

UNIVERSIDADE FEDERAL DO PAMPA

John Jefferson Antunes Saldanha

**GERENCIAMENTO INTELIGENTE DA RECARGA DE VEÍCULOS ELÉTRICOS
OTIMIZANDO A OPERAÇÃO DO SISTEMA ELÉTRICO DE POTÊNCIA**

Alegrete

2017

John Jefferson Antunes Saldanha

**GERENCIAMENTO INTELIGENTE DA RECARGA DE VEÍCULOS ELÉTRICOS
OTIMIZANDO A OPERAÇÃO DO SISTEMA ELÉTRICO DE POTÊNCIA**

Dissertação apresentada ao Programa de Pós-graduação Stricto Sensu em Engenharia Elétrica da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Mestre em Engenharia Elétrica.

Orientador: Eduardo Machado dos Santos

Alegrete
2017

Ficha catalográfica elaborada automaticamente com os dados fornecidos
pelo(a) autor(a) através do Módulo de Biblioteca do
Sistema GURI (Gestão Unificada de Recursos Institucionais) .

S162g Saldanha, John Jefferson Antunes

Gerenciamento inteligente da recarga de veículos elétricos
otimizando a operação do sistema elétrico de potência / John
Jefferson Antunes Saldanha.

126 p.

Dissertação(Mestrado)-- Universidade Federal do Pampa,
MESTRADO EM ENGENHARIA ELÉTRICA, 2017.

"Orientação: Eduardo Machado Dos Santos".

1. Sistemas de energia. 2. Modelagem e otimização de
sistemas elétricos. 3. Veículos elétricos. I. Título.

JOHN JEFFERSON ANTUNES SALDANHA

GERENCIAMENTO INTELIGENTE DA RECARGA DE VEÍCULOS ELÉTRICOS
OTIMIZANDO A OPERAÇÃO DO SISTEMA ELÉTRICO DE POTÊNCIA

Dissertação apresentada ao Programa de Pós-graduação
Stricto Sensu em Engenharia Elétrica da Universidade
Federal do Pampa, como requisito parcial para obtenção
do Título de Mestre em Engenharia Elétrica.

Área de concentração: Sistemas de Energia

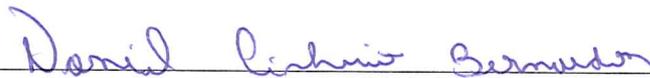
Dissertação defendida e aprovada em: 28 de Setembro de 2017.

Banca examinadora:



Prof. Dr. Eduardo Machado dos Santos

Orientador
(UNIPAMPA)



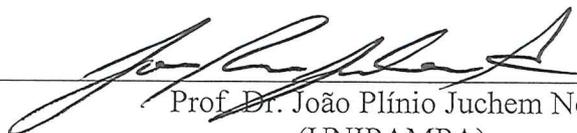
Prof. Dr. Daniel Pinheiro Bernardon

(UFSM)



Prof. Dr. Fernando Guilherme Kaehler Guarda

(UNIPAMPA)



Prof. Dr. João Plínio Juchem Neto

(UNIPAMPA)

*Dedico este trabalho à minha família,
por todo apoio, força, incentivo,
motivação e amizade.*

AGRADECIMENTOS

Agradeço ao Professor Eduardo Machado dos Santos por toda ajuda prestada, pela orientação fornecida e pelos ensinamentos repassados durante esta jornada. Sua orientação foi imensurável para a construção deste trabalho.

Agradeço aos membros da banca pelas valiosas sugestões que contribuíram para o crescimento desta pesquisa.

Agradeço aos professores e colegas do GESEP-UNIPAMPA. Em especial, aos colegas Alex, Arian, Fernanda e Marcel. Muito aprendi e muito ri com vocês.

Agradeço ao meu amor Gabriela pela companhia, suporte e carinho fornecidos antes, durante e após o desenvolvimento deste trabalho.

Agradeço aos meus pais, Marco e Angela, e meu irmão José Orlando, por tudo que já fizeram e fazem por mim. Principalmente por acreditar e incentivar em momentos difíceis e pelos sorrisos em momentos bons.

Agradeço a todos os demais que estavam na torcida.

Agradeço a Deus por tudo.

*“Bem-aventurados vós, que agora tendes
fome, porque sereis fartos. Bem-aventurados
vós, que agora chorais, porque haveis de rir.”
(Lucas 6:21)*

RESUMO

Uma difusão considerável pelo uso dos veículos elétricos *plug-in* (VEPs) tem sido promovida, de modo a reduzir as emissões poluentes dos veículos movidos a combustão, bem como preservar as fontes de energia fóssil. Entretanto, cabe ressaltar que os VEPs necessitam se conectar a rede elétrica para recarregar suas baterias. Nesse contexto, caso uma quantidade significativa de veículos elétricos *plug-in* solicitem recarga ao mesmo tempo, a operação do sistema elétrico de potência (SEP) será comprometida. Em contrapartida, os VEPs também podem auxiliar a rede elétrica através do controle da taxa de recarga e injeção de energia ativa. Assim, é importante realizar o controle da recarga dos VEPs. Dessa forma, este trabalho propõe um sistema inteligente fundamentado em duas interfaces para controlar a taxa de recarga dos VEPs. A primeira interface visa controlar a taxa de recarga de uma frota de veículos com base em um controlador lógico fuzzy projetado e posteriormente ajustado. Nesta interface, buscam-se atender os requisitos do consumidor. Na segunda, gerenciam-se diversas frotas de VEPs visando minimizar perdas de energia e desvios de tensão na rede elétrica. Os resultados da primeira interface mostram que ambos os controladores projetado e ajustado respondem ao cálculo da taxa de recarga levando em consideração as informações inseridas pelo consumidor. Em adição, a resposta do controlador ajustado é mais próxima da resposta desejada, comparando com o controlador projetado. Os resultados da segunda interface mostram que o método de otimização reduziu as perdas de energia elétrica e os desvios de tensão no sistema teste estudado. Concomitantemente, a energia entregue para os VEPs aumentou de maneira significativa. Desta forma, com o sistema desenvolvido, espera-se reduzir o impacto no sistema elétrico de potência e otimizar sua operação, beneficiando a concessionária local, a rede elétrica e o consumidor.

Palavras-chave: Controlador lógico fuzzy. Controle inteligente da recarga. Otimização da operação. Veículos elétricos *plug-in*.

ABSTRACT

A considerable diffusion for the plug-in electric vehicles (PEVs) use has been promoted in order to reduce pollutant emissions from combustion vehicles, as well as to preserve fossil energy sources. However, it should be noted that the VEPs need to connect in the power grid to charge their batteries. In this context, in case a significant amount of plug-in electric vehicles (PEVs) request charging at the same time, power grid operation will suffer complications. On the other hand, the PEVs can also aid the power grid through the charging rate control and active energy injection. Thus, it is important to control the charging of PEVs. In this way, this work proposes an intelligent system based on two interfaces to control the charging rate of PEVs. The first interface aims to control the charging rate of a vehicle fleet based on a fuzzy logic controller designed and subsequently adjusted. In this interface, it is sought to meet the consumer's requirements. In the second, several PEV fleets are managed in order to minimize power losses on the electricity grid. The results of the first interface show that both the designed and adjusted controllers respond to the charging rate calculation taking into account the information entered by the consumer. In addition, the adjusted controller response is closer to the desired response compared to the designed controller. The results of the second interface show that the optimization method reduced the energy losses and the voltage deviations in the test system studied. At the same time, the energy delivered to the PEVs increased significantly. Thus, with the developed system, it is expected to reduce the impact on the power grid and optimize its operation, benefiting the local utility, the electricity grid and the consumer.

Keywords: Fuzzy logic controller. Operation optimization. Plug-in electric vehicles. Smart charging control.

LISTA DE ILUSTRAÇÕES

Figura 1 – Esquema ilustrativo da comunicação entre o agregador e o sistema elétrico de potência.	35
Figura 2 – Descrição geral de um sistema de inferência fuzzy.	46
Figura 3 – Roleta para seleção dos pais.	47
Figura 4 – Operação de recombinação.	48
Figura 5 – Arquitetura da proposta para o controle inteligente da recarga de VEPs.	56
Figura 6 – Funcionamento geral da proposta para o controle inteligente da recarga de VEPs.	57
Figura 7 – Arquitetura do controlador lógico fuzzy para a aplicação.	60
Figura 8 – Disposições dos conjuntos fuzzy para as três variáveis de entrada e a variável de saída.	61
Figura 9 – Realocação de um conjunto fuzzy dentro de um intervalo de ajuste.	63
Figura 10 – Cromossomo \mathbf{z} com os genes codificados (picos dos conjuntos fuzzy).	66
Figura 11 – Taxas de recarga para alguns dos VEPs da frota sob estudo.	76
Figura 12 – Estados de carga atualizados para alguns dos VEPs da frota sob estudo.	77
Figura 13 – Estados de carga atualizados para alguns dos VEPs da frota sob estudo considerando uma mudança na prioridade do VEP 1.	78
Figura 14 – Saídas desejadas para as prioridades no intervalo $[0; 0, 1]$ ou $[0, 9; 1]$	79
Figura 15 – Resposta de um controlador fuzzy projetado e otimizado na recarga de um VEP com prioridades 0 e 1.	81
Figura 16 – Estados de carga atualizados para alguns VEPs com: (a) controlador fuzzy projetado e (a) controlador fuzzy ajustado.	82
Figura 17 – Superfície de saída do controlador fuzzy: não otimizado com prioridade 0; otimizado com prioridade 0; não otimizado com prioridade 1; otimizado com prioridade 1.	83
Figura 18 – Alimentador teste do IEEE de 123 barras utilizado para gerenciamento dos agregadores.	85
Figura 19 – Alimentador teste do IEEE de 34 barras utilizado para gerenciamento dos agregadores visando minimizar perdas de energia.	88
Figura 20 – Taxas de recarga para os 20 VEPs da frota estudada.	101
Figura 21 – Estados de carga das baterias dos 20 VEPs da frota estudada.	102
Figura 22 – Convergências da média das aptidões e da melhor aptidão do AG. O gráfico em (b) é uma aproximação das curvas de (a).	110
Figura 23 – Convergências da média das aptidões e da melhor aptidão do PSO.	111

