processo consiste em um problema de otimização com uma função de custo quadrática e restrições lineares, e é conhecido como programação quadrática (PQ) [97]. No CPG, este problema de otimização é resolvido a cada instante de amostragem, segundo o PHR.

Um problema de PQ consiste em minimizar a função (3.9) em relação a  $\mathbf{u}$  sujeito às restrições (3.18). Ou de maneira mais recorrente, o problema de PQ é declarado na sua forma padrão:

$$\begin{aligned} & \underset{\mathbf{u}}{\text{minimizar}} && \frac{1}{2} \mathbf{u}^T \mathbf{H} \mathbf{u} + \mathbf{b}^T \mathbf{u} + f_0 \\ & \text{sujeito a} && \mathbf{R} \mathbf{u} \leq \mathbf{c}. \end{aligned} \tag{3.19}$$

A programação quadrática é um caso particular de programação não linear, e problemas como (3.19) podem ser resolvidos por algoritmos que já são bem estabelecidos na literatura [97]. Por exemplo, caso o problema (3.19) seja convexo, ou seja, caso a matriz  $\mathbf{H}$  seja positiva-semidefinida, sua solução pode ser obtida através de algoritmos como o método dos conjuntos ativos (*Active-Set*) ou o método do ponto interior (*Interior Point*) [97].

### 3.2.3 Aplicação do Controle Preditivo Generalizado como Sistema de Gerenciamento de Energia

Nesta seção, a título de exemplo, é mostrado como o CPG pode ser aplicado para o gerenciamento de energia de um VEHCC como o da Figura 2.11, baseado no conceito proposto em [59]. O objetivo do controlador é fazer a sustentação de carga da bateria através da energia proveniente da CaC. Neste caso, o EdC da bateria, representada por  $\xi_{BT}$ , é a variável controlada, e representa a saída do sistema. A potência da CaC, representada por  $P_{FC}$ , é a variável de controle, e consiste na entrada do sistema. O diagrama de blocos desta aplicação é apresentado na Figura 3.3. Para fazer a




Figura 3.3: Diagrama de blocos do sistema de controle preditivo generalizado (CPG) para o gerenciamento de energia de um veículo elétrico híbrido a célula a combustível (VEHCC).

sustentação de carga da bateria, o CPG deve minimizar o erro futuro entre um EdC de referência, representado por  $\xi_{BT}^*$ , e o EdC. Portanto, a função de custo que deverá ser minimizada pelo sistema de controle preditivo, é dada por:

$$J = \sum_{j=1}^N [\xi_{BT}^* - \xi_{BT}(k+j)]^2 + \sum_{j=1}^{N_u} \lambda \Delta P_{FC}(k+j-1)^2. \quad (3.20)$$

A predição do EdC é calculada a partir de (2.18), em função da corrente da bateria. Como a bateria é recarregada somente pela CaC, a corrente da bateria pode ser calculada em função da potência da CaC, através da relação:

$$i_{FC} = \frac{-P_{FC}}{v_{BT}}, \quad (3.21)$$

que considera o elo cc do veículo sem perturbações e desconsidera as perdas no conversor cc/cc ( $\eta_b = 1$ ). Assim, o modelo de predição do EdC é dado pela expressão:

$$\xi_{BT}(k+1) = \xi_{BT}(k) + \frac{h}{Q_{BT}v_{BT}} P_{FC}(k), \quad (3.22)$$

que calcula o EdC em função da potência fornecida pela CaC. Os termos em (3.22) podem ser rearranjados da seguinte forma:

$$(1 - z^{-1}) \xi_{BT}(k) = \frac{h}{Q_{BT}v_{BT}} P_{FC}(k-1), \quad (3.23)$$

que tem o mesmo formato do modelo CARIMA dado por (3.3), com  $n_a = 1$  e  $n_b = 0$ :

$$A(z^{-1}) = 1 + a_1 z^{-1} = 1 - z^{-1}, \quad (3.24)$$

$$B(z^{-1}) = b_0 = \frac{h}{Q_{BT}v_{BT}}. \quad (3.25)$$

Como mostrado na Seção 3.2.1, as predições da saída devem ser primeiro obtidas e reescritas na forma (3.6) cujos termos matriciais são obtidos a partir do cálculo dos polinômios preditores  $E_j(z^{-1})$  e  $F_j(z^{-1})$  de grau  $j-1$  e  $n_a$ , respectivamente [74]. Estes polinômios podem ser obtidos dividindo 1 por  $\tilde{A}(z^{-1})$ , onde  $\tilde{A}(z^{-1}) =$

$(1 - z^{-1})A(z^{-1})$ , até que o resto possa ser fatorado como  $z^{-j}F_j(z^{-1})$ . O quociente da divisão é o polinômio  $E_j(z^{-1})$ . O primeiro passo dessa divisão tem como resultado:

$$E_1(z^{-1}) = 1 \quad F_1(z^{-1}) = 2 - z^{-1}$$

A título de exemplo, os polinômios apresentados a seguir foram calculados para um horizonte de predição  $N$  de 5 amostras e um horizonte de controle  $N_u$  com o mesmo tamanho. Segundo a metodologia de cálculos recursivo dos polinômios descrita em [74], os valores obtidos são:

$$\begin{aligned} E_2(z^{-1}) &= 1 + 2z^{-1} & F_2(z^{-1}) &= 3 - 2z^{-1} \\ E_3(z^{-1}) &= 1 + 2z^{-1} + 3z^{-2} & F_3(z^{-1}) &= 4 - 3z^{-1} \\ E_4(z^{-1}) &= 1 + 2z^{-1} + 3z^{-2} + 4z^{-3} & F_4(z^{-1}) &= 5 - 4z^{-1} \\ E_5(z^{-1}) &= 1 + 2z^{-1} + 3z^{-2} + 4z^{-3} + 5z^{-4} & F_5(z^{-1}) &= 6 - 5z^{-1}. \end{aligned}$$

De posse destes valores e do polinômio  $B(z^{-1})$  dado por (3.25), as matrizes  $\mathbf{G}$  e  $\mathbf{G}'(z^{-1})$  de (3.6) são obtidas a partir dos polinômios  $G_j(z^{-1}) = E_2(z^{-1})B(z^{-1})$ :

$$\begin{aligned} G_1(z^{-1}) &= \frac{h}{Q_{BT}v_{BT}} \\ G_2(z^{-1}) &= (1 + 2z^{-1})\frac{h}{Q_{BT}v_{BT}} \\ G_3(z^{-1}) &= (1 + 2z^{-1} + 3z^{-2})\frac{h}{Q_{BT}v_{BT}} \\ G_4(z^{-1}) &= (1 + 2z^{-1} + 3z^{-2} + 4z^{-3})\frac{h}{Q_{BT}v_{BT}} \\ G_5(z^{-1}) &= (1 + 2z^{-1} + 3z^{-2} + 4z^{-3} + 5z^{-4})\frac{h}{Q_{BT}v_{BT}}. \end{aligned}$$

Dessa forma, as predições da saída podem ser escritas como:

$$\begin{bmatrix} \hat{y}(k+1|k) \\ \hat{y}(k+2|k) \\ \hat{y}(k+3|k) \\ \hat{y}(k+4|k) \\ \hat{y}(k+5|k) \end{bmatrix} = \frac{h}{Q_{BT}v_{BT}} \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 2 & 1 & 0 & 0 & 0 \\ 3 & 2 & 1 & 0 & 0 \\ 4 & 3 & 2 & 1 & 0 \\ 5 & 4 & 3 & 2 & 1 \end{bmatrix} \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \Delta u(k+2) \\ \Delta u(k+3) \\ \Delta u(k+4) \end{bmatrix} + \begin{bmatrix} 2 - z^{-1} \\ 3 - 2z^{-1} \\ 4 - 3z^{-1} \\ 5 - 4z^{-1} \\ 6 - 5z^{-1} \end{bmatrix} y(k), \quad (3.26)$$

que é da forma (3.7), onde

$$\mathbf{G} = \frac{h}{Q_{BT}v_{BT}} \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 2 & 1 & 0 & 0 & 0 \\ 3 & 2 & 1 & 0 & 0 \\ 4 & 3 & 2 & 1 & 0 \\ 5 & 4 & 3 & 2 & 1 \end{bmatrix}, \quad \mathbf{f} = \begin{bmatrix} 2 - z^{-1} \\ 3 - 2z^{-1} \\ 4 - 3z^{-1} \\ 5 - 4z^{-1} \\ 6 - 5z^{-1} \end{bmatrix} y(k).$$

Uma vez calculados a matriz  $\mathbf{G}$  e o vetor  $\mathbf{f}$ , a função de custo  $J$  é escrita na forma (3.9). Em seguida, caso não hajam restrições, a lei de controle é calculada usando (3.10), caso contrário, a obtenção da lei de controle será dada pela solução do problema (3.19). Como mencionado na Seção 3.2.2, para limitar partidas e paradas desnecessárias e frequentes da CaC, é necessário impor uma demanda mínima de potência  $P_{FC,min}$ . A potência máxima gerada deve ser limitada em  $P_{FC,max}$  para evitar danos na CaC. Além disso, as CaC's tem os subsistemas auxiliares lentos, que nem sempre oferecem uma resposta rápida o suficiente, em comparação com a resposta elétrica. Por esta razão, são estabelecidas restrições  $\Delta P_{FC,min}$  e  $\Delta P_{FC,max}$  na taxa de variação da potência. Por fim, limites mínimo  $\xi_{BT,min}$  e máximo  $\xi_{BT,max}$  são impostos ao EdC para prevenir contra descarga excessiva ou sobrecarga da bateria.

As restrições que atuam nos limites de amplitude e taxa de variação da potência da CaC, e nos limites de amplitude do EdC da bateria podem ser descritos, respectivamente, por:

$$P_{FC,min} \leq P_{FC}(k) \leq P_{FC,max}, \quad (3.27)$$

$$\Delta P_{FC,min} \leq \Delta P_{FC}(k) \leq \Delta P_{FC,max}, \quad (3.28)$$

$$\xi_{BT,min} \leq \xi_{BT}(k) \leq \xi_{BT,max}. \quad (3.29)$$

### 3.3 Controle Preditivo Baseado em Modelo Não Linear

#### 3.3.1 Fundamentos do Controle Preditivo Baseado em Modelo Não Linear

Tal qual o CPG e outras técnicas de CPBM linear, o controle preditivo não linear também segue o PHR: a cada instante de amostragem, obtém-se uma sequência de valores futuros da entrada do sistema, que o direcionam para o estado desejado, através da solução de um problema de otimização. Porém, apenas o primeiro elemento desta sequência é aplicado ao processo e, no instante de amostragem seguinte, o problema de otimização é resolvido novamente. Entretanto, como já mencionado, em oposição às técnicas lineares, o CPBM não linear utiliza um modelo não linear para o cálculo das previsões do comportamento futuro do sistema [96].

Dado um sistema não linear, sem perturbações e cujos estados são mensuráveis, a sua representação no espaço de estados é dada por:

$$\mathbf{x}(k+1) = \mathbf{f}(\mathbf{x}(k), \mathbf{u}(k)), \quad (3.30)$$

onde  $\mathbf{f}$  é uma função vetorial não linear que atribui a um vetor de estados  $\mathbf{x}(k)$  e a um vetor entrada  $\mathbf{u}(k)$  o vetor de estados sucessor  $\mathbf{x}(k+1)$  no próximo instante de amostragem. Dada uma sequência de vetores de entrada em um horizonte de tempo finito  $N$ :

$$\mathbf{u}_k^N \triangleq \{\mathbf{u}(k|k), \mathbf{u}(k+1|k), \dots, \mathbf{u}(k+N-1|k)\}, \quad (3.31)$$

o problema que deve ser resolvido a cada instante de amostragem é formulado como:

$$\begin{aligned} & \underset{\mathbf{u}_k^N}{\text{minimizar}} && J(\mathbf{x}_k, \mathbf{u}_k^N) \\ & \text{sujeito a} && \mathbf{x}(k+1) = \mathbf{f}(\mathbf{x}(k), \mathbf{u}(k)), \\ & && \mathbf{x}(k) = \mathbf{x}_0, \\ & && \mathbf{G}(\mathbf{x}, \mathbf{u}) = \mathbf{0}, \\ & && \mathbf{H}(\mathbf{x}, \mathbf{u}) \geq \mathbf{0}, \end{aligned} \quad (3.32)$$

onde  $J(\mathbf{x}_k, \mathbf{u}_k^N)$  é uma função de custo de horizonte de predição finito,  $\mathbf{x}_0$  é o vetor de estados do sistema no instante de amostragem atual,  $\mathbf{G}(\mathbf{x}, \mathbf{u})$  é uma função que define as restrições de igualdade e  $\mathbf{H}(\mathbf{x}, \mathbf{u})$  é uma função que define as restrições de desigualdade. Supondo que (3.32) seja viável (i.e., admite solução), existe uma sequência ideal de entradas de controle  $\mathbf{u}_k^{N*}$  que minimiza  $J(\mathbf{x}_k, \mathbf{u}_k^N)$ .

Ao contrário de (3.19), o problema (3.32) é um caso mais geral de programação não linear. Em (3.32), a função de custo, apesar de ser normalmente quadrática, está sujeita a restrições que podem ser não lineares, como as funções  $\mathbf{f}$ ,  $\mathbf{G}$  e  $\mathbf{H}$ . Nestes casos, não há um algoritmo específico capaz de solucionar todos os problemas de otimização não linear, como no caso de um problema de otimização quadrática convexa, como (3.19). Em aplicações de CPBM não linear, dois métodos tipicamente utilizados são a Programação Quadrática Sequencial (PQS) e o métodos de ponto interior [96].

De acordo com o PHR, um algoritmo de CPBM não linear executa as seguintes etapas a cada instante de amostragem [96]:

1. Medir ou estimar o estado do sistema  $\mathbf{x}(k)$ ;
2. Definir  $\mathbf{x}_0 = \mathbf{x}(k)$  e resolver (3.32);
3. Definir  $\mathbf{u}(k+1) = \mathbf{u}^*(0)$  e usar esse valor de controle no próximo período de amostragem.

A função de custo de horizonte finito  $J(\mathbf{x}_k, \mathbf{u}_k^N)$  pode ser escolhida de acordo com os objetivos de controle (requisitos de desempenho), e levar em consideração diferentes indicadores de desempenho. De uma maneira geral, esta função pode ser escolhida de maneira arbitrária. No entanto, na maioria dos casos ela tem a forma

[98]:

$$J(\mathbf{x}_k, \mathbf{u}_k^N) = \sum_{i=0}^N L(\mathbf{x}_i, \mathbf{u}_i) + V(\mathbf{x}_N), \quad (3.33)$$

onde a função  $L$  é chamada de custo de etapa e a função  $V$  é um termo de penalidade terminal. O custo de etapa é tipicamente uma função quadrática de  $x$  e de  $u$  [98]:

$$L(\mathbf{x}_i, \mathbf{u}_i) = \mathbf{x}_i^T Q \mathbf{x}_i + \mathbf{u}_i^T R \mathbf{u}_i, \quad (3.34)$$

com  $Q$  e  $R$  positiva definidas.

### 3.3.2 Estabilidade do Controle Preditivo Baseado em Modelo Não Linear

Neste trabalho de doutorado foi dada maior atenção na verificação experimental do esquema de controle preditivo não linear proposto e, pelo fato do mesmo ter mostrado ser sempre estável, não foi feita a prova de estabilidade em malha fechada. Contudo, esta seção faz uma revisão sobre os principais métodos para se garantir essa estabilidade no CPBM não linear. O propósito desta revisão é servir de base para um futuro trabalho sobre a análise de estabilidade do controlador.

No CPBM não linear, a cada instante de amostragem  $k$ , uma solução de um problema de controle ótimo de malha aberta deve ser obtida. Este problema está sujeito à dinâmica do sistema e também à restrições que podem envolver seus estados e entradas. A partir de medições no instante  $k$ , o controlador prevê o comportamento dinâmico do sistema para um horizonte finito de  $N$  amostras (até  $k + N$ ). Com base nessas previsões, calcula-se qual deve ser a sequência de valores de entrada para que uma função de custo seja minimizada. No instante de amostragem seguinte ( $k + 1$ ), repete-se o procedimento. Assim, o controle em malha fechada se dá através da otimização *online* e iterativa sobre as previsões geradas pelo modelo.

Caso a) todos os estados do sistema sejam mensuráveis; b) o sistema não tenha perturbações; e c) o modelo seja capaz de reproduzir perfeitamente o comportamento do sistema, ao usar um horizonte de predição e de controle infinitos<sup>2</sup> ( $N = \infty$ ), garante-se que as previsões das entradas e dos estados computadas em  $k$  como solução do problema de otimização sejam de fato iguais às entradas e os estados do sistema real [98]. Esta consequência também implica em estabilidade do sistema em malha fechada, e tal metodologia é chamada de “CPBM não linear de horizonte infinito”, normalmente descrito apenas como método teórico conceitual [98].

O uso de um horizonte infinito pode ser facilmente aplicado para garantir a estabilidade no CPBM linear, pois existem maneiras eficientes de se resolver grandes

---

<sup>2</sup>Na prática, escolhe-se um valor muito elevado.

problemas de programação quadrática. Por outro lado, no caso do CPBM não linear, torna-se difícil ou mesmo infactível solucionar um problema com um número muito elevado de variáveis. Assim, o uso de um horizonte de predição finito é essencial no caso não linear. No entanto, quando um horizonte de previsão finito é usado, os estados e as entradas preditas serão diferentes do sistema real, mesmo que o modelo reproduza perfeitamente o comportamento do sistema [98]. Consequentemente, não há garantia de que o sistema em malha fechada seja estável.

Para se garantir a estabilidade do CPBM não linear de horizonte finito em malha fechada, deve-se modificar a montagem do problema através da adição de restrições ou mesmo termos na função de custo [98]. Essas modificações tem o único objetivo de se garantir a estabilidade e não tem, portanto, relação alguma com restrições físicas ou requisitos de desempenho desejados. Quando o CPBM não linear possui tais modificações, costuma-se rotulá-lo como “CPBM não linear com estabilidade garantida”. As restrições adicionais, usadas para garantir essa estabilidade são denominadas “restrições de estabilidade”.