LISTA DE TABELAS

Tabela 1 – Comparação entre fluxos de potência unidirecional e bidirecional. . . .	38
Tabela 2 – Objetivos e métodos da recarga coordenada para o fluxo de potência unidirecional.	40
Tabela 3 – Objetivos e métodos da recarga coordenada para o fluxo de potência bidirecional.	41
Tabela 4 – Principais comparações entre VEB, VEH e VEHP.	44
Tabela 5 – Escala numérica para comparações e julgamentos.	51
Tabela 6 – Relação do número de critério com o índice randômico.	53
Tabela 7 – Relação do número de critérios com o valor máximo de RC	53
Tabela 8 – Parâmetros dos conjuntos fuzzy projetado.	61
Tabela 9 – Base de regras para a saída TxR_0	62
Tabela 10 – Intervalo atribuído a cada categoria de prioridade.	69
Tabela 11 – Matriz de julgamentos das categorias da prioridade.	70
Tabela 12 – Pesos resultantes para a matriz de julgamentos definida.	71
Tabela 13 – Parâmetros dos conjuntos fuzzy antes e após a otimização com o PSO.	80
Tabela 14 – Potências mínima e máxima (em kW) de cada agregador.	86
Tabela 15 – Potências calculadas para cada agregador (kW).	86
Tabela 16 – Potência recebida pelo agregador e perdas elétricas do sistema.	87
Tabela 17 – Potências mínima e máxima (em kW) de cada agregador no sistema teste IEEE 34 barras.	88
Tabela 18 – Potência recebida pelo agregador e perdas elétricas no sistema teste de 34 barras.	89
Tabela 19 – Frota de VEPs utilizada no controlador lógico fuzzy projetado.	103
Tabela 20 – Parâmetros dos conjuntos fuzzy antes e após a otimização com AG e PSO.	105
Tabela 21 – Média e desvio padrão populacional das aptidões finais em 20 execuções independentes de cada algoritmo.	106
Tabela 22 – Tempo de uma única execução dos métodos para o ajuste do controlador lógico fuzzy.	106
Tabela 23 – Tempo de uma única execução dos métodos para o ajuste do controlador lógico fuzzy com 1.573 conjuntos de entrada.	108
Tabela 24 – Média e desvio padrão populacional das aptidões finais em 20 execuções independentes de cada algoritmo com 1.573 conjuntos de entrada.	108
Tabela 25 – Frota de VEPs na barra 2	113

Tabela 26 – Frota de VEPs na barra 6	113
Tabela 27 – Frota de VEPs na barra 11	114
Tabela 28 – Frota de VEPs na barra 16	114
Tabela 29 – Frota de VEPs na barra 22	114
Tabela 30 – Frota de VEPs na barra 29	115
Tabela 31 – Frota de VEPs na barra 32	115
Tabela 32 – Frota de VEPs na barra 37	115
Tabela 33 – Frota de VEPs na barra 43	116
Tabela 34 – Frota de VEPs na barra 46	117
Tabela 35 – Frota de VEPs na barra 50	117
Tabela 36 – Frota de VEPs na barra 56	118
Tabela 37 – Frota de VEPs na barra 59	119
Tabela 38 – Frota de VEPs na barra 60	119
Tabela 39 – Frota de VEPs na barra 64	120
Tabela 40 – Frota de VEPs na barra 69	120
Tabela 41 – Frota de VEPs na barra 71	120
Tabela 42 – Frota de VEPs na barra 74	121
Tabela 43 – Frota de VEPs na barra 77	121
Tabela 44 – Frota de VEPs na barra 80	122
Tabela 45 – Frota de VEPs na barra 85	122
Tabela 46 – Frota de VEPs na barra 88	123
Tabela 47 – Frota de VEPs na barra 92	123
Tabela 48 – Frota de VEPs na barra 99	124
Tabela 49 – Frota de VEPs na barra 100	124
Tabela 50 – Frota de VEPs na barra 102	125
Tabela 51 – Frota de VEPs na barra 106	125
Tabela 52 – Frota de VEPs na barra 109	126
Tabela 53 – Frota de VEPs na barra 111	126
Tabela 54 – Frota de VEPs na barra 114	126

LISTA DE ABREVIATURAS E SIGLAS

COD	Centro de Operação da Distribuição
SEP	Sistema Elétrico de Potência
VE	Veículo Elétrico
VEP	Veículo Elétrico <i>Plug-in</i>
VEB	Veículo Elétrico a Bateria
VEH	Veículo Elétrico Híbrido
VEHP	Veículo Elétrico Híbrido <i>Plug-in</i>
MCI	Motor de Combustão Interna
PSO	Otimização por enxame de partículas, do inglês, <i>Particle Swarm Optimisation</i>
AG	Algoritmo Genético
AHP	<i>Analytic Hierarchy Process</i>
V2G	Veículo-para-rede, do inglês <i>Vehicle-to-Grid</i>
SOC	Estado de Carga, do inglês <i>State Of Charge</i>
DSS	Simulador de Sistemas de Distribuição, do inglês <i>Distribution System Simulator</i>
IEEE	Instituto de Engenheiros Eletricistas e Eletrônicos, do inglês <i>Institute of Electrical and Electronics Engineers</i>
MISO	Múltiplas-entradas e única-saída, do inglês <i>multiple-input and single-output</i> .

LISTA DE SÍMBOLOS

p_i	Probabilidade atribuída para o cromossomo i
f_{min}	Menor valor de aptidão na população do algoritmo genético
f_i	Aptidão do cromossomo i
n_p	Tamanho da população do algoritmo genético
$\mathbf{X}_{pBest,j}$	Posição da melhor aptidão da partícula j
\mathbf{X}_{gBest}	Posição da melhor aptidão do enxame
\mathbf{X}_j	Posição da partícula j
\mathbf{V}_j	Velocidade da partícula j
A	Matriz de comparações do AHP
a_{ij}	Elemento da linha i e coluna j da matriz A
C	Critério de uma linha ou de uma coluna
w_{ij}	Valor atribuído à comparação do critério da linha i com o critério da coluna j
p_k	Peso do critério k
IC	Índice de consistência
$\lambda_{máx}$	Valor máximo dos autovalores correspondentes a cada critério
RC	Razão de consistência
IR	Índice randômico de consistência
TxR_0	Taxa de recarga inicial
TxR	Taxa de recarga final
SOC_0	Estado de carga inicial
SOC_f	Estado de carga final
t_0	Horário da conexão do veículo na rede elétrica
t_f	Horário da desconexão do veículo na rede elétrica
B_{cap}	Capacidade da bateria
$P_{min,j}$	Potência mínima do agregador j

$P_{max,j}$	Potência máxima do agregador j
P_{j0}	Potência atribuída para o agregador j durante o processo de otimização
P_j	Potência atribuída para o agregador j no final do processo de otimização
$prioridade$	Prioridade inserida pelo consumidor para o seu veículo ser totalmente recarregado dentro do período estipulado
Δt	Período de discretização da simulação
h	Horário atual
Δt_{VEP}	Período que o VEP ficará conectado para a recarga
ΔSOC	Porcentagem do estado de carga da bateria que precisa ser recarregada
$\mu_{\Delta t_{VEP}}$	Pertinência da variável de entrada Δt_{VEP}
$\mu_{\Delta SOC}$	Pertinência da variável de entrada ΔSOC
$\mu_{prioridade}$	Pertinência da variável de entrada $prioridade$
μ_{TxR_0}	Pertinência da variável de saída TxR_0
a, b e x_0	Parâmetros da função de pertinência
t_p	Número de parâmetros de ajuste do controlador fuzzy
$n^{(j)}$	Número de conjuntos fuzzy para a variável linguística de entrada j
q	Número de conjuntos fuzzy para a variável de saída
z^k	Localização do pico k no vetor \mathbf{z}
l_0^k	Limite inferior do intervalo de ajuste do pico k
l_h^k	Limite superior do intervalo de ajuste do pico k
\mathbf{z}	Vetor com as localizações dos picos
y	Saída do controlador lógico fuzzy
y_d	Saída desejada do controlador lógico fuzzy
k_1 e k_2	Constantes de escala
$a_{n,j}$	Localização do pico da função de pertinência j da variável de entrada n
b_q	Localização do pico da função de pertinência q da variável única variável de saída

$pico$	Valor decimal do pico
$nBits$	Número de bits da string binária a ser gerada
l_0	Limite inferior de ajuste
l_h	Limite superior de ajuste
$novoPico$	Novo pico normalizado
$P_{req,i}$	Potência requisitada pelo VEP i
n_{VEP}	Número de VEPs no agregador
P_D	Potência disponibilizada pelo COD para o agregador
$P_{req,i}^0$	Potência requisitada inicialmente pelo VEP i com base na taxa de recarga inicial TxR_0
$\bar{P}_{req,i}$	Potência normalizada do VEP i em função de P_D
P_{max}	Valor necessário no agregador para recarregar todos os VEPs
P_{min}	Valor mínimo que o agregador demanda do COD para garantir a recarga de apenas uma parcela da frota
$P_{VEP,i}$	Potência necessária para recarregar o VEP i até SOC_f
w	Peso que limita as potências por cada faixa de prioridade dos VEPs
l	Índice que indica a linha de distribuição do sistema
n_l	Número total de linhas de distribuição do sistema
R_l	Resistência da linha l
I_l	Corrente elétrica na linha l
n_A	Número total de agregadores
V_b	Módulo da tensão na barra b
V_d	Módulo da tensão desejada
P	Potência ativa
Q	Potência reativa
V_i	Tensão na barra i

SUMÁRIO

1	INTRODUÇÃO	27
1.1	Considerações gerais	27
1.2	Motivação	27
1.3	Justificativa	28
1.4	Objetivos	28
1.5	Delimitações do trabalho	29
1.6	Estrutura do trabalho	29
2	REVISÃO BIBLIOGRÁFICA	31
2.1	Considerações gerais	31
2.2	Impacto da recarga dos VEPs	31
2.3	Benefícios dos VEPs	33
2.3.1	Benefícios em termos ambientais	33
2.3.2	Serviços para o SEP	33
2.4	Desafios do conceito V2G	36
2.5	Estratégias para recargas	37
2.5.1	Tipos de recargas	37
2.5.2	Recarga descoordenada	38
2.5.3	Recarga coordenada	39
2.6	Considerações finais	41
3	FUNDAMENTAÇÃO TEÓRICA	43
3.1	Considerações gerais	43
3.2	Tecnologia dos veículos elétricos	43
3.3	Controlador lógico fuzzy	45
3.4	Algoritmo genético	46
3.5	Otimização por enxame de partículas	48
3.6	<i>Analytic hierarchy process</i>	50
3.7	Considerações finais	54
4	PROPOSTA PARA O CONTROLE INTELIGENTE DA RECARGA DE VEPS	55
4.1	Considerações gerais	55
4.2	Estrutura geral da proposta	55
4.3	Controle da recarga dos VEPs	59
4.3.1	Projeto do controlador lógico fuzzy	59
4.3.2	Otimização de um controlador lógico fuzzy	62
4.3.2.1	Função objetivo do ajuste do controlador lógico fuzzy	62
4.3.2.2	Algoritmo genético para o ajuste do controlador fuzzy	65

4.3.2.3	PSO para o ajuste do controlador fuzzy	67
4.3.3	Cálculo da taxa de recarga final	67
4.4	Gerenciamento das frotas de VEPs	68
4.4.1	Determinação das potências dos agregadores	68
4.4.2	Função objetivo para o gerenciamento dos agregadores	71
4.4.3	Método de otimização para o gerenciamento dos agregadores	73
4.5	Considerações finais	73
5	RESULTADOS E DISCUSSÕES	75
5.1	Considerações gerais	75
5.2	Considerações iniciais	75
5.3	Gerenciamento de uma frota de VEPs	75
5.3.1	VEPs se recarregando com controlador lógico fuzzy projetado	75
5.3.2	Otimização do controlador lógico fuzzy	78
5.3.3	VEPs se recarregando com controlador lógico fuzzy otimizado pelo PSO	80
5.4	Gerenciamento dos agregadores	84
5.4.1	Gerenciamento dos agregadores no sistema teste de 123 barras	84
5.4.2	Gerenciamento dos agregadores no sistema teste de 34 barras	87
5.5	Considerações finais	90
6	CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS	91
6.1	Conclusões	91
6.2	Sugestões para trabalhos futuros	92
	REFERÊNCIAS	93
	APÊNDICE A – TAXAS DE RECARGAS E ESTADOS DE CARGA DOS 20 VEPS	101
	APÊNDICE B – DADOS DOS 20 VEPS UTILIZADOS EM UM AGREGADOR	103
	APÊNDICE C – COMPARAÇÃO ENTRE O AG E O PSO PARA O AJUSTE DO CONTROLADOR FUZZY PRO- JETADO	105
	APÊNDICE D – DADOS DAS FROTAS DE VEPS UTILIZADAS NO COD	113

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES GERAIS

As preocupações com relação aos efeitos prejudiciais dos poluentes emitidos pelos veículos movidos à combustão têm sido crescentes. Aliado a isto, surgem preocupações relacionadas à segurança energética e com a manutenção das reservas de energia fóssil. Todos estes fatores vêm promovendo uma difusão considerável pelo uso dos veículos elétricos *plug-in* (VEPs) em contrapartida aos movidos a combustão, de modo a reduzir emissões poluentes e preservar as fontes de energia fóssil.

Nesse contexto, os veículos elétricos *plug-in* (VEPs) aparecem como uma opção para reduzir estas emissões e, ao mesmo tempo, diminuir a dependência do setor automotivo por combustíveis fósseis, uma vez que estes veículos são movidos por motores elétricos alimentados por energia armazenada em baterias. Eles podem ter somente motores elétricos (puramente elétricos) ou possuir motores a combustão em associação com motores elétricos (híbridos). Ambos os tipos necessitam se conectar a rede elétrica para recarregar as respectivas baterias. Dessa forma, o veículo consumirá energia do sistema atuando como carga elétrica.

Caso uma quantidade significativa de VEPs requisitem recarga ao mesmo tempo e sem coordenação, o sistema elétrico poderá sofrer com certas complicações. Entre estas, destacam-se os problemas de estabilidade, sobrecarga de linhas de distribuição e aumento da demanda durante períodos de pico, os quais podem ser gerados como consequência da recarga não coordenada de VEPs. Ressalta-se ainda que a última complicação citada pode ocasionar o despacho de plantas de geração caras e poluentes.

O VEP, visando o benefício da rede elétrica, também pode ser utilizado para prestar serviços auxiliares. Tais veículos são denominados de V2G, do inglês *vehicle-to-grid* ou veículo-para-rede. Os V2Gs podem fornecer regulação de tensão e frequência, dar suporte para entrada de fontes alternativas de energia elétrica e minimizar perdas de energia em redes elétricas de distribuição, entre outros benefícios.

Nesse contexto, visando mitigar impactos e beneficiar o sistema elétrico de potência, é importante realizar o controle da recarga dos veículos elétricos *plug-in*.

1.2 MOTIVAÇÃO

Pesquisas sobre os impactos que a recarga dos VEPs podem ocasionar na rede elétrica vêm sendo desenvolvidas desde a década de 80. Trabalhos como Orr, Emanuel e Oberg (1982), Collins e Mader (1983), Rahman e Shrestha (1993), Denholm e Short (2006), Kintner-Meyer, Schneider e Pratt (2007), Masoum, Moses e Hajforoosh (2012), Yilmaz e Krein (2013), Shafiee, Fotuhi-Firuzabad e Rastegar (2013), ElNozahy e Salama (2014) e Giglioli et al. (2014) abordam alguns dos impactos ocasionados.

No entanto somente nos últimos 20 anos essas pesquisas cresceram consideravel-

mente. Exemplos destes trabalhos que buscam a mitigação dos impactos e, também, o aproveitamento dos benefícios que os VEPs poderiam fornecer são Guille e Gross (2009), Clement-Nyns, Haesen e Driesen (2010), Han, Han e Sezaki (2010), Deilami et al. (2011), Sortomme e El-Sharkawi (2012), Zou e Liu (2015) e Vayá e Andersson (2016).

Entretanto, soluções inteligentes visando o benefício tanto do consumidor quanto da rede elétrica ainda precisam ser exploradas. Em adição, ainda não existem metodologias conhecidas no Brasil com a proposta deste projeto que possam ser aplicadas quando os VEPs tornarem-se uma realidade nacional.

Esses fatos motivaram esse trabalho, onde o foco é propor um sistema inteligente que ajude a mitigar os impactos da recarga dos VEPs na rede elétrica buscando, também, beneficiar o consumidor.

1.3 JUSTIFICATIVA

Devido as crescentes preocupações com os poluentes emitidos pelos veículos movidos à combustão, os veículos elétricos *plug-in* apresentam-se como uma alternativa para reduzir estas emissões. Entretanto, os VEPs necessitam se conectar à rede elétrica para recarregar suas baterias. Dessa forma, caso uma quantidade significativa de veículos requisitem recarga ao mesmo tempo e uma coordenação adequada não for empregada, a operação do sistema elétrico poderá sofrer certas complicações. Nesse contexto, é importante realizar um controle coordenado, controlado e planejado da recarga dos VEPs, para que os impactos na rede elétrica sejam mitigados.

Em contrapartida aos impactos, os veículos elétricos *plug-in* também podem auxiliar o sistema elétrico de potência através da prestação de serviços auxiliares. Estes serviços são aproveitados através do controle da taxa de recarga do veículo ou da injeção de energia do mesmo para a rede. Dessa forma, além de mitigar os impactos, pode-se aproveitar outros benefícios que auxiliem na operação da rede elétrica.

Aliando essas duas vertentes, justifica-se a necessidade de controlar a recarga dos veículos elétricos *plug-in*, visando mitigar impactos na rede elétrica e auxiliar a operação da mesma.

1.4 OBJETIVOS

Este trabalho tem como objetivo geral propor um sistema inteligente para controlar a recarga de veículos elétricos *plug-in*, visando satisfazer os requerimentos do consumidor e beneficiar a rede de distribuição de energia elétrica.

Como objetivos específicos, citam-se:

- Projetar um controlador lógico fuzzy para controlar a recarga de uma frota de VEPs;

- Ajustar a base de conhecimento do controlador lógico fuzzy projetado com dois métodos de otimização, compará-los de modo a determinar qual melhor se enquadra na função desejada;
- Verificar a influência do controlador ajustado em relação ao projetado na recarga de uma frota de VEPs;
- Desenvolver uma metodologia para gerenciar diversas frotas de VEPs em uma rede elétrica, visando minimizar perdas de energia elétrica.

1.5 DELIMITAÇÕES DO TRABALHO

Este trabalho apresenta as seguintes delimitações na sua proposta:

- Considera-se o controle da taxa de recarga dos veículos elétricos *plug-in* sem a injeção de energia ativa do mesmo na rede. Ou seja, o fluxo de potência é unidirecional da rede elétrica para o veículo;
- A proposta apresenta uma abordagem mista entre centralizada e descentralizada. A primeira, porque uma interface gerencia uma frota de VEPs. A segunda, porque o consumidor decide a necessidade do veículo após a recarga;
- O VEP é modelado como uma carga de potência constante, em função do estado de carga, da capacidade da bateria e da taxa de recarga do veículo;
- O controlador lógico fuzzy é projetado visando retornar a taxa de recarga para cada VEP relacionando o período de conexão do VEP à rede elétrica, o estado de carga a ser recarregado da bateria e a necessidade que o consumidor possui do veículo;
- O controlador fuzzy é projetado por um especialista e ajustado com base em uma saída desejada também inserida por este especialista;
- A operação do sistema elétrico é otimizada buscando minimizar perdas de energia elétrica.

1.6 ESTRUTURA DO TRABALHO

No Capítulo 2, apresenta-se a revisão bibliográfica acerca do trabalho, contendo os principais impactos e benefícios do veículo elétrico *plug-in* no sistema elétrico de potência, bem como as principais estratégias para recargas dos VEPs propostas na literatura especializada.

No Capítulo 3, são apresentados os conceitos teóricos necessários para o entendimento desta Dissertação, tais como: a tecnologia dos veículos elétricos, o controlador lógico fuzzy, as técnicas de otimização avaliadas, algoritmo genético e otimização por

enxame de partículas (PSO), bem como o método de auxílio à tomada de decisões AHP (*Analytic Hierarchy Process*).

O Capítulo 4 apresenta a proposta para o controle inteligente da recarga de veículos elétricos *plug-in*.

No Capítulo 5, os resultados obtidos com a metodologia proposta são apresentados, demonstrando a resposta de um controlador projetado na recarga de uma frota de VEPs, a resposta de dois métodos de otimização no ajuste deste controlador, bem como a resposta do controlador ajustado com o melhor método de otimização para a recarga de uma frota de 20 VEPs. Por fim, são apresentados os resultados que confirmam os benefícios trazidos para a rede elétrica através do gerenciamento de 30 frotas de VEPs.

Por fim, no Capítulo 6, as conclusões e as sugestões de trabalhos futuros são apresentadas.

2 REVISÃO BIBLIOGRÁFICA

2.1 CONSIDERAÇÕES GERAIS

Este capítulo apresenta a revisão bibliográfica realizada, a qual motivou e permitiu o desenvolvimento do sistema proposto neste trabalho. Inicialmente, os impactos e benefícios do veículo elétrico *plug-in* no sistema elétrico de potência são apresentados de forma concisa. Da mesma forma, os principais desafios que podem impedir a ampla difusão dos VEPs são considerados. Após, as estratégias para recargas dos VEPs recentemente propostas na literatura especializada são apresentadas, as quais motivaram a criação do sistema proposto nesta Dissertação.

2.2 IMPACTO DA RECARGA DOS VEPS

A recarga dos veículos elétricos *plug-in* é cíclica, variável e, de certa forma, imprevisível. Se uma quantidade significativa de VEPs requisitarem energia ao mesmo tempo e uma coordenação adequada não for empregada, a recarga poderá ocorrer aleatoriamente tanto no tempo quanto no espaço. Isto pode submeter o sistema elétrico de potência a certas complicações, principalmente em horários de pico.

O surgimento de picos de consumo indesejáveis durante a recarga de VEPs é muito provável, dado que os proprietários dos VEPs poderiam chegar em casa após o trabalho e iniciarem a recarga dos veículos durante um período de alta demanda. Aliado com o fato de que os chuveiros elétricos compõem uma grande parcela da carga residencial brasileira, a coincidência da recarga com o horário de uso do chuveiro poderia alterar significativamente o perfil de carga. Ipakchi e Albuyeh (2009) discutem que um típico VEP sob recarga mais que dobra a carga média de uma residência, alterando drasticamente a curva de carga do consumidor.