A seguir são descritos dois dos principais esquemas de CPBM não linear com estabilidade garantida: o CPBM não linear com restrição terminal de estado zero e o CPBM não linear quase infinito. Dado um sistema não linear representado por (3.30), cujos conjuntos  $\mathbb{X}$  e  $\mathbb{U}$  representam os conjuntos de restrições de estado e entrada respectivamente, os métodos descritos na sequência fazem referência às suposições abaixo [98]:

1. A função  $\mathbf{f} : \mathbb{R}^n \times \mathbb{R}^m \rightarrow \mathbb{R}^n$  é duas vezes continuamente diferenciável em  $\mathbb{X} \times \mathbb{U}$ ;
2. A origem  $\mathbf{0} = \mathbf{f}(\mathbf{0}, \mathbf{0})$  é um ponto de equilíbrio do sistema (esta suposição não é restritiva, uma vez que qualquer ponto de equilíbrio sempre pode ser deslocado para a origem);
3. O conjunto  $\mathbb{U} \subset \mathbb{R}^m$  é compacto e convexo, o conjunto  $\mathbb{X} \subseteq \mathbb{R}^n$  é fechado e simplesmente conexo com  $(\mathbf{0}, \mathbf{0})$  no interior de  $\mathbb{X} \times \mathbb{U}$ ;
4. Todos os estados do sistema são mensuráveis;
5. O sistema não tem perturbações;
6. O modelo reproduz perfeitamente o comportamento do sistema.

### CPBM Não Linear Com Restrição Terminal de Estado Zero

A forma mais simples de se garantir a estabilidade em malha fechada do CPBM não linear consiste em impor uma restrição de igualdade terminal de estado zero [98]:

$$\mathbf{x}(k + N|k) = \mathbf{0}, \quad (3.35)$$

para forçar os estados do sistema a zero no final do horizonte de predição. Desde que as suposições de 1 a 6 mencionadas anteriormente sejam válidas, e que o problema (3.32) seja factível, a origem do sistema em malha fechada será estável assintoticamente. Caso o estado do sistema esteja na origem e entrada seja zero, a imposição da restrição de igualdade (3.35) implica que o sistema permanecerá todo o tempo na origem se não houver perturbações. Portanto, supõe-se que o horizonte de predição se expande até o infinito [98].

A principal vantagem do CPBM não linear com restrição terminal de estado zero é a sua simplicidade, pois não requer cálculos ou ajustes *offline*. Por outro lado, o problema de otimização (3.32) pode não ser factível com uma restrição tão rígida como (3.35) [98]. Além disso, caso a função de custo não seja contínua na origem, a trajetória dos estados no CPBM não linear com restrição terminal de estado zero e um horizonte de predição infinito não será necessariamente igual a do CPBM não linear de horizonte infinito sem a restrição [98].

### CPBM Não Linear Quase Infinito

No CPBM não linear quase infinito [98, 99], o problema de otimização (3.32) é modificado através da utilização de um termo de penalidade terminal quadrático:

$$V(\mathbf{x}_N) = \mathbf{x}_N^T P \mathbf{x}_N, \quad (3.36)$$

e de uma restrição de estabilidade de desigualdade:

$$\mathbf{x}_N \in \Omega, \quad (3.37)$$

onde  $\mathbf{x}_N := \mathbf{x}(k + N|k)$ ,  $\Omega$  é uma região terminal e  $P$  uma matriz simétrica positiva definida. A região  $\Omega$  e a matriz  $P$  são calculadas *offline* de acordo com o procedimento descrito em [98], tal que (3.33), com a função  $V$  escolhida como em (3.36), se aproxime de uma função de custo com horizonte infinito. Neste caso,  $\Omega$  e  $P$  são utilizadas apenas para garantir a estabilidade do sistema em malha fechada e não tem relação com requisitos de desempenho do controlador.

Para que a origem do sistema em malha fechada seja estável assintoticamente, além das suposições de 1 a 6 mencionadas acima, as seguintes suposições também devem ser válidas [98]:

7. O custo de etapa quadrático, isto é, da forma (3.34);
8. A linearização Jacobiana  $\mathbf{x}(k + 1) = A\mathbf{x}(k) + B\mathbf{u}(k)$  de (3.30), onde  $A := \frac{\partial \mathbf{f}}{\partial \mathbf{x}}(\mathbf{0}, \mathbf{0})$  e  $B := \frac{\partial \mathbf{f}}{\partial \mathbf{u}}(\mathbf{0}, \mathbf{0})$ , é estabilizável.

No CPBM não linear quase infinito, a estabilidade em malha fechada do sistema é garantida resolvendo-se um problema de otimização com horizonte finito. Sua

principal vantagem é a necessidade de apenas uma restrição de desigualdade (3.37), que não é tão rígida como uma restrição de igualdade (3.35). No controle quase infinito, para garantir a estabilidade, não é necessário encontrar soluções ótimas do problema (3.32). Neste caso, basta que o problema seja factível para que ele seja também estável. A desvantagem deste método é a necessidade de se determinar previamente  $\Omega$  e  $P$ .

## 3.4 Sistema de Gerenciamento de Energia Preditivo Neural

### 3.4.1 Objetivos do Sistema de Controle

Conforme foi mostrado na Figura 2.1 no Capítulo 2, o VEHCC empregado neste trabalho não é do tipo *plug-in*. Ou seja, a bateria é recarregada somente pela CaC, e o sistema de gerenciamento de energia (SGE) deve garantir a operação do sistema de propulsão do veículo no modo sustentação de carga (descrito no Capítulo 1). Ao mesmo tempo, dispondo-se da capacidade do CPBM não linear de lidar com múltiplas restrições do sistema simultaneamente, o SGE deve ser capaz de proteger a bateria e a CaC contra danos e também alguns efeitos que podem acelerar sua degradação.

O SGE deve, portanto, encontrar uma solução para o problema de alocação de recursos energéticos, considerando três objetivos concorrentes:

1. Evitar uma descarga excessiva da bateria;
2. Evitar uma sobrecarga da bateria;
3. Minimizar o uso da CaC e maximizar sua eficiência.

Os objetivos 1 e 2 são estabelecidos com o intuito de aumentar a vida útil da bateria, e fazer a prevenção contra danos que são causados por uma descarga excessiva ou sobrecarga. Enquanto o objetivo 3 busca aumentar a vida útil da CaC e também melhorar a economia de combustível.

A solução para este problema de alocação de recursos consiste em um compromisso entre estes três objetivos, onde é impossível melhorar um sem piorar outro. Evitar a descarga excessiva da bateria implica no uso da CaC. Dessa forma, ao priorizar o objetivo 1, o terceiro é prejudicado. Ao rastrear a eficiência máxima da CaC o seu ponto de operação fica normalmente fixado em um valor de corrente [52]. Neste caso, se a demanda do motor elétrico for menor do que o gerado pela CaC em seu ponto de eficiência máxima, o excesso de energia gerada pela CaC irá carregar a bateria. Portanto, ao priorizar o objetivo 3, o segundo é penalizado.

### 3.4.2 Arquitetura do Sistema de Controle

A Figura 3.4 apresenta o diagrama de blocos do esquema de controle proposto, em que a planta a ser controlada consiste no sistema de propulsão do VEHCC apresentado na Figura 2.1 no Capítulo 2. Como mencionado no Capítulo 2, a corrente da CaC  $i_{FC}$  é controlada pelo conversor dc/dc *boost* e a potência de tração  $P_{EM}$ , que é requerida pelo motor elétrico, age como uma perturbação. O controle de  $i_{FC}$  é realizado por malha de controle interna, normalmente incorporada no conversor dc/dc, e configurada para rastrear a referência de corrente  $i_{FC}^*$ .

O SGE proposto consiste no CPBM não linear da Figura 3.4, e seu papel é determinar qual deve ser o valor ótimo da corrente de referência  $i_{FC}^*$ , para que seja possível alcançar o melhor compromisso entre os objetivos concorrentes mencionados no subseção anterior. Em função da potência demandada  $P_{EM}$  e do EdC da bateria  $\xi_{BT}$ , o CPBM não linear tenta manter uma quantidade de energia armazenada na bateria, rastreando uma referência de EdC desejada  $\xi_{BT}^*$ . O controlador CPBM não linear também possui a tensão medida da CaC  $v_{FC}$  como entrada, para poder calcular as previsões usando (2.42) de forma recursiva.




Figura 3.4: Diagrama de blocos do sistema de gerenciamento de energia (SGE) proposto.

### 3.4.3 Modelo de Predição Não Linear

Desconsiderando as perturbações, o balanço de potências dado em (2.1), o EdC da bateria dado em (2.18) e a tensão da CaC dada em (2.42), podem ser combinados e reescritos como um sistema não-linear representados no espaço de estados discreto:

$$\begin{cases} x_1^+ = x_1 + \frac{h}{Q_{BT}} \frac{\eta_b g(x, u) u}{v_{BT}} \\ x_2^+ = g(x, u) \\ x_3^+ = x_2 \\ x_4^+ = u \\ x_5^+ = x_4 \end{cases}, \quad (3.38)$$

onde  $h$  é o intervalo de amostragem,  $\eta_b$  é a eficiência do conversor cc/cc boost,  $g(x, u)$  é a função que representa a RNR dada em (2.42) e reescrita em função das variáveis

de estado,  $Q_{BT}$  é a capacidade da bateria,  $v_{BT}$  é a tensão da bateria e  $u = i_{FC}$  é a entrada do sistema, que corresponde à corrente da CaC. O vetor de estados do modelo de predição não linear dado por (3.38) é definido como:

$$x(k) = \begin{bmatrix} \xi_{BT}(k) & v_{FC}(k-1) & v_{FC}(k-2) & i_{FC}(k-1) & i_{FC}(k-2) \end{bmatrix}^T. \quad (3.39)$$

No modelo não linear do sistema de propulsão do VEHCC, dado por (3.38), considera-se que todos os estados podem ser medidos.

É importante ressaltar que:

$$\frac{\eta_b g(x, u) u}{v_{BT}} = \frac{\eta_b P_{FC}}{v_{BT}} = i_{BT}, \quad (3.40)$$

o que demonstra que, em (3.38), a equação de  $x_1^+$  é a mesma de (2.18), considerando  $P_{EM} = 0$  e  $P_{AS} = 0$  em (2.1). O CPBM não linear, então, utiliza (3.38) como o modelo de predição para prever o comportamento do sistema e resolver o problema de otimização dado por (3.32).

### 3.4.4 Função de Custo

No sistema de controle preditivo proposto para o gerenciamento de energia do VEHCC, a função de custo possui a forma:

$$J_N(\mathbf{u}_k) = \sum_{j=0}^{N-1} L(x(k+j), u(k+j)) + V(x(k+N)), \quad (3.41)$$

onde o primeiro termo consiste em um somatório da função  $L(x, u)$ , que deve ser calculada em todo horizonte de predição, e o segundo termo consiste na função  $V(x)$  avaliada somente no último ponto do horizonte de predição.

A função  $L(x, u)$  consiste em uma combinação de diferentes indicadores de desempenho que levam em conta os objetivos do controle. Como esta função é avaliada para todo o horizonte de predição ( $j = 1, \dots, N-1$ ), ela é denominada de “custo corrente”. A função  $L(x, u)$  especifica o desempenho desejado, resultante de considerações técnicas para atender aos objetivos de controle listados na Seção 3.4.1. Entretanto, como o CPBM não linear é formulado com um horizonte de predição finito, o custo corrente não pode garantir a estabilidade em malha fechada do sistema [96, 99, 100].

No CPBM não linear, uma abordagem utilizada para garantir a estabilidade do sistema em malha fechada com um horizonte de predição finito, consiste em adicionar um “custo terminal” na função de custo [99]. Na função de custo dada por (3.41) a função  $V(x)$  corresponde ao custo terminal. Esta função recebe este

nome pois é calculada apenas para o último instante do horizonte de produção  $k + N$ . Essa técnica é chamada de CPBM não linear *quase-infinito* e aproxima o caso do horizonte finito para um horizonte infinito com o mesmo custo corrente [99].

### 3.4.5 Indicadores de Desempenho

Considerando o EdC da bateria, o primeiro dos indicadores de desempenho é definido como:

$$\ell_k^{x_1} = \|x_1(k) - x_1^{ref}(k)\|_2^2, \quad (3.42)$$

onde  $\|\cdot\|_2^2$  denota o quadrado da norma euclidiana [96]. Este indicador de desempenho consiste na medição da distância entre o valor presente de  $x_1$  e o valor desejado  $x_1^{ref}$ . Portanto, a função de custo é penalizada se houver uma diferença entre os valores dessas duas variáveis. Consequentemente, (3.42) é usada para realizar a sustentação da carga da bateria e contribui para os objetivos de controle #1 e #2, apresentados na subseção 3.4.1.

Para garantir a operação do sistema sob ações de controle mais suaves e, portanto, evitar o uso intensivo da CaC, o próximo indicador de desempenho é definido como:

$$\ell_k^{\Delta u} = \|\Delta u(k)\|_2^2, \quad (3.43)$$

onde  $\Delta u(k) \triangleq u(k) - u(k-1)$  é a taxa de variação da corrente da CaC. Assim, o indicador de desempenho dado por (3.43) é usado para desacelerar a resposta do CaC à perturbação do sistema, e contribui para o objetivo de controle #3, apresentados na subseção 3.4.1.

Considerando o MEPT da CaC, o terceiro indicador de desempenho é definido como:

$$\ell_k^\eta = -\|\eta_{FC}(k)\|_2^2, \quad (3.44)$$

onde  $\eta_{FC}$  é a eficiência da CaC, dada por (2.38) em função das predições de tensão. Como a solução de (3.32) consiste em minimizar uma função de custo  $J_N$ , dada pela soma dos indicadores de desempenho, o termo fornecido por (3.44) possui sinal negativo para que as predições de eficiência sejam maximizadas durante o procedimento de resolução do PCO.

Através da combinação de (3.42), (3.43) e (3.44), o custo  $L(x, u)$  que deve ser minimizado é então definido como a soma ponderada dos três termos:

$$L(x, u) = \lambda_1 \ell_k^{x_1} + \lambda_2 \ell_k^{\Delta u} + \lambda_3 \ell_k^\eta \quad (3.45)$$

onde  $\lambda_1$ ,  $\lambda_2$  e  $\lambda_3$  são coeficientes que podem ser ajustados para priorizar um objetivo em detrimento do outro. A ordem de magnitude destes coeficientes depende da

ordem de magnitude de  $\ell_k^{x_1}$ ,  $\ell_k^{\Delta u}$  e  $\ell_k^\eta$ , caso  $x_1$ ,  $u$  e  $\eta_{FC}$  não estejam normalizadas.

### 3.4.6 Restrições do Sistema

As restrições do sistema podem ser impostas às variáveis de estado ou às variáveis de entrada. As variáveis de entrada são restritas com base nas características físicas e limitações do equipamento. Neste trabalho, as restrições impostas à corrente da CaC são:

$$2 \text{ A} \leq i_{FC} \leq 70 \text{ A}. \quad (3.46)$$

A corrente da CaC é limitada a 70 A pois é o valor máximo dado pelo fabricante. Além de proteger a CaC de valores elevados de corrente, neste caso, também foi imposto um limite de corrente inferior de 2 A. O limite inferior foi imposto para evitar partidas e paradas frequentes, que é um fator de degradação conhecido [55, 59] e, portanto, contribui para o objetivo de controle #3, apresentados na subseção 3.4.1.

Limites superior e inferior também são impostos ao EdC da bateria, para permitir que ela opere apenas dentro de uma faixa limitada, evitando uma descarga profunda ou uma sobrecarga:

$$55\% \leq \xi_{BT} \leq 65\%. \quad (3.47)$$

A restrição dada por (3.47) contribui, portanto, para os objetivos #1 e #2, enumerados na subseção 3.4.1. Estes limites arbitrários foram escolhidos com a finalidade de melhor testar o controlador. Uma janela menor permite visualizar como o controlador se comporta perto das restrições, mesmo em experimentos de menor duração. Em aplicações práticas, uma janela maior pode ser permitida (por exemplo, 20% e 90%). Contudo, mesmo com um limite superior maior, ainda há risco de sobrecarregar a bateria (caso o veículo transite por uma descida longa, por exemplo). Nestes casos, o VEHCC necessitaria um resistor de frenagem. Com o objetivo de, em um primeiro momento, simplificar o sistema de controle proposto, o veículo é considerado como um sistema com entrada única (corrente da CaC) e saída única (EdC da bateria). Por este motivo, nesta tese, o resistor de frenagem não foi considerado.

## 3.5 Resumo do Capítulo

O capítulo apresentou, em um primeiro momento, a formulação do CPG para o caso de um sistema com entrada única e saída única. A principal motivação para essa revisão é o entendimento de alguns fundamentos que são aplicáveis também ao CPBM não linear, quando não há restrições, e a lei do CPG é obtida de forma analítica. No caso com restrições, um problema de programação quadrática (PQ) deve ser resolvido a cada instante de amostragem seguindo o princípio do horizonte

retrocedente (PHR). O capítulo mostrou ainda como o CPG pode ser aplicado para fazer o gerenciamento de energia de um VEHCC, considerando o veículo como um sistema de entrada única e saída única

Em seguida, o capítulo apresentou uma revisão dos fundamentos básicos e formulação do algoritmo de um sistema de CPBM não linear. Além disso, foi feita uma breve revisão de algumas técnicas encontradas na literatura para garantir estabilidade em malha fechada do CPBM não linear. Por fim, o capítulo propôs a aplicação do CPBM não linear para o gerenciamento de energia de um VEHCC usando uma RNR como modelo da CaC. O objetivo deste trabalho é fazer a verificação experimental desse esquema de controle proposto e, por este motivo, não foi feita a prova de estabilidade em malha fechada. Este trabalho prioriza a descrição do método e sua validação experimental, apresentada no Capítulo 4.