Meliopoulos et al. (2009) afirmam que, se o veículo requisitar recarga em períodos indevidos e em centros urbanos congestionados, picos de consumo indesejáveis podem surgir. Outra comprovação apresentada indica que, com a adesão aos VEPs, a expectativa de solicitação do transformador também aumenta significativamente. Em adição, os autores afirmam que, caso o carregador empregado na recarga não for sofisticado o suficiente, problemas com o fator de potência e com as harmônicas injetadas passam a ser expressivos.

Ainda no contexto da qualidade de energia elétrica, o estudo de Jiang et al. (2014) conclui que a tensão de neutro na frequência fundamental aumenta relativamente na rede de distribuição secundária com a penetração de VEPs.

Além disso, Sperandio, Saldanha e Basso (2012) consideram um cenário de penetração de veículos elétricos *plug-in* na região metropolitana do estado do Rio Grande do Sul. O trabalho conclui que os transformadores das subestações estariam sobrecarregados durante a recarga dos VEPs. Além disso, em um dos casos simulados, violações no limite térmico de linhas de transmissão foram registradas.

Relacionado ao despacho energético, Basso (2011) afirma que, caso a energia elétrica da recarga dos VEPs seja proveniente de usinas termoelétricas convencionais no Brasil, excluindo as termonucleares, a poluição decorrente da geração aumentará de acordo com o incremento da penetração de veículos no Sistema Elétrico de Potência (SEP). Dessa forma, caso uma grande quantidade de VEPs comece a recarregar paralelamente e sem coordenação, a redução dos poluentes gerados pelos veículos a combustão não é expressiva, uma vez que ela é revertida em poluição emitida pelas usinas termoelétricas. Ainda, o autor divulga um estudo sobre o impacto da recarga dos VEPs no sistema de distribuição de energia elétrica, constatando, via simulações, que os transformadores apresentam situações de carregamento elevado devido à presença dos veículos elétricos. O mesmo comportamento foi constatado por ElNozahy e Salama (2014).

Fora do contexto da qualidade energética e da questão ambiental, de acordo com Masoum, Moses e Hajforoosh (2012), problemas locais nas redes de distribuição podem surgir com a recarga dos VEPs. Dentre esses problemas constatados pelos autores, destacam-se: aumento das perdas de energia e dos desvios de tensão, sobrecarga de condutores e de transformadores de distribuição e a redução da confiabilidade da rede elétrica de distribuição.

Outra consequência da recarga não coordenada de veículos elétricos verificada por Halbleib, Turner e Naber (2012), apontou um aumento na fatura de energia de até 22% para os consumidores, devido ao crescimento da demanda registrada pela recarga dos veículos, mesmo sob baixa taxa de penetração. Ainda no contexto financeiro, Veldman e Verzijlbergh (2015) exploraram o impacto da recarga dos veículos elétricos nos gastos de capitais. Estes gastos seriam resultantes da necessidade de reforçar a rede e também os custos das perdas de energia. Na metodologia desenvolvida, encontrou-se um aumento de 25% dos preços anteriores em comparação a um cenário sem inserção de VEs. Constatou-se que grande parte desse aumento nos custos são resultantes das perdas de energia.

Também, destaca-se o trabalho de Giglioli et al. (2014) o qual, através de uma abordagem probabilística, avalia o impacto da recarga na eficiência e na confiabilidade do sistema. Dessa forma, verificou-se que, se os VEPs solicitarem recarga durante horários de pico, algumas usinas termoelétricas de resposta rápida e com eficiência relativamente baixa devem ser acionadas para atender o crescimento da demanda. Assim, a eficiência global do sistema de geração diminui. Em adição, as confiabilidades destas plantas de geração também são baixas, reduzindo a confiabilidade global do sistema.

Ressalta-se ainda que recarga do VEP também pode influenciar na estabilidade transitória de tensão da rede elétrica de distribuição. Zhang et al. (2014) concluíram, a partir de simulações, que o sistema fica instável quando a taxa de penetração de VEPs alcança 50% da potência nominal do sistema e que essa instabilidade se agrava com o aumento da penetração. Isto indica que quanto maior a penetração de VEPs, menor será a estabilidade transitória de tensão.

Resumidamente, a recarga dos VEPs sem a coordenação adequada pode aumentar a carga média dos consumidores, causando picos de consumo indesejáveis. Além disso, essa recarga pode sobrecarregar transformadores e ultrapassar os limites térmicos das linhas de transmissão. Em adição, pode causar o despacho de usinas termoelétricas caras e altamente poluentes para atender a demanda crescente. Desvios de tensão e redução na confiabilidade e na eficiência também podem surgir. Por fim, a fatura de energia elétrica pode aumentar e a estabilidade de tensão pode ser comprometida.

2.3 BENEFÍCIOS DOS VEPs

2.3.1 BENEFÍCIOS EM TERMOS AMBIENTAIS

Em termos ambientais, as emissões de CO₂ e de gases do efeito estufa podem ser reduzidas drasticamente, conforme mostram Duvall e Knipping (2007), Jourabchi (2008) e Ramteen e Denholm (2009). Os referidos trabalhos indicam que as emissões podem não ser expressivamente mitigadas caso sejam utilizadas fontes de geração de energia elétrica poluentes. Além das reduções, registram-se também uma diminuição na dependência de combustíveis fósseis na indústria automotiva.

Comparando as tecnologias de veículos, verifica-se que os VEPs apresentam benefícios sobre os VEHs e veículos convencionais, mesmo contabilizando as emissões decorrentes da geração de energia elétrica. Kintner-Meyer, Schneider e Pratt (2007) projetam reduções de 27% dos gases do efeito estufa e 31% dos óxidos de nitrogênio. Os autores Stephan e Sullivan (2008) apontam que os VEPs reduzem as emissões de CO₂ em 25% a curto prazo e até 50% a longo prazo, quando comparados com os veículos híbridos. Já Axsen e Kurani (2010) calculam uma redução das emissões de CO₂ de mais de 32% a curto prazo e 25% a longo prazo, comparando VEPs com veículos de motores à combustão interna.

Dessa forma, evidencia-se que a adoção dos veículos elétricos *plug-in* irá reduzir significativamente a emissão de poluentes na atmosfera em relação aos veículos convencionais movidos a combustíveis fósseis. Entretanto, deve-se ter cuidado quando em relação à redução das emissões globais, que incluem a poluição gerada pelas usinas termoelétricas acionadas para atender a demanda. Neste caso, a diminuição das emissões totais pode não ser tão significativa.

2.3.2 SERVIÇOS PARA O SEP

Em sistemas elétricos de potência, os serviços auxiliares são os serviços necessários para manter a confiabilidade do sistema, manter o equilíbrio entre oferta e demanda e auxiliar a operação. Entre esses serviços, destacam-se o controle de frequência, o controle de tensão, a reserva circulante, o nivelamento da carga de pico, o auxílio na partida de

geradores de emergência (*black start*), o suporte para energia reativa e a compensação de perdas ativas.

Os veículos elétricos *plug-in* combinados no conceito V2G podem atuar em benefício da rede elétrica, através da prestação de diferentes serviços auxiliares. Entretanto, uma única unidade de veículo elétrico possui capacidade limitada para representar um benefício expressivo para a rede. Assim, os VEPs são normalmente agrupados em frotas ou, como Guille e Gross (2009) definem e explicam, em agregadores.

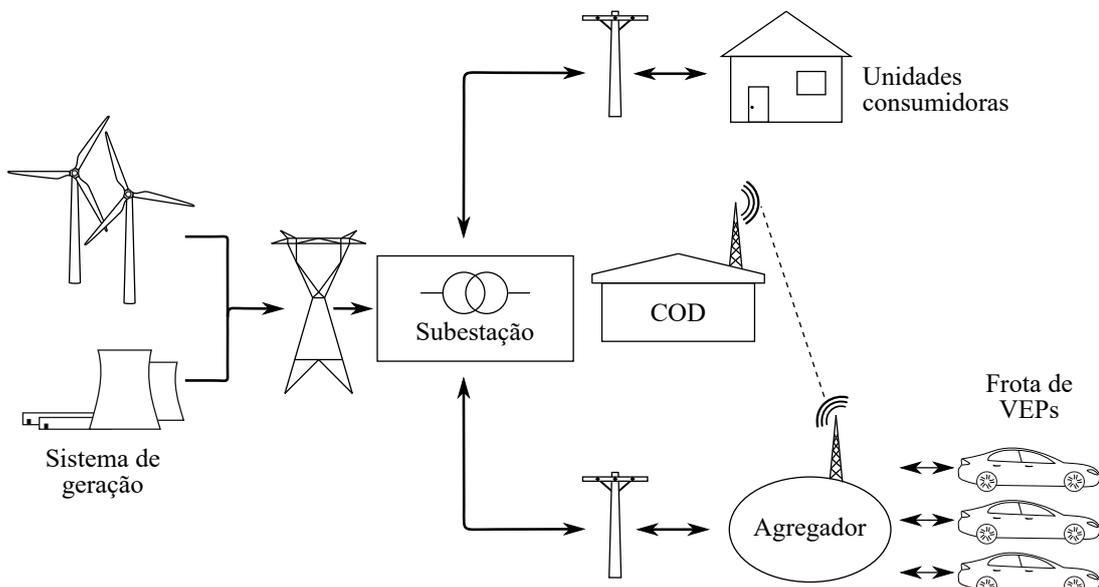
O agregador é uma entidade que reúne vários VEPs para gerar um impacto expressivo, benéfico e efetivo na rede elétrica. Ele atua como uma interface entre o operador do sistema e a frota de veículos conectada e possibilita a participação dos veículos no mercado elétrico. O agregador se comporta como um tomador de decisões, possuindo uma estratégia otimizada em seu funcionamento para efetivamente atuar como geração/armazenamento. Dessa forma, o agregador torna-se capaz de fornecer serviços auxiliares para a rede ou de atuar como uma carga controlável para ser recarregada de maneira mais benéfica para o sistema.

O esquema básico de comunicação entre o agregador e o SEP é ilustrado na Figura 1, onde a energia elétrica flui em um único sentido das usinas geradoras para os consumidores. Entre os VEPs e o agregador, o fluxo de energia é bidirecional, sendo que o último possui controle sobre a taxa de recarga ou descarga do primeiro. Os serviços auxiliares necessários para a rede e que possam ser executados pela frota de VEPs são solicitados remotamente pelo operador do sistema, configurando o fluxo de energia e comunicação em ambas as direções.

Dos serviços auxiliares no SEP, destacam-se a regulação de frequência e a regulação de tensão. A primeira é utilizada para balancear a oferta e demanda de energia ativa e a segunda para equilibrar a oferta e demanda de energia reativa. O conceito V2G é considerado uma alternativa muito promissora para realizar ambas as regulações, pois os VEPs podem responder rapidamente alterando suas taxas de recarga e descarga. Assim, eles possuem um maior valor de mercado quando atuando nos serviços de regulação, retornando lucros mais elevados (KEMPTON; TOMIĆ, 2005a; TOMIĆ; KEMPTON, 2007; RÍOS et al., 2012). O trabalho de Wu et al. (2012) comprova que a estabilidade transitória de um sistema elétrico sob diferentes faltas é melhorada através do controle da recarga dos VEHPs.

Dois outros serviços auxiliares são utilizados por Wang e Wang (2013): *peak shaving* e *valley filling*. Em tradução livre, corte do pico e preenchimento de vale, respectivamente. Ambos os conceitos servem para equilibrar a oferta e a demanda de energia elétrica. O primeiro corta picos de carga durante períodos críticos pelo controle da taxa de recarga ou pela descarga de energia. Já o segundo, consiste em recarregar o veículo durante horários fora de pico. Ou seja, a utilização de ambos os serviços busca suavizar a curva de carga, a fim de reduzir os picos durante horários de alta demanda e preencher os vales durante

Figura 1 – Esquema ilustrativo da comunicação entre o agregador e o sistema elétrico de potência.



Fonte: Adaptado de Tomić e Kempton (2007).

horários de baixa demanda.

Ainda dentro do contexto dos serviços auxiliares, Sortomme e El-Sharkawi (2012) consideram a prestação de serviços de reserva circulante de energia. No algoritmo criado, benefícios financeiros são oferecidos aos proprietários dos VEPs envolvidos no esquema.

Outros quatro serviços auxiliares que podem ser fornecidos por VEPs para redes de distribuição são investigados por Rautiainen et al. (2013): gerenciamento da carga de pico, gerenciamento do fluxo de potência, energia de reserva e melhoria da qualidade de energia. O primeiro caso considera o controle da taxa de recarga e descarga para suavizar a curva de carga. No segundo, utilizam-se os veículos para otimizar o fluxo de potência para atender um determinado objetivo, como por exemplo, reduzir perdas na linha. Ainda, considerou-se utilizar os VEPs como uma fonte de reserva para evitar interrupções. Por fim, procurou-se melhorar a qualidade da energia através da mitigação de quedas de tensão, harmônicas, *flicker* e assimetria.

Alguns outros benefícios que não se caracterizam como prestação de serviços auxiliares também podem ser extraídos da recarga controlada, entre eles:

- Aumento da precisão da previsão da demanda, conforme apresenta Ilić, Karnouskos e Beigl (2015);
- Redução dos custos e maximização dos benefícios quando aliando a recarga dos VEs com a geração de energia solar fotovoltaica, de acordo com Denholm, Kuss e Margolis (2013) e Vithayasrichareon, Mills e MacGill (2015);

- Redução da natureza intermitente das fontes renováveis solar e eólica, conforme Kempton e Tomić (2005b) e Wang et al. (2011).

Sumariamente, os veículos elétricos *plug-in*, através do conceito V2G, podem fornecer os serviços auxiliares de regulação de frequência e tensão, sendo estes provados como economicamente viáveis. Além disso, estes também podem ser utilizados para melhorar a estabilidade transitória, gerenciar a carga de pico, preencher os vales do perfil de consumo, disponibilizarem-se como reserva circulante de energia, gerenciar o fluxo de potência de maneira otimizada e melhorar a qualidade da energia elétrica. Nesse contexto, para que possam participar no mercado e providenciar serviços de forma expressiva, os veículos devem ser concentrados em agregadores, os quais atuam como interface entre a frota e o operador do SEP. Além disso, o conceito V2G aumenta a flexibilidade da rede para melhor aproveitar os recursos de energia renovável intermitentes, podendo também atuar no aumento da precisão da previsão de demanda como uma fonte variável de armazenamento.

2.4 DESAFIOS DO CONCEITO V2G

A utilização da bateria dos veículos para fornecer serviços auxiliares reduz sua vida útil devido aos ciclos extras de carga e descarga. Guille e Gross (2009) afirmam que, através de controle inteligente, tempo de recarga e fluxo de energia otimizados, é possível minimizar a taxa de degradação adicional da bateria devido aos serviços auxiliares. Ainda assim, existe uma barreira muito grande para atingir este controle inteligente.

Também, deve-se assegurar a comunicação segura entre o agregador, um grande número de VEPs e o operador do sistema elétrico, devendo existir uma infraestrutura bidirecional confiável. Além disso, sensores e medição inteligentes deverão ser implantados. A crescente demanda de energia para recarga poderá exigir, em alguns casos, ampliação da capacidade de geração, como citado anteriormente, uma vez que a recarga dos VEPs pode ocasionar impacto considerável nos equipamentos de distribuição, sobrecarregando-os. Todos esses pontos convergem para a necessidade de investimentos significativos no sistema elétrico para atender as mudanças decorrentes da inserção dos VEPs no SEP.

Outros desafios que impedem a difusão dos VEPs comumente apresentados são: o alto custo do investimento inicial comparado com os veículos convencionais, a baixa autonomia, a resistência dos setores automotivo e de petróleo, além da aceitação dos consumidores a esta nova tecnologia. Destaca-se que a resistência do setor automotivo está diminuindo, com incentivos sendo fornecidos para desenvolver esta tecnologia dos VEPs.

Tuttle e Baldick (2012) afirmam que devido a estes desafios o conceito V2G pode levar mais de 10 anos para ser atingido em quantidade significativa. No Brasil, a indústria automotiva passa por dificuldades devido à crise econômica de 2015, não correspondendo com as estimativas iniciais de crescimento, onde se incluem o crescimento esperado da frota

de veículos elétricos (VEs), que ainda é muito pequeno. Logo, não se tem uma penetração considerável de VEs no setor.

2.5 ESTRATÉGIAS PARA RECARGAS

2.5.1 TIPOS DE RECARGAS

Os veículos elétricos *plug-in* podem ser recarregados descoordenada ou coordenadamente. Na primeira, não existe nenhum controle sobre a taxa de recarga dos veículos elétricos. Assim, os mesmos começam a se recarregar imediatamente quando conectados ou após um tempo pré-determinado. Eles apenas cessam a recarga quando a bateria está totalmente preenchida ou o veículo é desconectado da rede. No segundo tipo de recarga, alguma estratégia que controla a recarga dos VEPs é aplicada.

Na recarga coordenada, pode-se limitar ou estabelecer a taxa de recarga do VEP, além de injetar potência ativa do mesmo na rede elétrica. O primeiro caso caracteriza-se pelo fluxo de potência unidirecional (da rede para o veículo). Já o segundo caso é caracterizado pelo fluxo de potência bidirecional (da rede para o veículo e vice-versa).

O fluxo de potência unidirecional apenas recarrega a bateria do VEP, possuindo um baixo custo de implementação. Com isso, a bateria não apresenta nenhuma degradação adicional por não se descarregar para a rede. Para esse tipo de fluxo, apenas uma conexão elétrica na rede é necessária. Dentre os principais benefícios, destacam-se a possibilidade de se aplicar um controle simples para a coordenação, o que propicia a mitigação dos impactos na rede, alcançado através da limitação da taxa de recarga.

O fluxo de potência bidirecional pode ser utilizado tanto para controlar a recarga como para suprir energia para a rede elétrica. Entretanto, ele envolve mais custos que o fluxo de potência anterior. Em adição, devido aos ciclos de descarga, a bateria sofre degradação extra. Além disso, para sua implantação, faz-se necessária comunicação bidirecional e medição inteligente. Dessa forma, este tipo de fluxo de potência permite prestar serviços auxiliares para a rede e apoio para entrada de fontes renováveis. A Tabela 1 relaciona alguns pontos de comparação entre os fluxos de potência unidirecional e bidirecional.

Além dos pontos abordados, as estratégias de recarga coordenada também podem ser descentralizadas ou centralizadas. Na recarga descentralizada ou distribuída, o proprietário do VEP decide quando irá recarregar a bateria. Já na recarga centralizada, uma entidade central reúne informações sobre a rede elétrica, a carga e a geração, estando apta para decidir e controlar a recarga ou descarga de um conjunto de VEPs. Conforme exposto por Waraich et al. (2013), ainda não é claro qual das duas abordagens implica em uma rede elétrica mais robusta, sendo que ambas podem ser combinadas em uma única estratégia.

Tabela 1 – Comparação entre fluxos de potência unidirecional e bidirecional.

	Fluxo de potência unidirecional	Fluxo de potência bidirecional
Fluxo de potência	<ul style="list-style-type: none"> • Fluxo de energia elétrica em uma direção • Apenas recarga da bateria 	<ul style="list-style-type: none"> • Fluxo de energia elétrica em duas direções • Recarga e descarga da bateria
Custo	<ul style="list-style-type: none"> • Baixo 	<ul style="list-style-type: none"> • Alto
Efeito na bateria	<ul style="list-style-type: none"> • Nenhuma degradação extra 	<ul style="list-style-type: none"> • Degradação extra da bateria devido à descarga
Sistema elétrico de distribuição	<ul style="list-style-type: none"> • Não precisa de investimento e modernização 	<ul style="list-style-type: none"> • Necessita investimento e modernização
Requisitos e desafios	<ul style="list-style-type: none"> • Conexão de energia na rede elétrica 	<ul style="list-style-type: none"> • Comunicação e conexão bidirecional de energia • Sensores e medição inteligente adequados • Troca de informação considerável • Custo e investimento extras • Perdas de energia • Stress dos dispositivos
Benefícios	<ul style="list-style-type: none"> • Simplifica problemas de interconexão • Controle simples e gerenciamento fácil • Fornece serviços baseados na potência reativa e ajuste dinâmico das taxas de recarga, mesmo sem fluxo inverso • Supre ou absorve energia reativa, sem ter que descarregar a bateria, através do controle de fase e ângulo da corrente 	<ul style="list-style-type: none"> • Serviços auxiliares • Regulação da potência ativa e estabilização de frequência e tensão • Reservas circulantes • Suporte para energia reativa • Corte de pico • Preenchimento de vale • Balanço de energia • Filtragem de harmônicas • Apoio para entrada de fontes renováveis

Fonte: Adaptado de Yilmaz e Krein (2013).

2.5.2 RECARGA DESCOORDENADA

A literatura específica não apresenta muitas estratégias para a recarga descoordenada. Isto acontece devido ao fato de que este tipo de recarga não resulta em benefícios expressivos para a rede elétrica. A recarga descoordenada é diretamente ditada pelos usuários, não sendo possível realizar uma coordenação e controle para atuar a favor do sistema elétrico de potência.

A recarga descoordenada mais comum acontece quando os VEPs começam a se recarregar imediatamente quando conectados na rede elétrica ou após um certo tempo de atraso ajustado pelo proprietário. No primeiro caso, o usuário não possui incentivo ou informações necessárias para realizar uma recarga favorável ao SEP. Já no segundo caso, ele possui informações e o tempo de atraso possibilita que o carregamento aconteça em períodos fora do pico. A recarga descoordenada acontece com frequência, pois os usuários

chegam em casa após o trabalho e conectam seus veículos para recarga (CLEMENT-NYNS; HAESSEN; DRIESEN, 2010).