# Capítulo 4

## Resultados e Discussões

Este capítulo apresenta os resultados experimentais para validar o funcionamento do sistema de gerenciamento de energia (SGE) preditivo neural proposto. O SGE foi implementado em um computador de placa única de baixo custo, e os experimentos foram realizados com uma bancada de testes *hardware-in-the-loop* (HiL) equipada com uma CaC do tipo PEM de 3 kW. Inicialmente, o capítulo descreve a bancada de testes HiL, utilizada tanto para obtenção dos dados de treinamento do modelo neural da CaC, quanto para a realização dos experimentos de validação do controlador. Em seguida, a validação do controlador proposto é feita através de uma análise de sensibilidade do coeficiente de penalização do esforço de controle, e do número de amostras do horizonte de predição. Ao final, o capítulo apresenta um estudo comparativo entre o CPBM não linear proposto, o controle preditivo generalizado (CPG) e um controle por banda de histerese (CBH).

### 4.1 Bancada de Testes *Hardware-in-the-Loop*

Os experimentos para validação do CPBM não linear proposto neste trabalho foram realizados em uma bancada de testes HiL, que se encontra no Laboratório de Células a Combustível do Cepel e é mostrada na Figura 4.1. Esta bancada é composta por um sistema NI PXIe-8880 RT, um computador de placa única BeagleBone Black (BBB), uma carga cc eletrônica programável, modelo NHR 4700, um computador que executa um aplicativo de supervisão e monitoramento desenvolvido em LabView, um osciloscópio (Tektronix DPO7104) e um empilhamento de CaC's do tipo PEM de 3 kW, modelo H3000, fabricado pela Horizon Fuel Cell Technologies.

O sistema PXI é usado para simular em tempo real o comportamento dinâmico da bateria, além de gerar um perfil de demanda de energia com base na velocidade do veículo e nos modelos descritos no Capítulo 2. O BBB é usado para processar o algoritmo do EMS proposto nesta tese e gerar o sinal de corrente de referência para controlar a carga cc eletrônica, que é empregada como uma interface de potência para

gerar a corrente desejada para a CaC. O programa desenvolvido em LabView tem a função de controlar a bancada, além de fazer o registro dos dados experimentais. Um diagrama com essa configuração é apresentado na Fig. 4.2.

O empilhamento H3000 é mostrado em mais detalhe na Figura 4.3. Ele é composto por 72 células, é do tipo catodo aberto e possui um controlador do próprio fabricante, que gerencia o suprimento de ar e regula a temperatura do empilhamento, através do controle da velocidade de quatro ventoinhas conectadas à parte traseira da unidade. Além disso, o H3000 é auto umidificado, opera no modo anodo fechado e com uma pressão inicial regulada em 0,2 MPa no anodo.




Figura 4.1: Bancada de testes *hardware-in-the-loop* (HiL).




Figura 4.2: Diagrama da bancada de testes *hardware-in-the-loop* (HiL).




Figura 4.3: Empilhamento de CaC's tipo PEM modelo H3000.

## 4.2 Identificação Experimental do Modelo do Empilhamento Tipo PEM

### 4.2.1 Dados Experimentais

O modelo neural utilizado pelo CPBM não linear para o cálculo das previsões de tensão da CaC deve ser treinado *offline*, em uma etapa de projeto que precede a validação experimental do controlador. Como descrito no Capítulo 2, tal modelo tem como entradas o valor presente da corrente da CaC e valores passados de corrente e de tensão. Assim, na fase de projeto, um conjunto de dados de pares de entrada e saída (corrente e tensão, respectivamente) deve ser usado para a identificação da RNR. Para a obtenção deste conjunto de dados, é realizado um experimento que consiste em impor um perfil de corrente à CaC e registrar as respostas no tempo da tensão.

O experimento foi realizado com um perfil que consiste em uma escada de corrente seguida de valores aleatórios. A escada de corrente é utilizada na etapa de identificação da equação de vazão média de hidrogênio, dada por (2.34), utilizada no cálculo da eficiência da CaC. Enquanto o perfil aleatório leva em consideração diversos cenários de operação da pilha, incluindo picos ocasionais na corrente. As medições de corrente e tensão são mostradas nas Figuras 4.4 e 4.5, respectivamente, e as medições da vazão instantânea e média de hidrogênio são apresentadas na Figura 4.6. Todos os dados foram registrados com um período de amostragem de 100 ms.




Figura 4.4: Dados experimentais de corrente da CaC para o treinamento do modelo neural.




Figura 4.5: Dados experimentais de tensão da CaC para o treinamento do modelo neural.




Figura 4.6: Medições dos valores instantâneo e médio da vazão hidrogênio para o perfil de corrente da Figura 4.4.

#### 4.2.2 Identificação do Modelo Neural da Tensão

Antes do treinamento da RNR, foi feita uma operação de decimação (*downsampling*) das medições de corrente e tensão por um fator de 10. Ou seja, o período de amostragem foi alterado de 100 ms para 1 s. O objetivo desta operação é evitar a super especialização (*overfitting*) da rede neural. Este fenômeno ocorre quando

o erro entre as previsões da RNR e os dados do conjunto de treinamento é muito pequeno, mas é grande quando a rede é testada com novos dados. Neste caso, a RNR “memoriza” os exemplos do treinamento, mas não é capaz de generalizar para novas situações. A decimação reduz o tamanho do conjunto de dados de treinamento e descarta informação desnecessária ou redundante, que pode prejudicar a convergência do algoritmo de treinamento da RNR, além de levar a um esforço computacional desnecessário. As medições de tensão também poderiam ser filtradas por um filtro passa-baixa, para eliminar as componentes de alta frequência. Porém, a série resultante sofreria influência da dinâmica do filtro.

A Figura 4.7 mostra o resultado da decimação nas medições de tensão. Nela, observa-se que esta operação minimiza o efeito das purgas sobre a tensão, ao mesmo tempo em que mantém a característica da resposta dinâmica da tensão ao degrau de corrente. A abertura da válvula de purga a cada 10 s, provoca pequenas quedas de tensão que podem ser observadas na curva azul da Figura 4.7. Contudo, a modelagem por RNR’s não é feita com objetivo de reproduzir este efeito. Por esta razão, busca-se preservar apenas a resposta da tensão com relação à corrente, que consiste na principal informação que deve ser memorizada pela rede neural. Por fim, como benefício adicional, a decimação também minimiza o ruído de medição.

Para garantir que o sinal com uma nova taxa de amostragem não apresente o efeito indesejável de *aliasing*, foi feita uma análise das componentes de frequência do perfil de tensão da Figura 4.5. A Figura 4.8 apresenta os espectros de frequência do perfil de tensão com a taxa de amostragem original e após a decimação. A Figura 4.8a mostra as componentes de frequência do perfil de tensão até frequência de 1 Hz amostrada na taxa de 100 ms. Neste caso não houve necessidade de mostrar componentes de frequência mais altas pois a amplitude das componentes é muito próximo de zero, mesmo em frequência menores que 1 Hz. Na Figura 4.8b são mostradas as componentes de frequência do perfil de tensão até frequência de 0,5 Hz (metade da taxa de amostragem) amostrada na taxa de 1 s. Uma comparação entre as Figuras 4.8a e 4.8b mostra que as componentes de frequência permaneceram inalteradas após a decimação e, portanto, não há efeito de *aliasing*.




Figura 4.7: Decimação das medições de tensão.




Figura 4.8: Espectros de frequências do perfil de tensão da Figura 4.5 amostrado com (a) 100 ms e (b) 1 s.




Figura 4.9: Série de tensão diferencial.

O número de amostras do vetor regressor (parâmetros  $M$  e  $N$  em (2.40)) é determinado seguindo o método descrito em [72]. Em um primeiro momento é feita a diferenciação da série de tensão e obtida a série de tensão diferencial, que é em princípio, estacionária. O cálculo dos elementos da série diferencial é feito através da diferença entre dois elementos subsequentes da série de tensão, de acordo com:

$$\Delta y_k = y_k - y_{k-1}. \quad (4.1)$$

Após calculada esta primeira diferença, a série de tensão diferencial possui a forma mostrada na Figura 4.9, que parece aproximadamente estacionária (sua média e variância são aproximadamente constantes).




Figura 4.10: Autocorrelação parcial da série de tensão diferencial.

Em seguida, para a determinação do número de amostras do vetor regressor, o gráfico de autocorrelação parcial amostral da série de tensão diferencial mostrado na Figura 4.10 é obtido<sup>1</sup>. Este gráfico revela que existe uma dependência entre o valor atual da tensão (atraso 0) e a primeira e a segunda amostras atrasadas da tensão (atrasos 1 e 2), para os quais o índice de correlação se encontra acima (ou abaixo) da linha que representa o intervalo de 95% de confiança. Ou seja, pode-se dizer que há pelo menos 95% de chance que a primeira e a segunda amostras atrasadas da tensão podem influenciar a amostra atual da série de tensão diferencial. Portanto, define-se  $N = 2$ . Por fim, o número de amostras atrasadas da saída (parâmetro  $N$ ) deve ser maior ou igual ao número de amostras atrasadas da entrada (parâmetro  $M$ ) [102]. Assim, escolheu-se o número de amostras atrasadas da entrada igual ao da saída:  $M = N = 2$ .


A RNR foi treinada usando o Neural Network Toolbox do MATLAB [103], e a Regularização Bayesiana foi empregada como algoritmo de treinamento. O algoritmo de treinamento, desenvolvido em MATLAB é apresentado na Seção B.1 do Apêndice B. O conjunto de dados de treinamento é composto pelos primeiros 1800 segundos registrados, e o conjunto de dados de validação corresponde aos dados restantes (de 1800 s até o final do experimento). O treinamento foi realizado recursivamente por dez vezes, forçando uma inicialização aleatória dos pesos da rede no início de cada ciclo de treinamento, e o resultado com o menor erro entre as previsões e os valores experimentais foi escolhido entre os dez. Foram testadas redes com 3, 4, 5 e 6 neurônios na cama oculta ( $n_h$ ). O melhor compromisso entre complexidade da rede e menor erro de predição obtido foi com a RNR com quatro neurônios na cama oculta ( $n_h = 4$ ).

As previsões de tensão da CaC durante a etapa de treinamento do modelo neural NARX resultante são apresentadas na Figura 4.11, e as previsões feitas pelo modelo na etapa de validação são mostradas na Figura 4.12. As previsões da etapa de treinamento são as melhores previsões feitas pela rede NARX durante esta fase,


<sup>1</sup>O gráfico apresentado foi obtido através da função *parcorr* do MATLAB [101]

usando apenas os dados registrados de 0 a 1800 s durante o experimento. Como mostra a Figura 4.11b, durante esta fase, o erro de predição relativo a cada instante é inferior a 2%, resultando em um erro quadrático médio (*Mean Squared Error* - MSE) de 0,0386. Durante a fase de validação, como mostra a Figura 4.12b, o erro permaneceu na maior parte do tempo também abaixo de 2%, excedendo esse valor apenas em alguns transitórios, resultando em um MSE de 0,0701.

Para uma aplicação em CPBM não linear, os erros de predição apresentados na Figura 4.12b são considerados aceitáveis. Ao ser implementado no controlador, o modelo NARX, que fornece predição de apenas uma amostra à frente, é adaptado para fornecer predições de várias amostras futuras no controlador proposto, como em [104]. Como o CPBM não linear requer apenas um horizonte de previsão de curto prazo (geralmente 10 a 20 amostras à frente) [74], as predições da tensão são feitas de maneira recursiva, substituindo os valores medidos (reais) de amostras passadas em (2.40) pelos valores preditos pelo modelo.




(a)




(b)

Figura 4.11: (a) Predições de tensão do modelo neural NARX e (b) erros de predição durante a etapa de treinamento.



(a)



(b)

Figura 4.12: (a) Predições de tensão do modelo neural NARX e (b) erros de predição durante a etapa de validação.

### 4.2.3 Identificação do Modelo de Vazão Média de Hidrogênio

A eficiência da CaC é calculada através relação (2.38) entre a potência elétrica gerada e o valor médio da vazão de hidrogênio estimado, dado por (2.34). Os parâmetros  $W_1$  e  $W_2$ , usados para o cálculo da vazão média de hidrogênio, são determinados através do método de mínimos quadrados usando os dados de vazão média durante a escada de corrente do perfil das Figuras 4.4 e 4.6. A Figura 4.13 exibe em pontos quadrados a vazão média de hidrogênio em função da corrente da CaC medida durante a parte inicial do experimento mostrada nas Figuras 4.4, 4.5 e 4.6. Na mesma figura, também é mostrada em azul a vazão média estimada de hidrogênio após a obtenção dos parâmetros  $W_1$  e  $W_2$ . Os valores obtidos para os parâmetros de (2.34) foram  $W_1 = 7,334 \times 10^{-4}$  g/A.s e  $W_2 = 7,744 \times 10^{-4}$  g/s. O coeficiente de determinação encontrado neste caso foi  $R^2 = 0,9972$ .




Figura 4.13: Vazão média de hidrogênio experimental e estimada em função da corrente da célula a combustível (CaC).

## 4.3 Resultados Experimentais

### 4.3.1 Validação do Controlador Proposto

O SGE baseado no CPBM não linear proposto nesta tese foi testado experimentalmente usando a bancada de testes HiL apresentada na Seção 4.1. Três experimentos foram realizados considerando três conjuntos de valores para os coeficientes de penalização  $\lambda_1$ ,  $\lambda_2$  e  $\lambda_3$ . Como definido na subseção 3.4.5,  $\lambda_1$  penaliza o erro entre o EdC da bateria e um valor de referência,  $\lambda_2$  penaliza a taxa de variação da corrente da CaC e  $\lambda_3$  favorece o rastreamento da eficiência máxima da CaC. O objetivo destes experimentos é mostrar como a escolha dos coeficientes de penalização influencia na resposta do controlador. Os diferentes conjuntos de coeficientes para cada um dos três casos de estudo são mostrados na Tabela 4.1, e os parâmetros dos modelos do veículo, da bateria e das curvas de eficiência dos conversores são mostrados nas Tabelas 4.2, 4.3 e 4.4, respectivamente.

O problema de otimização do CPBM não linear é resolvido usando um algoritmo de programação quadrática sequencial (PQS) implementado em MATLAB, que é exibido na Seção B.2 do Apêndice B. Em um algoritmo de PQS, o problema de otimização é aproximado para um problema de programação quadrática (PQ) em cada iteração. Assim, a cada iteração do algoritmo de PQS, um problema de PQ é resolvido usando o método dos conjuntos ativos, que também foi implementado em MATLAB e é exibido na Seção B.3 do Apêndice B.

Em todas os experimentos, o valor de referência do EdC da bateria foi ajustado

Tabela 4.1: Coeficientes de ponderação da função de custo para cada caso de estudo do CPBM não linear.

| Caso | $\lambda_1$ | $\lambda_2$ | $\lambda_3$ |
|------|-------------|-------------|-------------|
| A    | 1,00        | 0,01        | 0,00        |
| B    | 1,00        | 1,00        | 0,00        |
| C    | 1,00        | 1,00        | 0,20        |

Tabela 4.2: Parâmetros do modelo do veículo.

| Parâmetro | Descrição                            | Valor                  |
|-----------|--------------------------------------|------------------------|
| $m_V$     | Massa total                          | 450 kg                 |
| $A_f$     | Área frontal                         | 1,591 m <sup>2</sup>   |
| $r_w$     | Raio das rodas                       | 0,623 m                |
| $c_d$     | Coefficiente de arrasto aerodinâmico | 0,64                   |
| $c_r$     | Coefficiente de atrito               | 0,0094                 |
| $\rho_a$  | Densidade do ar                      | 1,18 kg/m <sup>3</sup> |
| $g$       | Aceleração gravitacional             | 9,81 m/s <sup>2</sup>  |

Tabela 4.3: Parâmetros dos modelo da bateria.

| Parâmetro  | Descrição                                         | Valor                  |
|------------|---------------------------------------------------|------------------------|
| $Q_{BT}$   | Capacidade                                        | 6,5 A.h                |
| $U_{BT}^0$ | Tensão constante                                  | 78,3 V                 |
| $R_{BT}$   | Resistência interna                               | 0,111 $\Omega$         |
| $K_1$      | Tensão de polarização                             | 0,116 V                |
| $K_2$      | Amplitude da zona exponencial da bateria          | 6,68 V                 |
| $K_3$      | Inverso da constante de tempo da zona exponencial | 2,31 A.h <sup>-1</sup> |

Tabela 4.4: Parâmetros das curvas de eficiência dos conversores.

| Parâmetro         | Valor                |
|-------------------|----------------------|
| $[c_0, c_1, c_2]$ | $[0,02, 0,05, 0,20]$ |

em 60%, o horizonte de predição  $N$  foi fixado em 10 amostras e um período de amostragem utilizado foi de 1 s. Para restrições impostas na corrente da CaC, de acordo com (3.46), foram impostos um valor mínimo de 2 A e um valor máximo de 70 A. No EdC da bateria, de acordo com (3.47), foi estabelecido um valor mínimo de 55% e um valor máximo de 65%. A janela de operação do EdC foi escolhida estreita desta maneira com a finalidade de testar o controlador. Portanto, se o controlador não puder respeitar os limites mínimo de 55% e máximo de 65%, ainda haverá uma margem de segurança para que a bateria não seja sobrecarregada durante os experimentos de validação. Em aplicações práticas, em um VEHCC real, uma janela maior pode ser usada.

O SGE foi testado com o ciclo de condução exibido na Figura 4.14. A CaC de 3 kW disponível na bancada HiL não é capaz de suprir sozinha a potência de propulsão requerida por um veículo com os parâmetros da Tabela 4.2. Por este motivo, a demanda de potência dada pelo modelo quase-estático com estes parâmetros foi reduzida a 40%. Ou seja, é como se fosse considerado um veículo com 40% do tamanho daquele cujos parâmetros são dados na Tabela 4.2. O modelo do veículo foi simulado em tempo real, e teve como resultado as curvas de potência de tração (em azul) mostradas nas Figuras 4.15, 4.16 e 4.17. Os testes com cada um dos casos

listados na Tabela 4.1 foram realizados considerando o mesmo perfil de consumo de energia elétrica.