Outra recarga descoordenada, mas que incentiva os donos dos VEPs, consiste na utilização de duas tarifas de energia elétrica. Uma tarifa mais cara é aplicada durante os períodos de pico e uma mais barata fora do horário de pico. Assim, assume-se que os usuários da tarifa dupla irão recarregar os veículos durante os períodos de baixa demanda onde o valor a ser pago pela energia é menor. No Brasil, a tarifa branca é a opção de incentivo aos consumidores para recarregar o VEP fora do horário de pico.

Enfatiza-se que, neste tipo de recarga, não existe um controle da taxa de recarga nem do fluxo de energia do veículo para a rede. Entretanto, os impactos podem ser mitigados através do incentivo de recarregar os VEPs fora do pico, utilizando tarifas de energia diferenciadas.

2.5.3 RECARGA COORDENADA

As pesquisas sobre as estratégias para o controle da recarga coordenada com fluxo de potência unidirecional têm crescido consideravelmente nos últimos anos. Dos trabalhos analisados, verificou-se que cada proposta compreende diferentes abordagens e suposições para solucionar o problema. Eles podem ser agrupados em termos do objetivo utilizado para formular o problema de otimização e do método de otimização aplicado para solucionar o problema.

Os principais objetivos adotados nas metodologias utilizadas para fluxo unidirecional na literatura especializada são apresentados na Tabela 2. Os métodos utilizados para a resolução dos problemas também são expostos.

Diversas pesquisas também buscam coordenar a recarga dos VEPs considerando o fluxo de potência bidirecional. Da mesma forma que o fluxo unidirecional, pode-se dividir os trabalhos conforme o objetivo da otimização e o método de otimização aplicado.

Os principais objetivos tratados pelos autores para o problema da recarga coordenada com fluxo de potência bidirecional e os métodos utilizados são apresentados na Tabela 3.

Na revisão bibliográfica das estratégias de recarga, verificou-se que não é considerada a vontade do proprietário do veículo em fornecer o mesmo para uma estratégia de recarga inteligente, levando em consideração apenas sua necessidade de disponibilidade do veículo após a recarga. Os trabalhos que consideram o interesse do usuário, limitam esta participação a apenas definir o horário de desconexão da rede elétrica. Outras metodologias exigem muita troca de informações, necessitando de uma comunicação extensiva, fato que pode não ser alcançado facilmente na rede elétrica atual. Verificou-se também que alguns trabalhos consideram as taxas de recarga constantes dos VEPs, o que pode dificultar o controle da recarga com muitos veículos. Por fim, certos métodos se mostraram computacionalmente complexos e custosos, inviabilizando sua aplicação em tempo real na

operação do SEP.

Tabela 2 – Objetivos e métodos da recarga coordenada para o fluxo de potência unidirecional.

Objetivo	Método	Referência
Minimizar perdas de energia	Programação quadrática e programação dinâmica	(CLEMENT-NYNS; HAESSEN; DRIESEN, 2010)
	Programação não-linear	(RAJABI; ESMAILI, 2014)
	Otimização por enxame de partículas discreta fuzzy e algoritmo genético fuzzy	(HAJFOROOSH; MASOUM; ISLAM, 2015)
	Otimização por enxame de partículas	Proposta deste trabalho
Regulação de frequência	Programação dinâmica	(HAN; HAN; SEZAKI, 2010)
Maximizar o lucro do agregador	Algoritmos heurísticos	(SORTOMME; EL-SHARKAWI, 2011)
	Programação linear fuzzy	(ANSARI et al., 2015)
Minimizar o custo da recarga	Otimização por enxame de partículas discreta fuzzy e algoritmo genético fuzzy	(HAJFOROOSH; MASOUM; ISLAM, 2015)
	Programação linear	(QIAN et al., 2011)
	Técnicas de busca e redes neurais	(PAPADOPOULOS et al., 2013)
	Programação evolucionária	(AHMAD; OTHMAN, 2014)
	Princípio mínimo de Pontryagin	(GENG; MILLS; SUN, 2013)
Reduzir os desvios de tensão	Sistemas artificiais imunes (AIS)	(OLIVEIRA; SOUZA; DELBONI, 2013)
Reduzir a sobrecarga da rede elétrica	Sistemas artificiais imunes (AIS)	(OLIVEIRA; SOUZA; DELBONI, 2013)
Minimizar o desvios entre a energia comprada no mercado e a energia consumida pelos VEPs	Programação linear	(SOARES; ALMEIDA; LOPES, 2014)
Prevenir o congestionamento da rede elétrica de distribuição	Programação linear	(HU et al., 2014)
Reduzir o pico de carga	Programação linear fuzzy	(ANSARI et al., 2015)
	Seleção otimizada	(GAN; TOPCU; LOW, 2013)
Maximizar a energia entregue aos VEPs	Otimização por enxame de partículas discreta fuzzy e algoritmo genético fuzzy	(HAJFOROOSH; MASOUM; ISLAM, 2015)

Fonte: Elaborado pelo autor.

Tabela 3 – Objetivos e métodos da recarga coordenada para o fluxo de potência bidirecional.

Objetivo da estratégia	Método utilizado	Referência
Minimizar os custos de energia	Programação sequencial quadrática	(WEIHAO et al., 2013)
	Programação quadrática inteira-mista	(BAI; QIAO, 2015)
	Algoritmo de busca por organismo auto adaptável modificado	(KAVOUSI-FARD et al., 2015)
Regulação de potência	Programação quadrática sequencial	(WEIHAO et al., 2013)
Melhorar a predição da geração de energia solar fotovoltaica	Otimização por enxame de partículas	(GHOFRANI; ARABALI; GHAYEKHLOO, 2014)
Maximizar a satisfação dos proprietários dos veículos	Programação não-linear	(SHAABAN et al., 2014)
Minimizar o custo operacional do SEP	Programação não-linear	(SHAABAN et al., 2014)
	Programação linear inteira-mista	(HADDADIAN et al., 2015)
Limitar as emissões de carbono	Programação linear inteira-mista	(HADDADIAN et al., 2015)
Minimizar o desbalanço de potência da rede elétrica	Programação linear inteira-mista	(NGUYEN; ZHANG; MAHMUD, 2015)
Reduzir o pico de consumo	Algoritmo próprio	(SINGH et al., 2015)
Aumentar a confiabilidade do sistema elétrico	Algoritmo de busca por organismo auto adaptável modificado	(KAVOUSI-FARD et al., 2015)
Regulação de frequência	Algoritmo próprio	(LIU et al., 2015)

Fonte: Elaborado pelo autor.

2.6 CONSIDERAÇÕES FINAIS

Neste Capítulo foram apresentados os impactos da recarga não coordenada dos VEPs e os benefícios que podem surgir se esta tecnologia for planejada e coordenadamente admitida. Ambas as abordagens justificam a necessidade de controlar a recarga dos VEPs.

O Capítulo também expôs os principais desafios que podem dificultar a ampla difusão dos VEPs e do conceito V2G.

Por fim, apresentaram-se algumas estratégias de controle da recarga dos VEPs. Os objetivos dos problemas e os métodos utilizados para resolver também foram listados. Além disso, um resumo das principais desvantagens das estratégias foi exposto. Este estudo das diferentes estratégias motivou a criação do sistema inteligente de controle da recarga de VEPs proposto.

Esta dissertação apresenta uma proposta com o objetivo de minimizar perdas de energia, utilizando o método de otimização por enxame de partículas (PSO). Como diferencial frente aos outros trabalhos, considera-se a vontade do proprietário em fornecer seu veículo para auxiliar a rede elétrica. Além disso, a taxa de recarga não é constante durante a recarga, conforme exposto em outros trabalhos encontrados na literatura especializada.

O Capítulo seguinte apresenta os conceitos básicos necessários para o entendimento da proposta desta Dissertação, como: o tipo de veículo elétrico considerado, o controlador lógico fuzzy projetado, os métodos de otimização aplicados e o método de auxílio à tomada de decisão utilizado.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 CONSIDERAÇÕES GERAIS

O presente Capítulo apresenta os conceitos fundamentais para o desenvolvimento desta Dissertação. Primeiramente, os principais tipos de veículos elétricos são apresentados. Na sequência, as etapas integrantes do controlador lógico fuzzy são definidas. Após, dois métodos de otimização são apresentados, algoritmo genético e otimização por enxame de partículas, respectivamente. Por fim, o método de tomada de decisão conhecido por AHP (do inglês *Analytic Hierarchy Process*) é exposto.

3.2 TECNOLOGIA DOS VEÍCULOS ELÉTRICOS

Os veículos elétricos (VEs) são propulsionados por motores elétricos, sendo estes alimentados pela energia elétrica armazenada em dispositivos como baterias e supercapacitores. De forma geral, eles podem ser classificados em três grupos distintos: à bateria (VEB), híbrido (VEH) e híbrido *plug-in* (VEHP). Uma classificação mais abrangente, denominada veículos elétricos *plug-in* (VEP), é comumente utilizada para englobar os VEBs e VEHPs, pois ambos necessitam conectar-se na rede elétrica para o processo de recarga.

Os veículos elétricos à bateria, também conhecidos como puramente elétricos, são movidos por motores elétricos que recebem energia elétrica armazenada em uma bateria. Ela é recarregada através da conexão na rede elétrica ou substituindo por outra já recarregada. Os VEHs combinam os veículos anteriores com veículos convencionais movidos a motores de combustão interna (MCI), sendo que o primeiro possibilita uma maior eficiência e economia do combustível, enquanto o último fornece uma maior autonomia. As baterias destes veículos são recarregadas por frenagem regenerativa e pelo motor a combustão.

Ressalta-se que os VEHPs possuem a mesma combinação dos motores elétrico e a combustão dos VEHs. Entretanto, a bateria pode ser recarregada na rede elétrica em adição à frenagem regenerativa e à recarga pelo motor à combustão (SALDANHA et al., 2016; CHAN, 1993; BASSO, 2011).

Em termos de consumo de energia, Brinkman et al. (2005) e Williamson e Emadi (2005) provaram que VEBs e VEHs proporcionam uma economia de combustível em relação aos veículos de combustão interna, incluindo o caso quando a energia elétrica é gerada através de recursos derivados do petróleo. Além disso, a utilização de VEBs e VEHs levam à redução da emissão de gases do efeito estufa. A Tabela 4 apresenta algumas comparações entre os VEB, VEH e VEHP, incluindo: o tipo de motor de propulsão que possuem, a forma de armazenamento de energia e a forma de abastecimento desta, os principais pontos que os diferenciam e os principais problemas enfrentados.

Tabela 4 – Principais comparações entre VEB, VEH e VEHP.