A influência do coeficiente  $\lambda_2$  (penalização da variação da corrente da CaC), sobre a suavidade das ações de controle pode ser avaliada observando as medições da corrente da CaC na Figura 4.18. Observa-se que, para o caso A, a corrente da CaC varia mais rapidamente, porque nele o valor de  $\lambda_2$  é o menor. No caso B, com o maior valor de  $\lambda_2$ , a resposta da corrente é mais lenta. O caso C possui o mesmo coeficiente de penalização variação da corrente da CaC que o caso B. Porém, no caso C,  $\lambda_3$  é diferente de zero e, portanto, há uma tentativa de rastrear a eficiência máxima da CaC. A influência de  $\lambda_3$  é discutida em detalhe nos próximos parágrafos.




Figura 4.14: Ciclo de condução (fase dois do ciclo FTP).




Figura 4.15: Potências de tração, da bateria e da CaC no elo cc para o caso A do CPBM não linear.




Figura 4.16: Potências de tração, da bateria e da CaC no elo cc para o caso B do CPBM não linear.

Ainda na Figura 4.18, também nota-se que o valor da corrente na CaC nunca chega a zero e, portanto, o controle respeitou a restrição mínima de 2 A da corrente.

O valor de  $\lambda_2$  teve pouca influência no EdC da bateria, como pode ser visto na Figura 4.19. Com um  $\lambda_2$  menor, no caso A, a corrente da CaC variou mais rapidamente do que nos casos B e C. No entanto, os casos A e B foram capazes de rastrear o ponto de ajuste do EdC de 60% com um erro semelhante, como mostrado pelas curvas na Figura 4.19, mesmo que o coeficiente de ponderação  $\lambda_2$  fosse cem vezes maior no caso B. O caso C teve um erro entre o EdC e seu valor de referência maior do que nos outros dois casos, mesmo tendo um  $\lambda_2$  igual ao do caso B. O erro maior, neste caso, é devido à influência de  $\lambda_3$ , que será explicada à seguir.




Figura 4.17: Potências de tração, da bateria e da CaC no elo cc para o caso C do CPBM não linear.




Figura 4.18: Medições experimentais da corrente da CaC real para os casos A, B e C do CPBM não linear.




Figura 4.19: EdC da bateria simulado em tempo real usando o controlador PXIe-8880 para os casos A, B e C do CPBM não linear.

Na Figura 4.20, pode-se analisar o efeito do coeficiente  $\lambda_3$ , usado para favorecer o rastreamento da eficiência máxima da CaC. A eficiência mostrada nessa figura foi calculada usando (2.38) a partir das medições de tensão e corrente da CaC, e da estimativa da vazão dada por (2.34) com os parâmetros levantados na seção 4.2.3. No caso C, o único com  $\lambda_3$  diferente de (e maior do que) zero, o controlador tenta maximizar a eficiência da CaC sempre que possível. Como resultado, a eficiência da CaC nunca atinge seu mínimo durante todo o experimento, como nos casos A e B. No caso C, o controlador tenta fazer com que a CaC opere em seu ponto de eficiência máxima, mas não pode fazer isso o tempo todo, porque há restrições que o controlador deve respeitar, como manter o EdC da bateria dentro dos limites estabelecidos por (3.47). Este efeito é observado analisando as curvas do caso C nas Figuras 4.19 e 4.20. Quando o EdC da bateria se aproxima do limite superior de 65%, há uma queda na eficiência da CaC porque, para manter o EdC abaixo do limite, o controlador diminui a corrente da CaC. Nos casos A e B, a eficiência da CaC é maior do que no caso C durante alguns momentos, mas na maior parte do tempo, a eficiência da CaC no caso C é maior e com menos variações.

No CPBM é esperado um compromisso entre as variáveis consideradas, ou seja, o controlador não pode operar de maneira ótima todas as variáveis simultaneamente. Uma análise da influência do ajuste dos coeficientes de ponderação ( $\lambda_1$ ,  $\lambda_2$  e  $\lambda_3$ ) em indicadores como o consumo de hidrogênio, degradação da CaC, energia elétrica total gerada pela CaC e eficiência total da CaC será feita na seção 4.3.3. Nela, as três versões do controlador proposto (casos A, B e C) serão comparadas a outros dois sistemas de gerenciamento de energia, um baseado no controle preditivo generalizado (CPG), e outro baseado no controle por banda de histerese (CBH).

### 4.3.2 Tempo de Cálculo do CPBM não linear

Para avaliar a influência do tamanho do horizonte de predição sobre o desempenho do controlador e sobre o tempo de cálculo, foram realizados dois experimentos adi-




Figura 4.20: Eficiência experimental da CaC real para os casos A, B e C do CPBM não linear.

cionais do caso C da Tabela 4.1, além daquele apresentado na subseção anterior. Os dois novos experimentos foram feitos um com um horizonte de predição de 5 amostras ( $N = 5$ ) e outro com horizonte de predição de 15 amostras ( $N = 15$ ). Por simplicidade, o horizonte de controle foi mantido com o mesmo tamanho que o horizonte de previsão.

Os tempos de execução do algoritmo de controle durante as primeiras 200 amostras dos experimentos do caso de estudo C, com  $N = 5$ ,  $N = 10$  e  $N = 15$ , são exibidos na Figura 4.21. Como esperado, o controlador com o horizonte de previsão mais curto apresentou o menor tempo de execução. Com um horizonte de 5 amostras, o tempo de execução foi de cerca de 20 ms, seguido pelo horizonte de 10 amostras com aproximadamente 100 ms e pelo horizonte de 15 amostras com 250 ms em média. Considerando o controlador com amostras  $N = 10$  como o caso base, ao reduzir esse número pela metade, o tempo de execução diminuiu 5 vezes. Ao aumentar o número de amostras em 1,5 vezes, o tempo de cálculo aumentou 2,5 vezes. Esses resultados mostram que o tempo de cálculo aumenta aproximadamente de forma exponencial em função do horizonte de predição.

Em relação ao desempenho do controlador, o caso com  $N = 5$  não obteve uma resposta satisfatória. Apesar do tempo de execução mais rápido, o controlador não foi capaz de manter o EdC da bateria dentro dos limites mínimo e máximo, como mostra a Figura 4.22. O caso com  $N = 10$  é o mesmo apresentado na subseção anterior, onde o controlador sempre procurou manter a eficiência da CaC o maior tempo possível próximo do seu valor máximo, desde que as restrições do EdC fossem respeitadas. Por fim, o caso com  $N = 15$  tem desempenho semelhante ao caso com amostras  $N = 10$ , mas ao custo de 2,5 vezes o tempo de execução. Os resultados mostram que o algoritmo de controle pôde ser executado com um horizonte de predição mais longo, com tempo ocioso suficiente entre os intervalos de amostragem,




Figura 4.21: Tempo de execução do algoritmo de controle durante as 200 primeiras amostras do caso C do CPBM não linear considerando diferentes tamanhos do horizonte de predição.




Figura 4.22: Comparação do EdC da bateria simulado em tempo real usando o controlador PXIe-8880 para o caso C do CPBM não linear considerando diferentes tamanhos do horizonte de predição.

atendendo às restrições do CPBM não linear.

### 4.3.3 Estudo Comparativo

Os resultados obtidos com o SGE baseado no CPBM não linear são comparados com um SGE baseado no CPG (descrito na Seção 3.2.3), e um SGE baseado no controle por banda de histerese (CBH). O CPG considera apenas o modelo do EdC da bateria, que consiste em um integrador. Tal modelo possui apenas um estado (o EdC) e apenas uma entrada, que é, neste caso, a potência da CaC (em vez da corrente, como no CPBM não linear). O CPG foi configurado para permitir uma penalidade da variável de controle semelhante à do CPBM não linear. Assim, restringiu-se a potência da CaC entre 130 W e 3000 W. Ao limitar a potência entre esses valores, a corrente da CaC fica limitada entre 2 A e 70 A aproximadamente, que são as mesmas restrições impostas a corrente no caso do CPBM não linear. O CPG implementado em MATLAB é exibido na Seção B.4 do Apêndice B.

O CBH, por sua vez, é configurado de acordo com a estratégia descrita em [105]. Nessa estratégia, a CaC pode operar em três modos diferentes: eficiência máxima, potência máxima ou potência zero (circuito aberto). O CBH coloca CaC no modo de eficiência máxima se o EdC da bateria for menor ou igual 55% e altera para o modo de espera caso o EdC atinja 65%, que são os mesmos limites inferior e superior impostos como restrições no caso do CPBM não linear e do CPG. Caso o EdC caia para 35%, o controlador entra no modo de máxima potência, e caso o EdC suba a 45% o controlador vai para o modo de espera novamente. No CBH, o algoritmo empregado para o rastreamento da máxima eficiência e da máxima potência foi o método de perturbar e observar (P&O), que é descrito em [106].

A seguir, o CPBM não linear proposto neste trabalho está identificado como controle preditivo neural (CPN). Os resultados experimentais de CPG e CBH são exibidos com os resultados do caso C do CPN nas Figuras 4.23 a 4.25. Como mostra

a Figura 4.23, todos os controladores gerenciam efetivamente a energia no sistema, isto é, fazem a sustentação de carga da bateria e mantêm o EdC dentro dos limites predeterminados. O CPG responde rapidamente para compensar a diminuição do estado de carga da bateria e apresenta o menor erro entre o EdC o seu valor de referência de 60%. Porém, diferentemente do CPN-C, o CPG não tem a capacidade de rastrear o ponto de eficiência máxima da CaC e, conseqüentemente, a corrente apresenta mais flutuações, como mostrado na Figura 4.24. Devido ao limite inferior imposto à corrente da CaC, a Figura 4.24 mostra que o CPN e o CPG inicializam a CaC apenas uma vez, no início do experimento, enquanto no caso do CBH há duas partidas. Portanto, o desempenho dos controladores CPN e CPG é melhor nesse sentido, uma vez que o número frequente de ciclos de partida e parada da CaC deve ser evitado para retardar o seu processo de degradação [55].

Com relação à eficiência da CaC, quando no modo de máxima eficiência, o CBH mantém a CaC operando com uma eficiência maior que o CPBM não linear e o CPG. Isso acontece porque o CBH não tem o objetivo de rastrear a referência EdC de 60% e, como mostra a Figura 4.25, o EdC da bateria oscila mais nesse caso. O CPN, por outro lado, minimiza o erro entre o EdC e seu valor de referência, além de rastrear a eficiência máxima (quando possível) e manter o EdC dentro de limites predefinidos. Por esses motivos, no caso do CPN, a eficiência da CaC é mantida




Figura 4.23: Comparação do EdC da bateria simulado em tempo real pelo controlador PXIe-8880 para o caso C do CPN, o CPG e o CBH.




Figura 4.24: Comparação das medições experimentais de corrente da CaC real para o caso C do CPN, o CPG e o CBH.




Figura 4.25: Eficiência experimental da CaC real para o caso C do CPN, o CPG e o CBH.

ligeiramente abaixo do seu valor máximo: o controlador tenta não sobrecarregar a bateria ao mesmo tempo em que tenta aumentar a eficiência da CaC (são dois objetivos concorrentes). No CPN, na maior parte do tempo, a eficiência da CaC é a mais alta possível e maior do que no caso dos outros dois controladores. Por outro lado, o CPG não possui capacidade de rastrear a eficiência máxima da CaC, por isso as oscilações na eficiência.

A Tabela 4.5 mostra, para cada uma das versões do CPN (A, B e C) e para o CPG e o CBH, o consumo de hidrogênio, a degradação da CaC, a energia elétrica gerada pela CaC e a eficiência total da CaC. O consumo apresentado nesta tabela considera qual seria a quantidade necessária de hidrogênio, para que o veículo percorresse uma distância de 100 km. Este consumo é calculado em função da quantidade total de hidrogênio consumida e da distância percorrida pelo veículo, ambas durante o experimento. A quantidade total de hidrogênio consumida foi calculada a partir das medições de vazão para cada um dos experimentos, e que são apresentadas no Apêndice C. A energia elétrica mostrada na Tabela 4.5 é calculada pela integral da opotência elétrica gerada pela CaC durante todo o experimento. A eficiência, por sua vez, também é calculada para a duração total do experimento. O seu valor  $\eta_{total}$  é dado por

$$\eta_{total} = \frac{\int_{T_{total}} P_{FC}(t) dt}{PCI \int_{T_{total}} \dot{m}_{H_2}(t) dt}, \quad (4.2)$$

Tabela 4.5: Consumo de hidrogênio, degradação da CaC, energia gerada pela CaC e eficiência total para os controladores CPN, GPC e HBC.

| Controle | Consumo de $H_2$ | Degradação             | Energia Elétrica | Eficiência |
|----------|------------------|------------------------|------------------|------------|
| CPN-A    | 258 g/100 km     | $2,912 \times 10^{-4}$ | 180 Wh           | 31%        |
| CPN-B    | 244 g/100 km     | $2,903 \times 10^{-4}$ | 178 Wh           | 33%        |
| CPN-C    | 253 g/100 km     | $2,874 \times 10^{-4}$ | 199 Wh           | 35%        |
| CPG      | 254 g/100 km     | $2,904 \times 10^{-4}$ | 181 Wh           | 32%        |
| CBH      | 256 g/100 km     | $5,119 \times 10^{-4}$ | 159 Wh           | 28%        |

que calcula a relação entre a energia elétrica total gerada pela CaC e a energia química total entregue sob a forma de hidrogênio, onde  $T_{total}$  é o tempo duração do experimento,  $P_{FC}(t)$  é a potência elétrica da CaC,  $\dot{m}_{H_2}(t)$  é a vazão de hidrogênio consumido e  $PCI$  é o valor do Poder Calorífico Inferior do hidrogênio, em J/kg.

A degradação mostrada na Tabela 4.5 foi calculada usando uma função de degradação da CaC  $\Delta_{FC}$ , dada por [107]:

$$\Delta_{FC}(t) = N_{start}\Delta_{start} + \int_0^t \delta(t)dt, \quad (4.3a)$$

$$\delta(t) = \frac{\delta_L}{3600} \left[ 1 + \frac{\alpha_L}{P_{nom}^2} (P_{FC}(t) - P_{nom})^2 \right], \quad (4.3b)$$

onde  $N_{start}$  é o número de partidas da CaC,  $\Delta_{start}$  é um coeficiente de degradação devido às partidas e paradas da CaC,  $\delta_L$  e  $\alpha_L$  são coeficientes de carga,  $P_{nom}$  é a potência nominal da CaC e  $P_{FC}(t)$  a potência da CaC no instante  $t$ . A função de degradação expressa um valor entre 0 (início da vida útil) e 1 (fim da vida útil). Na contabilização do número de partidas e paradas da CaC, para desconsiderar os efeitos do ruído nas medições de corrente, a CaC é considerada ligada quando sua corrente é superior a 500 mA. Os valores dos parâmetros usados em (4.3) são exibidos na Tabela 4.6.

Os resultados da Tabela 4.5 mostram que, em relação ao consumo de hidrogênio, o CPN sem maximização da eficiência (casos A e B) não apresentou vantagem em relação ao CPG e o CBH. No caso A, o consumo foi maior que o CPG e o CBH, e no caso B foi menor. A redução do consumo, no caso do CPN-B, está associada a penalização da taxa de variação da corrente da CaC ( $\lambda_2$  é 100 vezes maior no caso B do que no A). Essa economia de hidrogênio no caso B também poderia ser alcançada pelo CPG através do aumento da penalização da taxa de variação de potência. Portanto, não corresponde a uma vantagem do controle não linear sobre o linear. O caso C do CPN apresentou uma pequena redução do consumo em comparação ao CPG e ao CBH. Por outro lado, houve um aumento em comparação com o caso B, apesar dos dois terem a mesma penalização da taxa de variação da corrente da CaC ( $\lambda_2$ ). Essa diferença deve-se a função de custo do CPN-C possuir um termo para o rastreamento da eficiência máxima da CaC. Assim, nesse caso, a

Tabela 4.6: Parâmetros da função de degradação da CaC.

| Parâmetro        | Descrição                                        | Valor                |
|------------------|--------------------------------------------------|----------------------|
| $\Delta_{start}$ | Coeficiente de degradação por partidas e paradas | $2,5 \times 10^{-4}$ |
| $\delta_L$       | Coeficiente de carga                             | $5 \times 10^{-5}$   |
| $\alpha_L$       | Coeficiente de carga                             | 4                    |
| $P_{nom}$        | Potência nominal                                 | 3000 W               |

CaC opera por um tempo maior com uma potência mais elevada.

Quanto à degradação da CaC, a Tabela 4.5 mostra que o CPN apresentou uma ligeira melhora em relação ao CPG somente para o caso C, onde a corrente da CaC foi mantida mais estável (com menos picos). Em comparação com o CBH, tanto o CPN quanto o CPG apresentaram uma melhora significativa no nível de degradação, devido ao fato de apresentarem um número reduzido de partidas e paradas da CaC durante o experimento. Nos casos do CPN e do CPG, a CaC partiu apenas uma vez, no início do experimento, devido a restrição de corrente mínima, enquanto no caso do CBH, a CaC partiu duas vezes. Estes resultados mostram que, do ponto de vista de degradação da CaC, não há uma vantagem clara do CPN em relação ao CPG. Entretanto, devido a sua capacidade de impor restrições e limitar o número de partidas da CaC, tanto um quanto outro superaram o CBH.

A principal vantagem do CPN com rastreamento de eficiência máxima (caso C) fica evidente ao analisar a energia elétrica gerada e a eficiência, mostradas na Tabela 4.5. Os valores de energia elétrica gerada pela CaC durante o experimento e da eficiência total, mostrados na Tabela 4.5, demonstram que com o CPN-C a CaC foi capaz de gerar mais energia elétrica, mesmo tendo apresentado um consumo de hidrogênio similar ao do CPG e do CBH. Além disso, estes valores de hidrogênio consumido e energia gerada também demonstram que com o CPN-C seria possível utilizar uma bateria de menor capacidade. O efeito dessa energia a mais gerada pela CaC com o CPN-C também é observado na Figura 4.23, onde o EdC da bateria ficou um pouco acima da referência de 60% (bateria absorveu a diferença).