Características	VEB	VEH e VEHP
Propulsão	<ul style="list-style-type: none"> • Motores elétricos 	<ul style="list-style-type: none"> • Motores elétricos • Motores de combustão interna
Subsistema de armazenamento de energia	<ul style="list-style-type: none"> • Bateria • Supercapacitor 	<ul style="list-style-type: none"> • Bateria • Supercapacitor • Combustíveis fósseis ou alternativos
Fonte de energia e infraestrutura	<ul style="list-style-type: none"> • Pontos de recarga na rede elétrica 	<ul style="list-style-type: none"> • Postos de gasolina • Pontos de recarga na rede elétrica (para VEHP)
Principais observações	<ul style="list-style-type: none"> • Zero emissões locais • Alta eficiência energética • Independente de combustível fóssil <ul style="list-style-type: none"> • Autonomia relativamente curta • Alto custo inicial 	<ul style="list-style-type: none"> • Baixas emissões locais • Alta economia de combustível • Dependente de combustível fóssil • Maior autonomia • Maior custo que veículos de MCI
Principais problemas	<ul style="list-style-type: none"> • Capacidade de armazenamento da bateria • Pontos de recarga • Custo • Vida útil da bateria 	<ul style="list-style-type: none"> • Capacidade de armazenamento da bateria • Controle, otimização e gerenciamento de diversas fontes de energia

Fonte – Adaptado de Chan, Bouscayrol e Chen (2010).

Manz et al. (2014) mostram que os Estados Unidos da América (EUA) já subsidiam a compra de VEPs, os quais estão se tornando uma alternativa economicamente competitiva com os demais tipos de veículos, sendo que a frota de VEs vem crescendo consideravelmente na indústria automotiva. Ainda nos EUA, Duvall e Knipping (2007) preveem que, até o ano de 2020, 35% do total da frota de veículos será composta por VEPs. No Brasil, o estudo de Baran e Legey (2010) apresenta que a frota de automóveis continuará crescendo, tornando-se a quinta maior do mundo em 2030. Eles debatem que os VEs são uma opção interessante para o setor automotivo frente aos veículos utilizados atualmente. Entretanto, devido à recessão enfrentada pelo país em 2015, esta projeção deverá ser reestudada.

Assim, aliando os benefícios e prospecções citados anteriormente, os VEPs apresentam-se como uma nova tecnologia altamente promissora e com grande expectativa de exercer um papel fundamental nos setores elétrico e automobilístico nas próximas décadas. Entretanto, deve-se atentar para o fato de que o VEP pode atuar tanto como carga ou fonte de energia para o sistema elétrico de potência. O primeiro caso acontece quando o VEP está recarregando suas baterias, ou seja, consumindo energia da rede. Já o segundo caso pode acontecer com o veículo comunicando-se com a rede para atuar em seu benefício, seja fornecendo energia ativa ou controlando sua taxa de recarga. A este tipo de conceito denomina-se veículo-para-rede ou V2G (do inglês *vehicle-to-grid*).

Para a proposta apresentada nesta dissertação, considera-se o controle da recarga dos veículos elétricos plug-in, pois esta categoria compreende todos os veículos elétricos que necessitam se conectar para recarga, atuando como carga elétrica para o SEP. Além disso, leva-se em consideração o controle da taxa de recarga dos VEPs para mitigar o impacto no SEP. Isto é feito porque o VEP fornecendo energia para a rede elétrica ainda é um conceito distante de ser aplicado, pois a infraestrutura da rede elétrica deverá passar por mudanças bruscas, de modo a se adaptar a esta função (YILMAZ; KREIN, 2013).

Por fim, destaca-se que os parâmetros utilizados do VEP para a recarga são a capacidade de armazenamento de energia, o estado de carga, as taxas de recarga mínima e máxima.

3.3 CONTROLADOR LÓGICO FUZZY

O controlador lógico fuzzy é uma ferramenta que mapeia um espaço de entrada em um espaço de saída. Este mapeamento, também chamado de inferência, acontece quando se conhecem as entradas e as saídas de um sistema e a relação entre elas. Isto significa que se conhece qual saída é ativada para uma dada entrada. Com este conhecimento, a lógica fuzzy permite modelar o espaço de entrada para o espaço de saída. O mecanismo que realiza esta modelagem é uma lista de condições SE-ENTÃO, chamada de regras. Elas referenciam-se diretamente às variáveis e adjetivos que descrevem estas variáveis (REZNIK, 1997).

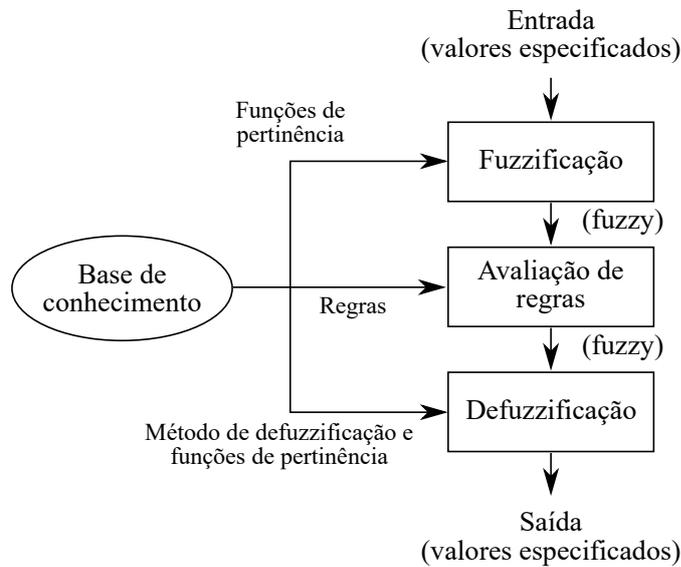
O processo geral de inferência de um controlador lógico fuzzy é apresentado na Figura 2. A base de conhecimento contém as funções de pertinência, o conjunto de regras e o método de defuzzificação.

A função de pertinência é uma curva responsável por representar uma entrada precisa em um certo degrau de pertinência de um dado conjunto fuzzy. Conforme explica Reznik (1997), algumas observações devem ser seguidas na escolha das funções de pertinência, visando garantir a eficiência do controlador fuzzy. Entre essas observações, destacam-se o número de funções para uma certa variável, a posição das funções no plano cartesiano, os comprimentos e suas formas. Entretanto, sabendo que estas observações devem ser feitas, somente a experiência profissional e o senso comum ditarão uma escolha sábia.

Destaca-se que, para os processos de fuzzificação e defuzzificação, utilizam-se funções de pertinência. Vale ressaltar ainda que o primeiro processo, converte o valor preciso de uma determinada variável de entrada para um valor fuzzy. Já o segundo, realiza o contrário, convertendo um conjunto fuzzy em uma quantidade escalar. Para a defuzzificação, os métodos mais utilizados são: centroide, bissetor, SOM (menor do máximo, do inglês *smallest-of-maximum*), MOM (meio do máximo, do inglês *middle-of-maximum*) e LOM (maior do máximo, do inglês *largest-of-maximum*).

O último componente principal de um controlador fuzzy é a lista de regras, a qual

Figura 2 – Descrição geral de um sistema de inferência fuzzy.



Fonte: Adaptado de Simões e Shaw (2007).

é feita através de condições do tipo “**SE** x é A **ENTÃO** y é B ”, com A e B sendo variáveis linguísticas definidas por conjuntos fuzzy dentro dos domínios X e Y , respectivamente. Uma regra deste tipo representa uma inferência de um fato conhecido (o antecedente, premissa ou hipótese) inferindo, ou assimilando, um fato totalmente novo (o conseqüente). Este tipo de representação expressa o raciocínio humano na sua própria linguagem de comunicação, facilitando a incorporação do conhecimento na modelagem de um sistema complexo. Com dois antecedentes a regra passa a ter a forma “**SE** x é A **E** y é B **ENTÃO** z é C ”.

Uma descrição detalhada do processo de inferência de um controlador lógico fuzzy pode ser obtida em MathWorks (2017).

O controlador lógico fuzzy utilizado na metodologia proposta foi utilizado para gerar os valores iniciais das taxas de recarga dos VEPs. Este leva em consideração os dados inseridos pelos consumidores e as informações dos veículos no início do processo de recarga.

3.4 ALGORITMO GENÉTICO

O algoritmo genético (AG) é um método de otimização baseado nos princípios da genética e seleção natural. O procedimento da busca genética realizada pelo algoritmo é fundamentado nos elementos de reprodução, recombinação e mutação (RAO, 2009).

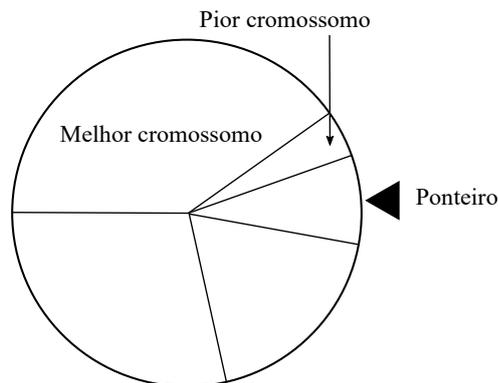
Cada variável de projeto no AG é representada por uma string de números binários (0 e 1). A conversão de um valor decimal da variável de projeto para a representação binária é chamada de codificação binária. Com todas as variáveis no formato binário,

concatenam-se elas em um único vetor para formar um cromossomo. Uma população inicial é então gerada com um determinado número de cromossomos. Gerada a população inicial, o AG cria a próxima geração utilizando os operadores de reprodução, recombinação e mutação.

Nesse contexto, a reprodução é o processo no qual os cromossomos mais aptos da população (boas soluções para o ajuste do controlador fuzzy) possuem elevadas probabilidades de fornecer várias cópias na próxima geração. Conforme cita Rao (2009), com este processo aumenta-se a qualidade dos cromossomos na próxima geração levando, conseqüentemente, a melhores soluções do problema de otimização.

Sendo assim, a inicialização da reprodução consiste em selecionar os pais da população atual. Esta seleção é feita com uma roleta, onde cada cromossomo na população possui uma parcela de tamanho proporcional ao seu valor de aptidão, conforme Figura 3. A cada vez que uma cópia é requisitada, a roleta é girada para selecionar o pai. O cromossomo que parar no ponteiro da roleta será o pai selecionado para ser copiado. A roleta é girada n_p vezes, onde n_p é o tamanho da população.

Figura 3 – Roleta para seleção dos pais.



Fonte: Adaptado de Gurocak (1999).

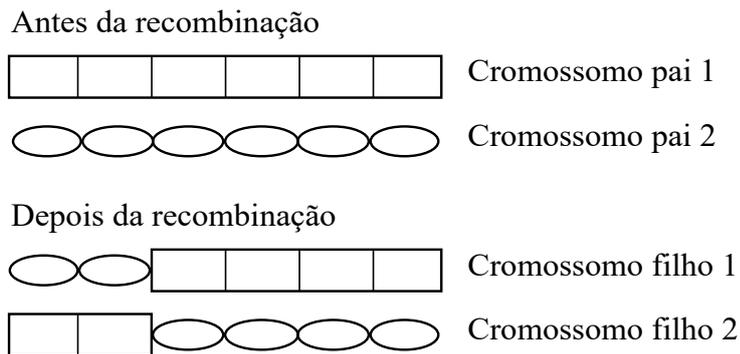
Se a otimização objetiva minimizar um dado problema, a roleta é construída de tal forma que o cromossomo com o menor valor da função objetivo (o cromossomo mais apto) possua a maior parcela da roleta. Assim, aumenta-se a chance deste cromossomo se reproduzir. O valor da probabilidade do cromossomo para o caso de minimização é calculado de acordo com a Equação (3.1).

$$p_i = \frac{f_{min}/f_i}{\sum_{i=1}^{n_p} \frac{f_{min}}{f_i}} \quad (3.1)$$

Em (3.1), f_{min} é o menor valor de aptidão na população, f_i é o valor de aptidão do cromossomo i , n_p é o tamanho da população e p_i é a probabilidade atribuída para o cromossomo i (maior parcela da roleta).