## 4.4 Resumo do Capítulo

Neste capítulo foram apresentados os resultados experimentais de validação do SGE preditivo neural proposto neste trabalho. Em uma etapa de projeto, antes da validação experimental do controlador, o modelo neural da tensão da CaC utilizado no controlador foi obtido. Além do modelo neural, também foram obtidos os parâmetros do modelo de vazão média de hidrogênio da CaC, que é usado para o cálculo da eficiência.

O controle preditivo neural (CPN) proposto foi implementado em um computador de placa única (BeagleBone Black), e os experimentos foram realizados em uma bancada de testes HiL equipada com uma CaC do tipo de PEM de 3 kW. Os testes de validação foram feitos com três conjuntos de coeficientes de penalização ( $\lambda_1$ ,  $\lambda_2$  e  $\lambda_3$ ), e os resultados demonstraram que o SGE proposto foi capaz de fazer a sustentação de carga da bateria, sem violar as restrições impostas. Ao mesmo tempo, quando foi adicionado o termo para maximização da eficiência ( $\lambda_3 \neq 0$ ), demonstrou-se que o controlador pôde operar a CaC em sua região mais eficiente,

desde que as restrições fossem respeitadas.

O capítulo apresentou ainda uma análise de sensibilidade do tempo de cálculo do controlador em função do tamanho do horizonte de predição. Demonstrou-se que o tempo de cálculo aumenta aproximadamente de forma exponencial com o horizonte de predição. Mostrou-se ainda que o controlador necessita de um horizonte de predição mínimo, caso contrário seu desempenho apresenta problemas. Como no caso com horizonte de 5 amostras, onde as restrições do EdC da bateria não foram respeitadas.

Por fim, o capítulo fez um estudo comparativo entre as diferentes versões do CPN, um controle preditivo generalizado (CPG) e um controle por banda de histerese (CBH). Neste estudo, foi avaliada a influência dos parâmetros do CPN em variáveis como o consumo de hidrogênio, degradação, eficiência e geração de energia da CaC durante os experimentos. Em termos de consumo de hidrogênio e degradação da CaC, demonstrou-se que tanto o CPN quanto o CPG foram mais vantajosos que o CBH. Além disso, mostrou-se que o CPN com capacidade rastreamento da eficiência máxima da CaC (caso C) foi o mais eficiente.

# Capítulo 5

## Conclusão

### 5.1 Considerações Finais

Um veículo elétrico híbrido a célula a combustível (VEHCC) incorpora tanto as vantagens de um veículo elétricos bateria (VEB) quanto as de um veículo com motor de combustão interna (VMCI). Como os VEB's, que são elétricos puros, os VEHCC's não emitem gases poluentes localmente. Porém, diferente daqueles, os VEHCC's possuem o tempo de reabastecimento e a autonomia similares aos dos VMCI's. Para este tipo de aplicação, a célula a combustível (CaC) do tipo PEM (*Proton Exchange Membrane*) é, atualmente, a tecnologia mais adequada, pois são mais compactas e sua temperatura e pressão de operação são mais baixas em comparação com outros tipos de CaC's. No entanto, as CaC's do tipo PEM possuem, hoje, um custo relativamente alto devido ao uso de metais preciosos em seus eletrodos. Além disso, fenômenos de degradação nas CaC's levam a um aumento no consumo de hidrogênio, um combustível cujo custo ainda não é competitivo o suficiente para viabilizar os VEHCC's como alternativa aos demais tipos de veículos elétricos, caso seja considerado apenas o custo de locomoção. Caso haja restrições de emissão de CO<sub>2</sub>, o hidrogênio torna-se competitivo, uma vez que os VEHCC's são considerados veículos de emissão local zero.

Neste contexto, esta tese apresentou uma proposta de sistema de gerenciamento de energia (SGE) baseado na técnica de controle preditivo baseado em modelo (CPBM) não linear. O objetivo principal do SGE é gerenciar o uso da CaC, afim de minimizar a degradação da mesma e proporcionar maior economia de combustível. Ao mesmo tempo, deve-se fazer a sustentação de carga da bateria do veículo, de maneira a garantir o fornecimento de energia para o sistema de propulsão. No CPBM, seja ele linear ou não linear, o modelo é fundamental. Dispor de um modelo mais preciso favorece a resposta do controlador, que no caso do SGE proposto significa um melhor desempenho do VEHCC em relação à economia de hidrogênio e à degra-

dação da CaC. Por esta razão, e pela falta de um modelo preciso do sistema a ser controlado, no controlador proposto, uma rede neural recorrente (RNR) é utilizada para modelar a CaC do tipo PEM.

O uso de RNR's para modelar o comportamento dinâmico de empilhamentos de CaC's do tipo PEM, foi inicialmente proposto por Lopes em [69], cujo resultado foi publicado em periódico internacional [72]. Essa estratégia justifica-se pelo fato de que mudanças nas condições internas de um empilhamento de CaC's afetam diretamente sua tensão terminal. Como as RNR's são modelos auto-regressivos, a precisão do modelo neural se mantém pois suas predições dependem dos valores passados da tensão da CaC usados como entrada. Lopes, em [69, 72], propôs em seu trabalho a modelagem por RNR's com vistas a aplicações de CPBM, onde inclusive sugere um esquema de controle para rastrear o ponto de eficiência máxima de um empilhamento de CaC's do tipo PEM. Contudo, não há uma implementação desse controlador, nem mesmo em simulação. Por esta razão, umas das principais contribuições do presente trabalho é a verificação experimental do funcionamento de um CPBM com RNR's, assim como melhor formalização da análise e projeto deste tipo de controle.

Devido à natureza das diferentes fontes de energia, a alocação de recursos em um VEHCC consiste em um problema multiobjetivo, sujeito à diferentes restrições. No caso de um VEHCC, como neste trabalho, tenta-se priorizar o uso da CaC no ponto de maior eficiência para reduzir o consumo de combustível, ao mesmo tempo em que o estado de carga (EdC) deve ser mantido dentro de limites predefinidos para evitar uma sobrecarga ou uma descarga excessiva. Algumas vezes, os objetivos concorrem entre si, como quando o SoC da bateria está próximo do limite máximo e CaC deve se distanciar do ponto de eficiência máxima para reduzir a energia elétrica gerada.

Neste tipo de problema, o SGE baseado em CPBM (tanto linear quanto não linear) é mais vantajoso que os SGE's tradicionais, baseados em métodos heurísticos. O CPBM é capaz de lidar com problemas multivariável e com diversas restrições simultaneamente. Os métodos heurísticos, por outro lado, dependem de regras muitas vezes complexas e que não exploram necessariamente o desempenho ótimo do veículo, em termos de eficiência, como é o caso aqui, ou mesmo em termos de outras variáveis. O CPBM não linear ainda apresenta uma vantagem comparado ao CPBM linear, pois considera todas as regiões de operação da CaC, sem recorrer à linearizações e aproximações comumente empregadas nos trabalhos encontrados na literatura, tanto em aplicações veiculares quanto estacionárias. O CPBM não linear também permite a inclusão em sua função de custo um termo para o rastreamento do ponto de eficiência máxima da CaC, o que não é possível no caso linear.

O SGE proposto nesta tese foi implementado em um computador de placa única de baixo custo, e o seu funcionamento foi validado experimentalmente em uma

bancada de testes *hardware-in-the-loop* (HiL) equipada com uma CaC real de 3 kW. No caso do CPBM não linear, há uma preocupação em aplicações em tempo real, devido ao tempo do processamento, pois geralmente o algoritmo de otimização é mais exigente computacionalmente que no caso do CPBM linear. Porém, o *hardware* de processamento utilizado foi capaz de responder com rapidez suficiente em todos os experimentos realizados neste trabalho. Neste trabalho, o *hardware* utilizado foi o computador de placa única BeagleBone Black. Uma análise de sensibilidade mostrou que o tempo de cálculo aumenta aproximadamente de forma exponencial em função do tamanho do horizonte de predição (número amostras futuras). Além disso, os resultados desta análise mostraram que se o horizonte de predição for muito curto (poucas amostras), o desempenho do controle fica comprometido, apesar do ganho no tempo de processamento.

Os resultados experimentais ainda mostraram que o SGE proposto foi capaz de gerenciar efetivamente a energia no sistema de propulsão, usando a CaC real para garantir a sustentação de carga da bateria emulada. A análise de sensibilidade do coeficiente de penalização da variável de controle (corrente da CaC) mostrou que este parâmetro tem pouca influência sobre o EdC da bateria, contudo, influencia principalmente o tempo de resposta da CaC. Os experimentos também demonstraram que o CPBM não linear tem a capacidade de rastrear e operar no ponto de eficiência máxima da CaC, sempre que possível caso não sejam violadas as demais restrições e também sejam atendidos os outros objetivos de controle. Este recurso permite reduzir o coeficiente de penalização da corrente e ainda assim garantir uma operação mais eficiente da CaC. Penalizar demais a corrente pode ser problemático dependendo da capacidade da bateria do veículo, pois a CaC não poderia responder a tempo no caso de uma descarga abrupta da bateria (demanda de energia elevada e repentina).

Por fim, o estudo comparativo entre o controle preditivo neural (CPN) proposto, o controle preditivo generalizado (CPG) e o controle por banda de histerese (CBH) demonstrou que o CPN foi capaz de reduzir o consumo de hidrogênio do VEHCC e reduzir o coeficiente de degradação da CaC. Ao analisar o consumo total de hidrogênio, o CPN apresentou uma ligeira redução em comparação com o CPG e o CBH. Mas ao considerar a eficiência de conversão de energia durante todo o experimento, mostrou-se que com o CPN a CaC pôde gerar mais energia elétrica, mesmo com consumo de hidrogênio similar ao outros dois controladores. Tal resultado sugere que, com o CPN, pode-se usar uma bateria de menor capacidade, o que contribui na diminuição do peso do veículo e, portanto, na eficiência global. Além disso, em comparação com o CBH, o CPN e o CPG reduziram significativamente a degradação da CaC, devido principalmente à sua capacidade de reduzir o número de ciclos de partida e parada, através de imposição de uma restrição de corrente mínima. A

redução da degradação é fundamental para maximizar a vida útil da CaC em uma aplicação veicular real.

## 5.2 Trabalhos Futuros

Para dar continuidade ao trabalho apresentado nesta tese, os seguintes tópicos são sugeridos como trabalhos futuros:

- Estudo de estabilidade do CPBM não linear proposto;
- Estudo e validação do CPBM não linear proposto com um modelo dinâmico completo do VEHCC, e não apenas o modelo quase-estático;
- Adaptação da metodologia e controle preditivo neural proposto neste trabalho para uma aplicação estacionária, como em CaC's para microrredes com armazenamento de energia usando não apenas baterias, mas hidrogênio e fontes renováveis variáveis;
- Maximizar a energia recuperada durante a frenagem regenerativa em sistemas de propulsão de VEHCC's que dispõem de um resistor de frenagem;
- Estudo do uso do modelo neural para predição de alagamento dos eletrodos da CaC e inclusão de objetivos no CPBM não linear proposto para prevenir a ocorrência deste fenômeno.

# Referências Bibliográficas

- [1] EUROPEAN PARLIAMENT. “CO2 emissions from cars: facts and figures (infographics)”. 2016. Disponível em: <<http://www.europarl.europa.eu/news/en/headlines/society/20190313ST031218/co2-emissions-from-cars-facts-and-figures-infographics>>. Acesso em: 04 out. 2019.
- [2] EMPRESA DE PESQUISA ENERGÉTICA. *Balanço Energético Nacional 2018 - Relatório Síntese*. Relatório técnico, 2018.
- [3] EMPRESA DE PESQUISA ENERGÉTICA. *Balanço Energético Nacional 2018*. Relatório técnico, 2018.
- [4] DA CUNHA, B. S. L. “Análise da Influência do Óleo Diesel e da Gasolina Automotiva Sobre a Inflação Nacional”. 2015.
- [5] SCHAFER, A., VICTOR, D. G. “The future mobility of the world population”, *Transportation Research Part A: Policy and Practice*, v. 34, n. 3, pp. 171–205, abr. 2000.
- [6] INTERNATIONAL ENERGY AGENCY. *World Energy Outlook 2013*. Relatório técnico, 2013.
- [7] DEPARTAMENTO NACIONAL DE TRÂNSITO. “Estatísticas - Frota de Veículos - DENATRAN”. 2019. Disponível em: <<https://infraestrutura.gov.br/component/content/article/115-portal-denatran/8552-estat%C3%ADsticas-frota-de-ve%C3%ADculos-denatran.html>>. Acesso em: 15 out. 2019.
- [8] GUZZELLA, L., SCIARRETTA, A. *Vehicle Propulsion Systems, Introduction to Modeling and Optimization*. 3 ed. , Springer, 2013.
- [9] BORBA, B. S. M. C. *Modelagem Integrada da Introdução de Veículos Leves Conectáveis à Rede Elétrica no Sistema Energético Brasileiro*. Tese de doutorado, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil, 2012.

- [10] POD POINT. “Hyundai KONA Electric 64 kWh (2018) Charging Guide | Pod Point”. 2018. Disponível em: <<https://pod-point.com/guides/vehicles/hyundai/2018/kona-64-kwh>>. Acesso em: 10 out. 2019.
- [11] HYUNDAI. “Hyundai KONA Electric”. . Disponível em: <<https://www.hyundaiusa.com/kona-electric/index.aspx>>. Acesso em: 14 out. 2019.
- [12] LHOMME, W. *Gestion d’énergie de véhicules électriques hybrides basée sur la représentation énergétique macroscopique*. Tese de doutorado, Université Lille 1 - Sciences et Technologies, Lille, França, 2007.
- [13] POD POINT. “Toyota Prius PHEV (2017) Charging Guide | Pod Point”. 2017. Disponível em: <<https://pod-point.com/guides/vehicles/toyota/2017/prius-phev>>. Acesso em: 21 nov. 2019.
- [14] NEHRIR, M. H., WANG, C. *Modeling and Control of Fuel Cells: Distributed Generation Applications*. 1 ed. Hoboken, NJ, EUA, John Wiley & Sons, 2009.
- [15] SCHULZ, D., JAHN, M., PFEIFER, T. “Grid Integration of Photovoltaics and Fuel Cells”. In: Strzelecki, R. M., Benysek, G. (Eds.), *Power Electronics in Smart Electrical Energy Networks*, 1 ed., cap. 12, Londres, Springer, 2008.
- [16] HYUNDAI. “Hyundai Nexo Fuel Cell SUV”. . Disponível em: <<https://www.hyundaiusa.com/nexo/index.aspx>>. Acesso em: 14 out. 2019.
- [17] PARRA, D., VALVERDE, L., PINO, F. J., et al. “A review on the role, cost and value of hydrogen energy systems for deep decarbonisation”, *Renewable and Sustainable Energy Reviews*, v. 101, pp. 279–294, mar. 2019.
- [18] ABE, J. O., POPOOLA, A. P. I., AJENIFUJA, E., et al. “Hydrogen energy, economy and storage: review and recommendation”, *International Journal of Hydrogen Energy*, v. 44, n. 29, pp. 15072–15086, jun. 2019.
- [19] COLBERTALDO, P., AGUSTIN, S. B., CAMPANARI, S., et al. “Impact of hydrogen energy storage on California electric power system: Towards 100% renewable electricity”, *International Journal of Hydrogen Energy*, v. 44, n. 19, pp. 9558–9576, abr. 2019.
- [20] NADALETI, W. C., DOS SANTOS, G. B., LOURENÇO, V. A. “The potential and economic viability of hydrogen production from the use of

- hydroelectric and windfarms surplus energy in Brazil: A national and pioneering analysis”, *International Journal of Hydrogen Energy*, v. 45, n. 3, pp. 1373–1384, jan. 2020.
- [21] FARROKHABADI, M., SOLANKI, B. V., CANIZARES, C. A., et al. “Energy Storage in Microgrids: Compensating for Generation and Demand Fluctuations While Providing Ancillary Services”, *IEEE Power and Energy Magazine*, v. 15, n. 5, pp. 81–91, ago. 2017.
- [22] EHRET, O., BONHOFF, K. “Hydrogen as a fuel and energy storage: Success factors for the German Energiewende”, *International Journal of Hydrogen Energy*, v. 40, n. 15, pp. 5526–5533, abr. 2015.
- [23] FEDERAL MINISTRY OF ECONOMICS AND TECHNOLOGY; FEDERAL MINISTRY FOR THE ENVIRONMENT, NATURE CONSERVATION AND NUCLEAR SAFETY. *Energy Concept for an Environmentally Sound, Reliable and Affordable Energy Supply*. Relatório técnico, Berlin, Alemanha, 2010.
- [24] DEUTSCHE GESELLSCHAFT FÜR INTERNATIONALE ZUSAMMENARBEIT (GIZ) GMBH. “Deutschlands Energiewende - A Transição Energética Alemã”. Disponível em: <<http://www.energiewende-global.com/pt/?topic=mobilitaet>>. Acesso em: 25 nov. 2019.
- [25] “California Air Resources Board Zero Emission Vehicle (ZEV) Program”. 2017. Disponível em: <<https://www.arb.ca.gov/msprog/zevprog/zevprog.htm>>. Acesso em: 17 abr. 2018.
- [26] SCHOENUNG, S. M., KELLER, J. O. “Commercial potential for renewable hydrogen in California”, *International Journal of Hydrogen Energy*, v. 42, n. 19, pp. 13321–13328, maio 2017.
- [27] CALIFORNIA FUEL CELL PARTNERSHIP. “Stations Map”. Disponível em: <<https://cafcp.org/stationmap>>. Acesso em: 16 jun. 2020.
- [28] LANE, B., SHAFFER, B., SAMUELSEN, G. S. “Plug-in fuel cell electric vehicles: A Californiacase study”, *International Journal of Hydrogen Energy*, v. 42, n. 20, pp. 14294–14300, maio 2017.
- [29] LARMINIE, J., DICKS, A. *Fuel Cells Systems Explained*. 2 ed. Chichester, Inglaterra, John Wiley & Sons, 2003.

- [30] MARX, N., BOULON, L., GUSTIN, F., et al. “A review of multi-stack and modular fuel cell systems: Interests, application areas and on-going research activities”, *International Journal of Hydrogen Energy*, v. 39, n. 23, pp. 12101–12111, Aug 2014.
- [31] INAL, O. B., DENIZ, C. “Assessment of fuel cell types for ships: Based on multi-criteria decision analysis”, *Journal of Cleaner Production*, v. 265, pp. xx, abr. 2020.
- [32] DE TROYA, J. J., ÁLVAREZ, C., FERNÁNDEZ-GARRIDO, C., et al. “Analysing the possibilities of using fuel cells in ships”, *International Journal of Hydrogen Energy*, v. 41, n. 4, pp. 2853–2866, jan. 2016.
- [33] BANHAM, D., KISHIMOTO, T., ZHOU, Y., et al. “Critical advancements in achieving high power and stable nonprecious metal catalyst-based MEAs for real-world proton exchange membrane fuel cell applications”, *Science Advances*, v. 4, n. 3, pp. 1–7, mar. 2018.
- [34] U.S. DEPARTMENT OF ENERGY. “Comparison of Fuel Cell Technologies”. Disponível em: <[https://www.energy.gov/sites/prod/files/2016/06/f32/fcto\\_fuel\\_cells\\_comparison\\_chart\\_apr2016.pdf](https://www.energy.gov/sites/prod/files/2016/06/f32/fcto_fuel_cells_comparison_chart_apr2016.pdf)>. Acesso em: 16 jun. 2019.
- [35] RAVEY, A., BLUNIER, B., MIRAOU, A. “Control Strategies for Fuel-Cell-Based Hybrid Electric Vehicles: From Offline to Online and Experimental Results”, *IEEE Transactions on Vehicular Technology*, v. 61, n. 6, pp. 2452–2457, jul. 2012.
- [36] PUKRUSHPAN, J. T., STEFANOPOULOU, A. G., PENG, H. *Control of Fuel Cell Power Systems: Principles, Modeling, Analysis and Feedback Design*. 1 ed. Londres, Inglaterra, Springer-Verlag London, 2004.
- [37] CHEN, J., B.SIEGEL, J., STEFANOPOULOU, A. G., et al. “Optimization of purge cycle for dead-ended anode fuel cell operation”, *International Journal of Hydrogen Energy*, v. 38, n. 12, pp. 5092–5105, abr. 2013.
- [38] OU, K., WANG, Y.-X., KIM, Y.-B. “Performance Optimization for Open-cathode Fuel Cell Systems with Overheating Protection and Air Starvation Prevention”, *Fuel Cells*, v. 17, n. 3, pp. 299–307, jun. 2017.
- [39] ARCE, A., DEL REAL, A. J., BORDONS, C., et al. “Real-Time Implementation of a Constrained MPC for Efficient Airflow Control in a PEM Fuel Cell”, *IEEE Transactions on Industrial Electronics*, v. 57, n. 6, pp. 1892–1905, jun. 2010.

- [40] CHEN, J., LIU, Z., WANG, F., et al. “Optimal Oxygen Excess Ratio Control for PEM Fuel Cells”, *IEEE Transactions on Control Systems Technology*, v. 26, n. 5, pp. 1711–1721, set. 2018.
- [41] LIU, J., GAO, Y., SU, X., et al. “Disturbance-Observer-Based Control for Air Management of PEM Fuel Cell Systems via Sliding Mode Technique”, *IEEE Transactions on Control Systems Technology*, v. 27, n. 3, pp. 1129–1138, maio 2019.
- [42] KIM, B. M., CHOI, Y. H., YOO, S. J. “Adaptive Control of Proton Exchange Membrane Fuel Cell Air Supply Systems With Asymmetric Oxygen Excess Ratio Constraints”, *IEEE Access*, v. 8, pp. 5537–5549, 2020.
- [43] VAHIDI, A., STEFANOPOULOU, A., PENG, H. “Current Management in a Hybrid Fuel Cell PowerSystem: A Model-Predictive Control Approach”, *IEEE Transactions on Control Systems Technology*, v. 14, n. 6, pp. 1047–1057, nov. 2006.
- [44] SUN, J., KOLMANOVSKY, I. V. “Load Governor for Fuel Cell Oxygen Starvation Protection: A Robust Nonlinear Reference Governor Approach”, *IEEE Transactions on Control Systems Technology*, v. 13, n. 6, pp. 911–920, nov. 2005.
- [45] KROMER, M. A., HEYWOOD, J. B. *Electric Powertrains: Opportunities and Challenges in the U.S. Light-Duty Vehicle Fleet*. Sloan Automotive Laboratory, Massachusetts Institute of Technology LFEE 2007-03 RP, 2007.
- [46] CARIGNANO, M., RODA, V., COSTA-CASTELLÓ, R., et al. “Assessment of Energy Management in a Fuel Cell/Battery Hybrid Vehicle”, *IEEE Access*, v. 7, pp. 16110–16122, 2019.
- [47] ZHOU, D., GAO, F., RAVEY, A., et al. “Online energy management strategy of fuel cell hybrid electric vehicles based on time series prediction”. In: *2017 IEEE Transportation Electrification Conference and Expo (ITEC)*, pp. 113–118, Chicago, IL, EUA, jun. 2017.
- [48] VALVERDE, L., ROSA, F., BORDONS, C., et al. “Energy Management Strategies in hydrogen Smart-Grids: A laboratory experience”, *International Journal of Hydrogen Energy*, v. 41, n. 31, pp. 13715–13725, ago. 2016.
- [49] ETTIHIR, K., CANO, M. H., BOULON, L., et al. “Design of an adaptive EMS for fuel cell vehicles”, *International Journal of Hydrogen Energy*, v. 42, n. 2, pp. 1481–1489, jan. 2017.

- [50] SULAIMAN, N., HANNAN, M., MOHAMED, A., et al. “A review on energy management system for fuel cell hybrid electric vehicle: Issues and challenges”, *Renewable and Sustainable Energy Reviews*, v. 52, pp. 802–814, dez. 2015.
- [51] ETTIHIR, K., BOULON, L., AGBOSSOU, K. “Energy management strategy for a fuel cell hybrid vehicle based on maximum efficiency and maximum power identification”, *IET Electrical Systems in Transportation*, v. 6, n. 4, pp. 261–268, dez. 2016.
- [52] PEREIRA, D. F., DA COSTA LOPES, F., WATANABE, E. H. “Neural Generalized Predictive Control for Tracking Maximum Efficiency and Maximum Power Points of PEM Fuel Cell Stacks”. In: *IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society*, pp. 1878–1883, Washington, DC, EUA.
- [53] ZHOU, D., AL-DURRA, A., MATRAJI, I., et al. “Online energy management strategy of fuel Cell hybrid electric vehicles: a fractional-order extremum seeking method”, *IEEE Transactions on Industrial Electronics*, v. 65, n. 8, pp. 6787–6799, ago. 2018.
- [54]
- [55] ZAKRISSON, E. *The Effect of Start/Stop Strategy on PEM Fuel Cell Degradation Characteristics*. Tese de Mestrado, Chalmers University of Technology, Gothenburg, Sweden, 2011.
- [56] BORDONS, C., RIDAO, M. A., PÉREZ, A., et al. “Model Predictive Control for power management in hybrid fuel cell vehicles”. In: *2010 IEEE Vehicle Power and Propulsion Conference*, pp. 1–6, Lille, France.
- [57] AMIN, BAMBANG, R. T., ROHMAN, A. S., et al. “Energy Management of Fuel Cell/Battery/Supercapacitor Hybrid Power Sources Using Model Predictive Control”, *IEEE Transactions on Industrial Informatics*, v. 10, n. 4, pp. 1992–2002, nov. 2014.
- [58] TORREGLOSA, J. P., GARCÍA, P., FERNÁNDEZ, L. M., et al. “Predictive Control for the Energy Management of a Fuel-Cell-Battery-Supercapacitor Tramway”, *IEEE Transactions on Industrial Informatics*, v. 10, n. 1, pp. 276–285, fev. 2014.
- [59] VALVERDE, L., BORDONS, C., ROSA, F. “Integration of Fuel Cell Technologies in Renewable-Energy-Based Microgrids Optimizing Operational

- Costs and Durability”, *IEEE Transactions on Industrial Electronics*, v. 63, n. 1, pp. 167–177, Jan 2016.
- [60] HE, H., QUAN, S., SUN, F., et al. “Model Predictive Control with Lifetime Constraints Based Energy Management Strategy for Proton Exchange Membrane Fuel Cell Hybrid Power Systems”, *IEEE Transactions on Industrial Electronics*, pp. 1–1, mar. 2020.
- [61] PEREIRA, D. F., LOPES, F. D. C., WATANABE, E. H. “Nonlinear Model Predictive Control for the Energy Management of Fuel Cell Hybrid Electric Vehicles in Real-Time”, *IEEE Transactions on Industrial Electronics*, pp. 1–1, mar. 2020.
- [62] CHEN, H., CHEN, J., LU, H., et al. “A Modified MPC-based Optimal Strategy of Power Management for Fuel Cell Hybrid Vehicles”, *IEEE/ASME Transactions on Mechatronics*, pp. 1–1, maio 2020.
- [63] HU, X., ZOU, C., TANG, X., et al. “Cost-Optimal Energy Management of Hybrid Electric Vehicles Using Fuel Cell/Battery Health-Aware Predictive Control”, *IEEE Transactions on Power Electronics*, v. 35, n. 1, pp. 382–392, jan. 2020.
- [64] VALVERDE, L., ROSA, F., DEL REAL, A. J., et al. “Modeling, simulation and experimental set-up of a renewable hydrogen-based domestic microgrid”, *International Journal of Hydrogen Energy*, v. 38, n. 27, pp. 11672–11684, set. 2013.
- [65] LUNA, J., USAI, E., HUSAR, A., et al. “Enhancing the Efficiency and Lifetime of a Proton Exchange Membrane Fuel Cell Using Nonlinear Model-Predictive Control With Nonlinear Observation”, *IEEE Transactions on Industrial Electronics*, v. 64, n. 8, pp. 6649–6659, ago. 2017.
- [66] AMPHLETT, J. C., BAUMERT, R. M., MANN, R. F., et al. “Performance Modeling of the Ballard Mark IV Solid Polymer Electrolyte Fuel Cell I. Mechanistic Model Development”, *Journal of The Electrochemical Society*, v. 142, n. 1, pp. 1–8, Jan 1995.
- [67] LEE, J. H., LALK, T. R., APPLEBY, A. J. “Modeling electrochemical performance in large scale proton exchange membrane fuel cell stacks”, *Journal of Power Sources*, v. 70, n. 2, pp. 258–268, Feb 1998.
- [68] ZHOU, D., NGUYEN, T. T., BREAZ, E., et al. “Global parameters sensitivity analysis and development of a two-dimensional real-time model of

- proton-exchange-membrane fuel cells”, *Energy Conversion and Management*, v. 162, n. 15, pp. 276–292, Apr 2018.
- [69] DA COSTA LOPES, F. *Modelagem de empilhamentos de células a combustível PEM por redes neurais*. Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2013.
- [70] JI, M., WEI, Z. “A Review of Water Management in Polymer Electrolyte Membrane Fuel Cells”, *Energies*, v. 2, n. 4, pp. 1057–1106, nov. 2009.
- [71] STEINER, N. Y., HISSEL, D., MOÇOTÉGUY, P., et al. “Diagnosis of polymer electrolyte fuel cells failure modes (flooding & drying out) by neural networks modeling”, *International Journal of Hydrogen Energy*, v. 36, n. 4, pp. 3067–3075, fev. 2011.
- [72] DA COSTA LOPES, F., WATANABE, E. H., ROLIM, L. G. B. “A Control-Oriented Model of a PEM Fuel Cell Stack Based on NARX and NOE Neural Networks”, *IEEE Transactions on Industrial Electronics*, v. 62, n. 8, pp. 5155–5163, ago. 2015.
- [73] NØRGAARD, M., RAVN, O., POULSEN, N. K., et al. *Neural Networks for Modelling and Control of Dynamic Systems: a practitioner’s handbook*. 1 ed. Great Britain, Springer-Verlag London, 2000.
- [74] CAMACHO, E. F., BORDONS, C. *Model Predictive Control*. 2 ed. Londres, Inglaterra, Springer-Verlag London, 2007.
- [75] VELARDE, P., VALVERDE, L., MAESTREA, J. M., et al. “On the comparison of stochastic model predictive control strategies applied to a hydrogen-based microgrid”, *Journal of Power Sources*, v. 343, pp. 161–173, mar. 2017.
- [76] GARCIA-TORRES, F., BORDONS, C. “Optimal Economical Schedule of Hydrogen-Based Microgrids With Hybrid Storage Using Model Predictive Control”, *IEEE Transactions on Industrial Electronics*, v. 62, n. 8, pp. 5195–5207, mar. 2017.
- [77] FROBERG, A., NIELSEN, L. “Efficient Drive Cycle Simulation”, *IEEE Transactions on Vehicular Technology*, v. 57, n. 3, pp. 1442–1453, maio 2008.
- [78] WIPKE, K. B., CUDDY, M. R., BURCH, S. D. “ADVISOR 2.1: A User-Friendly Advanced Powertrain Simulation Using a Combined Backward/-Forward Approach”, *IEEE Transactions on Vehicular Technology*, v. 48, n. 6, pp. 1751–1761, nov. 1999.

- [79] GUZZELLA, L., AMSTUTZ, A. “CAE Tools for Quasi-Static Modeling and Optimization of Hybrid Powertrains”, *IEEE Transactions on Vehicular Technology*, v. 48, n. 6, pp. 1762–1769, nov. 1999.
- [80] MATHWORKS. “Simulink - Simulation and Model-Based Design - Matlab & Simulink”. Disponível em: <<https://www.mathworks.com/products/simulink.html>>. Acesso em: 17 dez. 2019.
- [81] UNITED NATIONS ECONOMIC COMMISSION FOR EUROPE. “Addendum 100: Regulation No. 101”. 2013. Disponível em: <<http://www.unece.org/trans/main/wp29/wp29regs101-120.html>>. Acesso em: 16 dez. 2019.
- [82] UNITED STATES ENVIRONMENTAL PROTECTION AGENCY. “Dynamometer Drive Schedules | Vehicle and Fuel Emissions Testing”. 2019. Disponível em: <<https://www.epa.gov/vehicle-and-fuel-emissions-testing/dynamometer-drive-schedules>>. Acesso em: 01 nov. 2019.
- [83] GUZZELLA, L., AMSTUTZ, A. *The QSS Toolbox Manual*. Swiss Federal Institute of Technology Zurich, Zurique, Suíça, jun. 2005.
- [84] LETROUVÉ, T., BOUSCAYROL, A., LHOMME, W., et al. “Different models of a traction drive for an electric vehicle simulation”. In: *2010 IEEE Vehicle Power and Propulsion Conference*, pp. 1–6, Lille, França.
- [85] DUPONT, F. H., BERTOMEU, J. Z., RECH, C., et al. “Mathematical efficiency modeling of static power converters”. In: *2015 Brazilian Power Electronics Conference*, pp. 1–6, Fortaleza, Brasil.
- [86] JANTSCH, M., SCHMIDT, H., SCHMID, J. “Results of the concerted action on power conditioning and control”. In: *11th European Photovoltaic Solar Energy Conference*, p. 1589–1593, Montreux, Suíça.
- [87] RAMPINELLI, G. A. *Estudo de Características Elétricas e Térmicas de Inversores para Sistemas Fotovoltaicos Conectados à Rede*. Tese de D.Sc., Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, Brasil, 2010.
- [88] TREMBLAY, O., DESSAINT, L., DEKKICHE, A. “A Generic Battery Model for the Dynamic Simulation of Hybrid Electric Vehicles”. In: *2007 IEEE Vehicle Power and Propulsion Conference*, pp. 284–289, Arlington, TX, EUA, 2007.

- [89] DA COSTA LOPES, F., WATANABE, E. H., ROLIM, L. G. B. “Analysis of the time-varying behavior of a PEM fuel cell stack and dynamical modeling by recurrent neural networks”. In: *2013 Brazilian Power Electronics Conference*, pp. 601–608, Gramado, RS, 2013.
- [90] PEREIRA, D. F., LOPES, F. C., WATANABE, E. H. “Prediction of PEMFC Stack Efficiency Using Recurrent Neural Networks”. In: *2017 IEEE 26th International Symposium on Industrial Electronics (ISIE)*, pp. 1017–1022, Edimburgo, Escócia, 2017.
- [91] CUTLER, C. R., RAMAKER, B. L. “Dynamic matrix control - a computer control algorithm”. In: *A.I.C.H.E. 86th National Meeting*, Houston, TX, EUA, abr. 1979.
- [92] RICHalet, J., RAULT, A., TESTUD, J. L., et al. “Model predictive heuristic control: Applications to industrial processes”, *Automatica*, v. 14, n. 5, pp. 413–428, set. 1978.
- [93] CLARKE, D. W., MOHTADI, C., TUFFS, P. S. “Generalized predictive control—Part I The basic algorithm”, *Automatica*, v. 23, n. 2, pp. 137–148, mar. 1987.
- [94] CLARKE, D. W., MOHTADI, C., TUFFS, P. S. “Generalized predictive control—Part II Extensions and interpretations”, *Automatica*, v. 23, n. 2, pp. 149–160, mar. 1987.
- [95] DOS SANTOS, J. E. S. *Controle preditivo não-linear para sistemas de Hammerstein*. Tese de D.Sc., Universidade Federal de Santa Catarina, Florianópolis, SC, Brasil, 2007.
- [96] GRÜNE, L., PANNEK, J. *Nonlinear Model Predictive Control*. 1 ed. London, England, Springer-Verlag London, 2011.
- [97] NOCEDAL, J., WRIGHT, S. J. *Numerical Optimization*. 2 ed. Nova York, EUA, Springer-Verlag New York, 2006.
- [98] ALLGÖWER, F., BADGWELL, T. A., QIN, J. S., et al. “Nonlinear Predictive Control and Moving Horizon Estimation — An Introductory Overview”. In: *Advances in Control*, pp. 391–449, Londres, 1999.
- [99] CHEN, H., ALLGOWER, F. “A Quasi-Infinite Horizon Nonlinear Model Predictive Control Scheme with Guaranteed Stability”, *Automatica*, v. 34, n. 10, pp. 1205–1217, October 1998.

- [100] FINDEISEN, R., ALLGOWER, F. “An Introduction to Nonlinear Model Predictive Control”. In: *21st Benelux Meeting on Systems and Control*, pp. 1–23, Veldhoven, Holanda, jan. 2002.
- [101] MATHWORKS. “Sample partial autocorrelation - MATLAB parcorr”. 2020. Disponível em: <<https://www.mathworks.com/help/econ/parcorr.html>>. Acesso em: 17 mar. 2020.
- [102] CALÔBA, L. P. “Introdução ao Uso de Redes Neurais na Modelagem de Sistemas Dinâmicos e Séries Temporais”. In: *Livro de Minicursos do XIV Congresso Brasileiro de Automática*, pp. 1–52, Natal, RN, 2002.
- [103] BEALE, M. H., HAGAN, M. T., DEMUTH, H. B. *Neural Network Toolbox™ User’s Guide*. Natick, MA, USA, Mathworks, September 2016.
- [104] SOLOWAY, D., HALEY, P. J. “Neural generalized predictive control”. In: *Proceedings of the 1996 IEEE International Symposium on Intelligent Control*, pp. 277–282, Dearborn, MI, EUA, 1996.
- [105] ETTIHIR, K., BOULON, L., AGBOSSOU, K., et al. “Design of an energy management strategy for PEM Fuel Cell Vehicles”. In: *2012 IEEE International Symposium on Industrial Electronics*, pp. 1714–1719, Hangzhou, China, maio 2012.
- [106] HERRERA VEGA, D., MARX, N., BOULON, L., et al. “Maximum efficiency point tracking for hydrogen fuel cells”. In: *2014 IEEE 27th Canadian Conference on Electrical and Computer Engineering (CCECE)*, pp. 1–6, Toronto, ON, Canada, 2014.
- [107] DEPATURE, C., JEMEI, S., BOULON, L., et al. “IEEE VTS Motor Vehicles Challenge 2017 - Energy Management of a Fuel Cell/Battery Vehicle”. In: *2016 IEEE Vehicle Power and Propulsion Conference (VPPC)*, pp. 1–6, Hangzhou, China, 2016.

# Apêndice A

## Linearização do Modelo de Predição

Dado um sistema discreto não linear descrito por:

$$\mathbf{x}(k+1) = \mathbf{f}(\mathbf{x}(k), \mathbf{u}(k)), \quad (\text{A.1})$$

onde  $\mathbf{x}(k) \in \mathbb{R}^n$  é o vetor de estados,  $\mathbf{u}(k) \in \mathbb{R}^m$  é o vetor de entrada e  $\mathbf{f}(x, u) \in \mathbb{R}^n$  um vetor de funções não lineares que descreve a dinâmica do sistema. Ao serem consideradas pequenas variações em torno de um ponto equilíbrio do sistema  $(\mathbf{x}_*, \mathbf{u}_*)$ , o sistema (A.1) pode ser aproximado pelo sistema linear

$$\Delta \mathbf{x}(k+1) = A \Delta \mathbf{x}(k) + B \Delta \mathbf{u}(k), \quad (\text{A.2})$$

que tem como vetor de estados  $\Delta \mathbf{x}(k)$ , que representa as variações de  $\mathbf{x}$  em torno do ponto de equilíbrio  $\mathbf{x}_*$ , tem como entrada o vetor  $\Delta \mathbf{u}(k)$  que representa as variações de  $\mathbf{u}$  em torno do ponto de equilíbrio  $\mathbf{u}_*$  e cujas matrizes  $A$  e  $B$  são dadas pelos jacobianos:

$$A = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_2} & \cdots & \frac{\partial f_1}{\partial x_n} \\ \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} & \cdots & \frac{\partial f_2}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_n}{\partial x_1} & \frac{\partial f_n}{\partial x_2} & \cdots & \frac{\partial f_n}{\partial x_n} \end{bmatrix}_{(x_*, u_*)}, \quad (\text{A.3})$$

$$B = \begin{bmatrix} \frac{\partial f_1}{\partial u_1} & \frac{\partial f_1}{\partial u_2} & \cdots & \frac{\partial f_1}{\partial u_n} \\ \frac{\partial f_2}{\partial u_1} & \frac{\partial f_2}{\partial u_2} & \cdots & \frac{\partial f_2}{\partial u_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_n}{\partial u_1} & \frac{\partial f_n}{\partial u_2} & \cdots & \frac{\partial f_n}{\partial u_n} \end{bmatrix}_{(x_*, u_*)}. \quad (\text{A.4})$$

O modelo de predição do NMPC proposto neste trabalho é dado pelo sistema

não linear no espaço de estados:

$$\begin{cases} x_1(k+1) = x_1(k) + h \frac{\eta_b}{Q_{BT}v_{BT}} g(x(k), u(k)) u(k) \\ x_2(k+1) = g(x(k), u(k)) \\ x_3(k+1) = x_2(k) \\ x_4(k+1) = u(k) \\ x_5(k+1) = x_4(k) \end{cases}, \quad (\text{A.5})$$

onde a função  $g$  consiste na rede neural, para o cálculo das predições da tensão da CaC, e cujo vetor de estados é definido por:

$$x(k) = \begin{bmatrix} \xi_{BT}(k) & v_{FC}(k-1) & v_{FC}(k-2) & i_{FC}(k-1) & i_{FC}(k-2) \end{bmatrix}^T. \quad (\text{A.6})$$

A equação que descreve matematicamente a rede neural que faz as predições da tensão da CaC é dada por:

$$g(x, u) = \hat{v}_{FC}(k) = \sum_{i=1}^{n_h} W_i \tanh \left[ \sum_{j=1}^{n_\varphi} w_{ij} \varphi_j(k) + w_{i0} \right] + W_0, \quad (\text{A.7})$$

e os cálculos das derivadas parciais, detalhado a seguir, para a obtenção das matrizes  $A$  e  $B$  foi feito considerando uma rede neural com dois atrasos na entrada e na saída ( $M = N = 2$ , e portanto  $n_\varphi = 1 + M + N = 5$ ). Dessa forma, o vetor  $\varphi_j(k)$  com as variáveis de entrada da rede neural é definido como:

$$\begin{aligned} \varphi(k) &= \begin{bmatrix} i_{FC}(k) & i_{FC}(k-1) & i_{FC}(k-2) & v_{FC}(k-1) & v_{FC}(k-2) \end{bmatrix}^T, \\ &= \begin{bmatrix} u(k) & x_4(k) & x_5(k) & x_2(k) & x_3(k) \end{bmatrix}^T. \end{aligned} \quad (\text{A.8})$$

O cálculo de cada uma das derivadas parciais que compõem os elementos das matrizes  $A$  e  $B$  é apresentado a seguir:

$$\frac{\partial f_1}{\partial x_1} = \frac{\partial \xi_{BT}(k+1)}{\partial \xi_{BT}(k)} = 1, \quad (\text{A.9})$$

$$\frac{\partial f_1}{\partial x_2} = \frac{\partial \xi_{BT}(k+1)}{\partial v_{FC}(k-1)} = h \frac{\eta_b}{Q_{BT}v_{BT}} u(k) \frac{\partial \hat{v}_{FC}(k)}{\partial v_{FC}(k-1)}, \quad (\text{A.10})$$

$$\frac{\partial f_1}{\partial x_3} = \frac{\partial \xi_{BT}(k+1)}{\partial v_{FC}(k-2)} = h \frac{\eta_b}{Q_{BT}v_{BT}} u(k) \frac{\partial \hat{v}_{FC}(k)}{\partial v_{FC}(k-2)}, \quad (\text{A.11})$$

$$\frac{\partial f_1}{\partial x_4} = \frac{\partial \xi_{BT}(k+1)}{\partial i_{FC}(k-1)} = h \frac{\eta_b}{Q_{BT}v_{BT}} u(k) \frac{\partial \hat{v}_{FC}(k)}{\partial i_{FC}(k-1)}, \quad (\text{A.12})$$

$$\frac{\partial f_1}{\partial x_5} = \frac{\partial \xi_{BT}(k+1)}{\partial i_{FC}(k-1)} = h \frac{\eta_b}{Q_{BT} v_{BT}} u(k) \frac{\partial \hat{v}_{FC}(k)}{\partial i_{FC}(k-2)}, \quad (\text{A.13})$$

$$\frac{\partial f_2}{\partial x_1} = \frac{\partial v_{FC}(k-1)}{\partial \xi_{BT}(k)} = 0, \quad (\text{A.14})$$

$$\frac{\partial f_2}{\partial x_2} = \frac{\partial \hat{v}_{FC}(k)}{\partial v_{FC}(k-1)} = \sum_{i=1}^{n_h} W_i \operatorname{sech}^2 \left[ \sum_{j=1}^{n_\varphi} w_{ij} \varphi_j(k) + w_{i0} \right] w_{i4}, \quad (\text{A.15})$$

$$\frac{\partial f_2}{\partial x_3} = \frac{\partial \hat{v}_{FC}(k)}{\partial v_{FC}(k-2)} = \sum_{i=1}^{n_h} W_i \operatorname{sech}^2 \left[ \sum_{j=1}^{n_\varphi} w_{ij} \varphi_j(k) + w_{i0} \right] w_{i5}, \quad (\text{A.16})$$

$$\frac{\partial f_2}{\partial x_4} = \frac{\partial \hat{v}_{FC}(k)}{\partial i_{FC}(k-1)} = \sum_{i=1}^{n_h} W_i \operatorname{sech}^2 \left[ \sum_{j=1}^{n_\varphi} w_{ij} \varphi_j(k) + w_{i0} \right] w_{i2}, \quad (\text{A.17})$$

$$\frac{\partial f_2}{\partial x_5} = \frac{\partial \hat{v}_{FC}(k)}{\partial i_{FC}(k-2)} = \sum_{i=1}^{n_h} W_i \operatorname{sech}^2 \left[ \sum_{j=1}^{n_\varphi} w_{ij} \varphi_j(k) + w_{i0} \right] w_{i3}, \quad (\text{A.18})$$

$$\frac{\partial f_3}{\partial x_1} = \frac{\partial f_3}{\partial x_3} = \frac{\partial f_3}{\partial x_4} = \frac{\partial f_3}{\partial x_5} = 0, \quad (\text{A.19})$$

$$\frac{\partial f_3}{\partial x_2} = 1, \quad (\text{A.20})$$

$$\frac{\partial f_4}{\partial x_1} = \frac{\partial f_4}{\partial x_2} = \frac{\partial f_4}{\partial x_3} = \frac{\partial f_4}{\partial x_4} = \frac{\partial f_4}{\partial x_5} = 0, \quad (\text{A.21})$$

$$\frac{\partial f_5}{\partial x_1} = \frac{\partial f_5}{\partial x_2} = \frac{\partial f_5}{\partial x_3} = \frac{\partial f_5}{\partial x_5} = 0, \quad (\text{A.22})$$

$$\frac{\partial f_5}{\partial x_4} = 1, \quad (\text{A.23})$$

$$\frac{\partial f_1}{\partial u} = h \frac{\eta_b}{Q_{BT} v_{BT}} \left[ \frac{\partial \hat{v}_{FC}(k)}{\partial i_{FC}(k)} i_{FC}(k) + \hat{v}_{FC}(k) \right], \quad (\text{A.24})$$

$$\frac{\partial f_2}{\partial u} = \frac{\partial \hat{v}_{FC}(k)}{\partial i_{FC}(k)} = \sum_{i=1}^{n_h} W_i \operatorname{sech}^2 \left[ \sum_{j=1}^{n_\varphi} w_{ij} \varphi_j(k) + w_{i0} \right] w_{i1} \quad (\text{A.25})$$

$$\frac{\partial f_3}{\partial u} = 0, \quad (\text{A.26})$$

$$\frac{\partial f_4}{\partial u} = 1 \quad (\text{A.27})$$

$$\frac{\partial f_5}{\partial u} = 0. \quad (\text{A.28})$$

# Apêndice B

## Códigos Fonte do MATLAB

### B.1 Algoritmo de Treinamento da Rede NARX

```
1 %TREINAREDES Treinamento do modelo neural da tensao da CaC
2 %
3 %   Autor: Derick Furquim Pereira
4 %
5 %% parametros da rede neural
6 du=2;           % no. de atrasos na entrada
7 dy=2;           % no. de atrasos na saida
8 nNeurons=4;      % no. de neuronios na camada escondida
9 trnSetSize=.6;   % tamanho do conjunto de treinamento
10 % cria rede narx
11 rede_narx=narxnet(0:du,1:dy,nNeurons);
12 rede_narx.trainFcn='trainlm';
13 rede_narx.divideFcn='';
14 rede_narx.trainParam.mu_max=1e21;
15 rede_narx.trainParam.min_grad=1e-20;
16 rede_narx.trainParam.show=10;
17 rede_narx.trainParam.epochs=1000;
18 %% leitura dos dados
19 % perfil: CurrentProfile1
20 % data do ensaio: 21/01/2020
21 data=xlsread('20200121_CurrentProfile1_LV.xlsx');
22 tensao1=data(712:end-205,1);
23 corrente1=data(712:end-205,2);
24 tempo1=(1:1:size(corrente1,1)*.1)';
25 tempo2=linspace(min(tempo1), max(tempo1), 3000);
26 % downsample
27 tensao2=interp1(tempo1,tensao1,tempo2,'linear');
28 corrente2=interp1(tempo1,corrente1,tempo2,'linear');
29 %% seperacao dos conjuntos de treinamento e validacao
30 % conversao dos vetores em sequencia de dados
31 uSq=con2seq(corrente2);
```

```

32 ySq=con2seq(tensao2);
33 % conjuntos de dados de treinamento
34 uTrn=uSq(1:round(trnSetSize*size(corrente2,2)));
35 yTrn=ySq(1:round(trnSetSize*size(tensao2,2)));
36 % conjuntos de dados de validacao
37 uVal=uSq(round(trnSetSize*size(corrente2,2))-1:end);
38 yVal=ySq(round(trnSetSize*size(tensao2,2))-1:end);
39 %% treinamento da rede neural
40 mseTotal=zeros(10,1);
41 rmseTotal=zeros(10,1);
42 mapeTotal=zeros(10,1);
43 r2Total=zeros(10,1);
44 PesosEntrada=cell(10,1);
45 PesosCamada=cell(10,1);
46 Bias=cell(10,1);
47 for i=1:10
48     % rede narx (treinamento)
49     rede_narx=init(rede_narx); % inicializacao dos pesos
50     [XsTrn, XiTrn, AiTrn, TsTrn]=preparets(rede_narx,uTrn,{},yTrn);
51     rede_narx=train(rede_narx,XsTrn,TsTrn, XiTrn); % treinamento
52     simNarx=sim(rede_narx,XsTrn, XiTrn); % simulacao
53     % erro da rede narx
54     yNarx=cell2mat(simNarx);
55     yTrainNarx=cell2mat(TsTrn);
56     erroNarx=100*abs(yTrainNarx-yNarx)./yTrainNarx;
57     % indicadores da rede narx
58     mseNarx=mse(rede_narx,TsTrn,simNarx);
59     rmseNarx=sqrt(mseNarx);
60     mapeNarx=mean(erroNarx);
61     r2Narx=rsquare(yTrainNarx,yNarx);
62     % rede noe (validacao)
63     rede_noe=closeloop(rede_narx);
64     [XsVal, XiVal, AiVal, TsVal]=preparets(rede_noe,uVal,{},yVal);
65     simNoe=rede_noe(XsVal, XiVal, AiVal);
66     % erro da rede noe
67     yNoe=cell2mat(simNoe);
68     yValNoe=cell2mat(TsVal);
69     erroNoe=100*abs(yValNoe-yNoe)./yValNoe;
70     % indicadores da rede noe
71     mseNoe=mse(rede_noe,TsVal,simNoe);
72     rmseNoe=sqrt(mseNoe);
73     mapeNoe=mean(erroNoe);
74     r2Noe=rsquare(yValNoe,yNoe);
75     % salvar indicadores
76     mseTotal(i)=mseNoe;
77     rmseTotal(i)=rmseNoe;
78     mapeTotal(i)=mapeNoe;

```

```

79     r2Total(i)=r2Noe;
80     % plot tensao (validacao rede noe)
81     if i<6
82         figure(1)
83         subplot(5,1,i)
84         title(['i=' num2str(i) ', r2=' num2str(r2Noe)])
85     else
86         figure(2)
87         subplot(5,1,i-5)
88         title(['i=' num2str(i) ', r2=' num2str(r2Noe)])
89     end
90     plot(yValNoe,'b','LineWidth',1)
91     hold on
92     plot(yNoe,'--r','LineWidth',1)
93     % salvar pesos e bias da rede
94     PesosEntrada{i}=rede_narx.IW;
95     PesosCamada{i}=rede_narx.LW;
96     Bias{i}=rede_narx.b;
97 end

```

## B.2 Algoritmo do Sistema de Gerenciamento de Energia Preditivo Neural

```

1  %NMPCEMS
2  %
3  %   Autor: Derick Furquim Pereira
4  %
5  %   I_FC_ref=NMPCEMS(q_BT_m,V_FC_m) implementa um algoritmo de
6  %   programacao quadratica sequencial (SQP) para resolver o
7  %   problema de controle otimo de um cotrole preditivo nao linear
8  %   que faz o gerenciamento de energia de um veiculo eletrico
9  %   hibrido a celula a combustivel.
10 %
11 %   Argumentos de entrada:
12 %
13 %   q_BT_m      valor medido do estado de carga da bateria
14 %   V_FC_m      valor medido da tensao da celula a combustivel
15 %
16 %   Argumentos de saida:
17 %
18 %   I_FC_ref     corrente de referencia da celula a combustivel
19 %                calculada pelo controlador
20 %
21 function I_FC_ref=nmpcems(q_BT_m,V_FC_m)

```

```

22 %=====
23 % initialize parameters
24 %=====
25 % NMPC parameters
26 N=15;
27 T=1;
28 % fuel cell voltage and optimum control sequence measured at
29 % instant k-1
30 persistent v_old u_old
31 if isempty(v_old), v_old = 78.11246569; end
32 if isempty(u_old), u_old = zeros(1,N); end
33 % SQP parameters
34 TolOpt=1e-6;
35 MaxIt=200;
36 % SQP line search parameters
37 eta=.1;
38 tau=.9;
39 rho=.5;
40 muk=10;
41 %=====
42 % step 1: obtain new initial values
43 %=====
44 x0=[q_BT_m; V_FC_m; v_old; u_old(1); u_old(2)];
45 u0=shiftHorizon(u_old);
46 %=====
47 % step 2: solve the optimal control problem (SQP)
48 %=====
49 % starting point
50 uk=u0;
51 uk1=uk;
52 % evaluate f0, g0, c0, A0
53 xk=computeOpenloopSolution(@model,N,T,x0,uk);
54 fk=costfunction(xk,uk);
55 fk1=fk;
56 ck=nonlinearconstraints(xk,uk);
57 ck1=ck;
58 gk=zeros(length(uk),1);
59 Ak=zeros(length(ck),length(uk));
60 ukp=uk;
61 for i=1:length(uk)
62     ukp(i)=ukp(i)+sqrt(eps);
63     xkp=computeOpenloopSolution(@model,N,T,x0,ukp);
64     gk(i)=(costfunction(xkp,ukp)-fk)/sqrt(eps);
65     Ak(:,i)=(nonlinearconstraints(xkp,ukp)-ck)/sqrt(eps);
66     ukp(i)=uk(i);
67 end
68 % initialize Lagrange multipliers

```

```

69 lambdak=ones(size(ck));
70 j= ck==0; % index of active constraints
71 lambdak(j)=1; % only active multipliers are nonzero
72 % choose initial n x n symmetric pd hessian approximation B0
73 Bk=eye(length(uk));
74 % repeat until a convergence test is satisfied
75 k=1;
76 stop=false;
77 while (~stop)
78     % compute pk by solving QP subproblem
79     % Lk is the corresponding multiplier
80     [pk,~,Lk,~]=solveqp(Bk,gk,Ak,-ck,uk',TolOpt,MaxIt);
81     % set plambda
82     plambda=Lk-lambdak;
83     % choose muk
84     if muk<(gk'*pk+.5*pk'*Bk*pk)/((1-rho)*norm(ck,1))
85         muk=(gk'*pk+.5*pk'*Bk*pk)/((1-rho)*norm(ck,1))+10; %*rand;
86     end
87     % compute line search step alphak
88     alphak=1;
89     phik=fk+muk*max([0; -ck]);
90     D1k=gk'*pk-muk*max([0; -ck]);
91     cont=true;
92     while cont
93         xk1=computeOpenloopSolution(@model,N,T,x0,uk+(alphak*pk)');
94         fk1=costfunction(xk1,uk+(alphak*pk)');
95         ck1=nonlinearconstraints(xk1,uk+(alphak*pk)');
96         phik1=fk1+muk*max([0; -ck1]);
97         if phik1<=phik+eta*alphak*D1k
98             cont=false;
99         else
100             alphak=.9*tau*alphak;
101             if alphak<=TolOpt
102                 cont=false;
103                 xk1=computeOpenloopSolution(@model,N,T,x0,uk+...
104                     (alphak*pk)');
105                 fk1=costfunction(xk1,uk+(alphak*pk)');
106                 ck1=nonlinearconstraints(xk1,uk+(alphak*pk)');
107             end
108         end
109     end
110     % calculate new iterates
111     sk=alphak*pk;
112     uk1=uk+sk';
113     lambdak1=lambdak+alphak*plambda;
114     % evaluate fk1, gk1, ck1, Ak1
115     ukp=uk1;

```

```

116     gk1=zeros(length(uk1),1);
117     Ak1=zeros(length(ck1),length(uk1));
118     for i=1:length(uk1)
119         ukp(i)=ukp(i)+sqrt(eps);
120         xkp=computeOpenloopSolution(@model,N,T,x0,ukp);
121         gk1(i)=(costfunction(xkp,ukp)-fk1)/sqrt(eps);
122         Ak1(:,i)=(nonlinearconstraints(xkp,ukp)-ck1)/sqrt(eps);
123         ukp(i)=uk1(i);
124     end
125     % compute first-order optimality conditions
126     F=[gk1-Ak1'*lambdak1; lambdak1.*ck1];
127     % check convergence
128     if max(abs(F))<=TolOpt % pk ou sk
129         stop=true;
130     % stop if step is too small
131     elseif norm(sk,2)<=TolOpt*norm(uk,2)
132         stop=true;
133     % stop if fun is not decreasing
134     elseif abs(fk1-fk)<=TolOpt*abs(fk)
135         stop=true;
136     % stop if maximum iterations exceeded
137     elseif k>=MaxIt
138         stop=true;
139     else
140         % compute new hessian approximation (BFGS)
141         yk=(gk1-gk)-(Ak1-Ak)*lambdak1;
142         if sk'*yk>=.2*sk'*Bk*sk
143             thetak=1;
144         else
145             thetak=.8*sk'*Bk*sk/(sk'*Bk*sk-sk'*yk);
146         end
147         rk=thetak*yk+(1-thetak)*Bk*sk;
148         Bk=Bk+(rk*rk')/(sk'*rk)-(Bk*sk)*(sk'*Bk)/(sk'*Bk*sk);
149         % repeat
150         uk=uk1;
151         fk=fk1;
152         gk=gk1;
153         ck=ck1;
154         Ak=Ak1;
155         lambdak=lambdak1;
156         k=k+1;
157     end
158 end
159 % x*=xk1
160 u_new=uk1;
161 % store the present values of V_FC and U
162 u_old=u_new;

```

```

163 v_old=x0(2);
164 %=====
165 % step 3: apply control to process
166 %=====
167 I_FC_ref=u_new(1);

```

## B.3 Algoritmo do Método dos Conjuntos Ativos para Programação Quadrática Convexa

```

1 %SOLVEQP Quadratic programming.
2 %
3 %   Author: Derick Furquim Pereira
4 %
5 %   [x,fval,lambda,k]=SOLVEQP(G,c,A,b,x0,TolOpt,MaxIt) attempts to
6 %   solve a quadratic programming problem of the form:
7 %
8 %           min 0.5*x'*G*x + x'*c
9 %           x
10 %
11 %           subject to  Aeq*x = beq **T0 D0**
12 %                      A*x >= b
13 %
14 %   using the active-set method for convex QP [1].
15 %
16 %   Input arguments:
17 %
18 %   G           positive semidefinite hessian (convex QP)
19 %   x0          feasible starting point
20 %   Aeq*x = b   linear equality constraints **T0 D0**
21 %   A*x >= b    linear inequality constraints
22 %   TolOpt      tolerance for stop criteria
23 %   MaxIt       maximum number of iterations allowed
24 %
25 %   Output arguments:
26 %
27 %   x           vector x that minimizes 0.5*x'*G*x + x'*c
28 %   fval        value of objective function at x
29 %   lambda      Lagrange multipliers
30 %   k           number of iterations
31 %
32 %   References:
33 %
34 %   [1] Nocedal, J., Wright, S., Numerical Optimization, 2nd ed.,
35 %   2006.

```

```

36 %
37 function [x,fval,lambda,k]=solveqp(G,c,A,b,x0,TolOpt,MaxIt)
38 % feasible starting point
39 xk=x0;
40 % set initial working set W0
41 % set of active constraints
42 Wk=find(abs(A*xk-b)<=TolOpt*ones(size(b)));
43 % set of inactive constraints
44 NotWk=find(abs(A*xk-b)>TolOpt*ones(size(b)));
45 % declare Wk and NotWk size upper bounds (matlab coder)
46 coder.varsize('Wk',[length(b) 1]);
47 coder.varsize('NotWk',[length(b) 1]);
48 % initialize variables
49 lambdai=[];
50 k=1;
51 stop=false;
52 while ~stop
53     k=k+1;
54     % solve equality constrained problem to find pk with
55     % constraints from the working set Wk
56     gk=G*xk+c;
57     Aak=A(Wk,:);
58     zk=zeros(size(Aak,1),1);
59     [pk,~] = nullspace_method(G,gk,Aak,zk);
60     % if pk==0
61     if max(abs(pk))<=TolOpt
62         % compute lagrange multipliers lambdai that satisfy
63         % Aak'*lambdai=gk
64         lambdai=linsolve(Aak',gk);
65         % check if all lagrange multipliers are non negative
66         lambdai_non_negative=true;
67         for i=1:length(lambdai)
68             if lambdai(i)<0
69                 lambdai_non_negative=false;
70             end
71         end
72         % stop if all lambda >=0
73         if lambdai_non_negative
74             % stop with x*=xk;
75             stop=true;
76         else
77             % find index of the most negative multiplier
78             j1=1;
79             min_lamb=lambdai(1);
80             for j=2:length(lambdai)
81                 if lambdai(j)<min_lamb
82                     j1=j;

```

```

83         min_lamb=lambdai(j);
84     end
85 end
86 % remove constraint associated with most negative
87 % multiplier from the working set
88 vec1=[NotWk; Wk(j1)];
89 NotWk=unique(vec1(:));
90 Wk(j1)=[];
91 end
92 % if pk~=0
93 else
94     % compute step alphak
95     alphai=zeros(1,length(NotWk));
96     for j=1:length(NotWk)
97         i=NotWk(j);
98         if ( all(A(i,:)*pk<0) && all(abs(A(i,:)*pk)>=TolOpt) )
99             alphai(j)=(b(i)-(A(i,:)*xk))/(A(i,:)*pk);
100         else
101             alphai(j)=2;
102         end
103     end
104     alphak=min([1 alphai]);
105     % update current iterate
106     xk=xk+alphak*pk;
107     % if maximum number of iterations is reached
108     if k==MaxIt
109         % calculate new multipliers
110         lambdai=linsolve(Aak',gk);
111         % stop
112         stop=true;
113     % repeat
114     else
115         % if there are blocking constraints (alphak<1)
116         if alphak<1
117             % find index of the blocking constraints
118             j2=1;
119             min_alph=alphai(1);
120             for j=2:length(alphai)
121                 if alphai(j)<min_alph
122                     j2=j;
123                     min_alph=alphai(j);
124                 end
125             end
126             % add the blocking constraint to the working set
127             vec2=[Wk; NotWk(j2)];
128             Wk=unique(vec2(:));
129             NotWk(j2)=[];

```

```

130         % if there are no blocking constraints, the working set
131         % remains the same: Wk+1=Wk
132         end
133     end
134 end
135 end
136 % x*=xk;
137 x=xk;
138 % fval
139 fval=.5*x'*G*x + x'*c;
140 % lagrange multipliers, if any
141 lambda=zeros(length(b),1);
142 if ~isempty(Wk)
143     lambda(Wk)=lambdai;
144 end

```

## B.4 Algoritmo do Sistema de Gerenciamento de Energia Preditivo Linear

```

1 %GPCEMS
2 %
3 %   Autor: Derick Furquim Pereira
4 %
5 %   P_FC_ref=GPCEMS(q_BT_m) implementa um algoritmo de programacao
6 %   quadratica (QP) para resolver o problema de controle otimo de
7 %   um cotrole preditivo generalizado que faz o gerenciamento de
8 %   energia de um veiculo eletrico hibrido a celula a combustivel.
9 %
10 %   Argumentos de entrada:
11 %
12 %   q_BT_m        valor medido do estado de carga da bateria
13 %
14 %   Argumentos de saida:
15 %
16 %   P_FC_ref      potencia de referencia da celula a combustivel
17 %                  calculada pelo controlador
18 %
19 function P_FC_ref = gpcems(q_BT_m)
20 %=====
21 % initialize parameters
22 %=====
23 % gpc parameters
24 % N1=1;
25 N2=10;

```

```

26 delta=1;
27 lambda=.00001;
28 w=60*ones(N2,1);
29 G=1e-3*[
30     0.056980056980057          0          0
           0          0          0
           0          0          0
           0
31     0.113960113960114    0.056980056980057          0
           0          0          0
           0          0          0
           0
32     0.170940170940171    0.113960113960114    0.056980056980057
           0          0          0
           0          0          0
           0
33     0.227920227920228    0.170940170940171    0.113960113960114
           0.056980056980057          0          0
           0          0          0
           0
34     0.284900284900285    0.227920227920228    0.170940170940171
           0.113960113960114    0.056980056980057          0
           0          0          0
           0
35     0.341880341880342    0.284900284900285    0.227920227920228
           0.170940170940171    0.113960113960114    0.056980056980057
           0          0          0
           0
36     0.398860398860399    0.341880341880342    0.284900284900285
           0.227920227920228    0.170940170940171    0.113960113960114
           0.056980056980057          0          0
           0
37     0.455840455840456    0.398860398860399    0.341880341880342
           0.284900284900285    0.227920227920228    0.170940170940171
           0.113960113960114    0.056980056980057          0
           0
38     0.512820512820513    0.455840455840456    0.398860398860399
           0.341880341880342    0.284900284900285    0.227920227920228
           0.170940170940171    0.113960113960114    0.056980056980057
           0
39     0.569800569800570    0.512820512820513    0.455840455840456
           0.398860398860399    0.341880341880342    0.284900284900285
           0.227920227920228    0.170940170940171    0.113960113960114
           0.056980056980057];
40 Fj=[
41     2     -1
42     3     -2

```

```

43         4      -3
44         5      -4
45         6      -5
46         7      -6
47         8      -7
48         9      -8
49        10      -9
50        11     -10];
51 H=2*(delta*(G'*G)+lambda*eye(N2));
52 % fuel cell current and soc measured at instant k-1
53 persistent q_old du_old u_old
54 if isempty(q_old), q_old=62; end % initial soc
55 if isempty(du_old), du_old=zeros(N2,1); end
56 if isempty(u_old), u_old=0; end
57 %=====
58 % step 1: obtain new initial values
59 %=====
60 du0=shiftHorizon(du_old');
61 f=Fj*[q_BT_m; q_old];
62 b=(2*delta*(f-w) '*G)';
63 R=[
64     tril(ones(N2)) % amplitude constraints
65     -tril(ones(N2)) % amplitude constraints
66     G
67     -G];
68 c=[
69     ones(N2,1)*(3000-u_old) % amplitude constraints
70     -ones(N2,1)*(0-u_old) % amplitude constraints
71     65*ones(N2,1)-f
72     -55*ones(N2,1)+f];
73 %=====
74 % step 2: solve the optimal control problem (SQP)
75 %=====
76 du=solveqp(H,b,-R,-c,du0',1e-6,50);
77 u=u_old+du(1);
78 % store present values
79 q_old=q_BT_m;
80 du_old=du;
81 u_old=u;
82 %=====
83 % step 3: apply control to process
84 %=====
85 P_FC_ref=u;

```

# Apêndice C

## Outros Resultados Experimentais

Neste apêndice são exibidas as curvas com as medições de corrente, tensão e vazão de hidrogênio da CaC, que foram realizadas em todos os experimentos deste trabalho, mas que não foram mostradas no Capítulo 4.

### C.1 Controle Preditivo Não Linear

A Figura C.1 mostra a tensão da CaC durante os experimentos dos casos A, B e C do CPBM não linear proposto neste trabalho. Nestes três experimentos foi considerado um horizonte de predição de 10 amostras ( $N = 10$ ). As Figuras C.2, C.3 e C.4 exibem, respectivamente, a vazão de hidrogênio da CaC durante os experimentos dos casos A, B e C do CPBM não linear.




Figura C.1: Medições experimentais da tensão da CaC real para os casos A, B e C do CPBM não linear.

A corrente e a tensão da CaC medidas durante os experimentos do caso C do CPBM não linear, considerando horizontes de predição de 5 e 15 amostras, são mostradas nas Figuras C.5 e C.6, respectivamente. As Figuras C.7 e C.8 exibem, respectivamente, a vazão de hidrogênio da CaC durante os experimentos do caso C do CPBM não linear considerando os horizontes de predição de 5 e 15 amostras.




Figura C.2: Medições experimentais da vazão de hidrogênio da CaC real para o caso A do CPBM não linear.




Figura C.3: Medições experimentais da vazão de hidrogênio da CaC real para o caso B do CPBM não linear.




Figura C.4: Medições experimentais da vazão de hidrogênio da CaC real para o caso C do CPBM não linear.




Figura C.5: Medições experimentais da corrente da CaC real para o caso C do CPBM não linear com horizonte de previsão de 5 e 15 amostras.




Figura C.6: Medições experimentais da tensão da CaC real para o caso C do CPBM não linear com horizonte de predição de 5 e 15 amostras.




Figura C.7: Medições experimentais da vazão de hidrogênio da CaC real para o caso C do CPBM não linear com horizonte de predição de 5 amostras.




Figura C.8: Medições experimentais da vazão de hidrogênio da CaC real para o caso C do CPBM não linear com horizonte de predição de 15 amostras.

## C.2 Controle Preditivo Generalizado

A tensão da CaC medida no experimento do CPG é exibida na Figura C.9. A Figura C.10 mostra a vazão de hidrogênio da CaC durante o mesmo experimento.

## C.3 Controle por Banda de Histerese

A tensão da CaC medida no experimento do CBH é exibida na Figura C.11. A Figura C.12 mostra a vazão de hidrogênio da CaC durante o mesmo experimento.




Figura C.9: Medições experimentais da tensão da CaC real para o CPG.




Figura C.10: Medições experimentais da vazão de hidrogênio da CaC real para o CPG.




Figura C.11: Medições experimentais da tensão da CaC real para o CBH.




Figura C.12: Medições experimentais da vazão de hidrogênio da CaC real para o CBH.