Realizada a etapa de seleção de bons pais, entra em operação a recombinação. Nela, os cromossomos trocam informações entre si. O operador utiliza dois dos cromossomos pais selecionados e troca partes deles em um local selecionado aleatoriamente. A Figura 4 ilustra um exemplo de recombinação. Com este operador, permite-se que os cromossomos possam se misturar e combinar qualidades desejadas na formação de filhos. Após isto, os filhos são colocados de volta na população substituindo os cromossomos menos aptos.

Figura 4 – Operação de recombinação.



Fonte: Adaptado de Gurocak (1999).

A evolução da geração atual é completada pelo terceiro operador de mutação. Este operador inverte um dos bits do cromossomo em um local selecionado aleatoriamente. A mutação provoca pequenas perturbações em uma solução (visando evitar mínimos locais), aleatoriamente invertendo um de seus bits. Entretanto, a mutação só ocorre com uma pequena probabilidade (RAO, 2009).

Dessa forma, a próxima geração é composta por alguns cromossomos da geração anterior, cromossomos filhos e algumas perturbações em toda a população, devido à mutação, caso ela tenha ocorrido. A evolução da população termina após um número pré-definido de gerações. O cromossomo com o menor valor de aptidão contém os valores otimizados das variáveis de projeto. A *string* de zeros e uns resultante é decodificada para se obter os valores equivalentes em decimal das variáveis.

O algoritmo genético foi utilizado nesta proposta para ajustar o controlador lógico fuzzy inicialmente projetado, o qual busca otimizar a recarga dos VEPs de acordo com a necessidade informada pelos consumidores.

3.5 OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS

A otimização por enxame de partículas (PSO, do inglês *particle swarm optimization*) é um método de otimização baseado no comportamento de uma colônia ou enxame de insetos, de um bando de pássaros ou de um cardume de peixes. O PSO simula o comportamento destes organismos. Cada indivíduo ou partícula em um enxame se comporta

de uma forma distribuída utilizando sua própria inteligência e a inteligência coletiva do enxame. Dessa forma, se uma partícula encontra um caminho bom para a comida, o resto do enxame irá seguir este caminho (BANKS; VINCENT; ANYAKOHA, 2007).

Na otimização, o enxame é composto por um número determinado de partículas. Cada partícula é inicialmente localizada em uma posição aleatória no espaço de busca multidimensional. Além disso, cada uma possui duas características: posição e velocidade. Cada partícula se desloca pelo espaço de busca e armazena a melhor posição encontrada (com relação à função objetivo do problema). As partículas comunicam-se entre si repassando as boas posições, ajustando suas posições individuais e respectivas velocidades baseando-se nas informações recebidas (RAO, 2009).

De acordo com Rao (2009), a implementação computacional do PSO, considerando um problema de minimização sem restrições, possui os seguintes passos:

1. Definir o número de partículas do enxame;
2. Inicializar aleatoriamente a posição de cada partícula dentro de seus limites inferior e superior;
3. Inicializar as velocidades aleatoriamente ou defini-las como zero;
4. Para cada partícula:
 - a) Calcular o valor da função objetivo (valor de aptidão);
 - b) Se o valor de aptidão calculado é menor que o melhor valor de aptidão na história da partícula (**pBest**), definir o valor atual como o novo **pBest**;
5. Escolher a partícula com o menor valor de aptidão de todas as partículas como o **gBest** (melhor valor do enxame);
6. Para cada partícula:
 - a) Calcular a velocidade da partícula de acordo com a Equação (3.2). Caso a velocidade calculada seja maior que a velocidade máxima, definir velocidade como o valor máximo;

$$\mathbf{V}_{j+1} = \mathbf{V}_j + c1 \cdot rand() \cdot [\mathbf{X}_{pBest,j} - \mathbf{X}_j] + c2 \cdot rand() \cdot [\mathbf{X}_{gBest} - \mathbf{X}_j] \quad (3.2)$$

Onde: \mathbf{V}_{j+1} é a nova velocidade da partícula j , \mathbf{V}_j é a velocidade atual da partícula j , \mathbf{X}_j é a posição atual da partícula j , $rand()$ é uma função que retorna um único número randômico uniformemente distribuído no intervalo $(0, 1)$, $\mathbf{X}_{pBest,j}$ é a posição do melhor valor de aptidão na história da partícula j , \mathbf{X}_{gBest} é a posição do melhor valor de aptidão de todas as partículas e $c1$ e $c2$ são os componentes cognitivo e social, respectivamente.

b) Atualizar a posição da partícula de acordo com a Equação (3.3);

$$\mathbf{X}_{j+1} = \mathbf{X}_j + \mathbf{V}_{j+1} \quad (3.3)$$

Onde: \mathbf{X}_{j+1} é a nova posição da partícula j .

7. Se o critério de parada não foi atingido, voltar ao passo 4.

Assim como o AG, o PSO foi utilizado na metodologia proposta para ajustar o controlador lógico fuzzy inicialmente projetado, também visando otimizar a recarga dos VEPs. Os dois métodos de otimização foram aplicados separadamente e, na sequência, comparados para verificar qual apresentou o melhor desempenho. Em adição, o PSO também foi aplicado no COD para o gerenciamento de diversas frotas de VEP.

3.6 ANALYTIC HIERARCHY PROCESS

O AHP é um método de auxílio para a tomada de decisões quando múltiplos critérios devem ser atendidos concomitantemente. Na modelagem do problema, este método leva em consideração a opinião de especialistas para definir o grau de importância de cada critério considerado. Dessa forma, o método AHP é uma ferramenta que maximiza o grau de confiabilidade dos julgamentos. Isto é possível porque permite fazer uma comparação par a par, definindo o quanto um critério é melhor do que o outro (WOLFF, 2008).

Visando guiar o especialista no julgamento de cada par de critérios, uma escala de intensidade é utilizada. Esta escala converte uma opinião verbalizada em um valor numérico. A Tabela 5 representa a escala que realiza esta conversão, a partir da qual é possível determinar o quão relevante uma característica é sobre a outra, inferindo o grau de relevância de cada um deles.

Com a comparação par a par de todos os critérios, uma matriz com os julgamentos estabelecidos é criada, chamada de matriz de comparações (matriz A). A construção desta matriz é feita da seguinte forma:

1. Cada linha e cada coluna são representadas por um critério. Ou seja, a linha 1 e a coluna 1 da matriz são definidas pelo mesmo critério;
2. a_{ij} é o elemento da linha i e da coluna j da matriz de comparações A . O valor de a_{ij} é obtido através da comparação do critério da linha i (C_i) com o critério da coluna j (C_j);
3. Os valores de a_{ij} podem ser:
 - a) w_{ij} , se C_i é mais importante, ou seja, domina, C_j ;
 - b) $1/w_{ij}$, se C_j domina C_i ;

Tabela 5 – Escala numérica para comparações e julgamentos.

Escala numérica	Intensidade de importância
1	Mesma importância
2	Fraca ou leve
3	Importância moderada
4	Mais moderada
5	Forte importância
6	Mais forte
7	Muito forte
8	Muito, muito importante
9	Extremamente importante

Fonte: Adaptado de Silva (2011).

c) 1, se nenhum domina o outro.

Onde w_{ij} é o valor atribuído à comparação do critério da linha i com o critério da coluna j na comparação par a par, C_i é o critério da linha i da matriz A e C_j é o critério da coluna j da matriz A .

A matriz A , com n critérios, ficará da forma apresentada na Equação (3.4). Observa-se que esta é uma matriz quadrada, com os elementos inferiores à diagonal principal correspondentes ao inverso dos elementos superiores a diagonal principal.

$$A = \begin{matrix} & C_1 & C_2 & \cdots & C_n \\ \begin{matrix} C_1 \\ C_2 \\ \vdots \\ C_n \end{matrix} & \begin{bmatrix} 1 & a_{12} & \cdots & a_{1n} \\ 1/a_{12} & 1 & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 1/a_{1n} & 1/a_{2n} & \cdots & 1 \end{bmatrix} \end{matrix} \quad (3.4)$$

O método AHP consiste em encontrar, utilizando a matriz A , os pesos que representam o grau de importância de cada critério. Das diversas metodologias propostas para o cálculo, as de Wang et al. (2008) e Pamplona (1999) têm sido bastante utilizadas, onde os pesos são definidos pela Equação (3.5).

$$p_k = \frac{\left(\prod_{j=1}^n a_{kj} \right)^{1/n}}{\sum_{k=1}^n \left(\prod_{j=1}^n a_{kj} \right)^{1/n}} \quad (3.5)$$

Em (3.5), p_k é o peso do critério k . Com os valores dos pesos, pode-se criar uma hierarquia de importância dos critérios. O critério com o maior peso é o mais importante e o critério com o menor peso é o menos importante (WOLFF, 2008).

Além disso, em busca de medir a inconsistência das medidas dos julgamentos, o AHP utiliza um método matemático, o qual define o índice de consistência (IC) da matriz A através da Equação (3.6).

$$IC = \frac{\lambda_{m\acute{a}x} - n}{n - 1} \quad (3.6)$$

Em (3.6), IC é o índice de consistência, n é o número de critérios e $\lambda_{m\acute{a}x}$ é o valor máximo dos autovalores correspondentes a cada critério, podendo ser encontrado com a Equação (3.7).

$$\lambda_{m\acute{a}x} = \max_{k=1,2,\dots,n} \left[\frac{\sum_{j=1}^n (a_{kj} \cdot p_j)}{p_k} \right] \quad (3.7)$$

O índice de consistência IC mede a distância entre o máximo autovalor da matriz de julgamentos e o autovalor de uma matriz perfeitamente consistente. Conforme indica Saaty e Tran (2007), IC é sempre maior ou igual a zero para uma matriz recíproca positiva, pois $\lambda_{max} \geq n$.

Caso os julgamentos realizados sejam perfeitos, então o máximo autovalor é igual ao número de critérios n ($\lambda_{max} = n$) (ALONSO; LAMATA, 2006). Nesta situação, o índice de consistência IC é zero, indicando que a matriz de comparações A é igual a matriz de consistência.

Entretanto, caso os julgamentos não sejam perfeitos, o máximo autovalor é sempre maior que n . Com isto, a diferença no numerador de (3.5) é igual a soma dos autovalores restantes (AUPETIT; GENEST, 1993). Isto implica que quanto menor a diferença, mais consistente será a matriz de julgamentos.

Conforme apresentado, o índice IC reflete o quanto a matriz de comparações A se distancia de uma matriz de consistência. Entretanto, ainda não relaciona o nível de dificuldade da construção dos julgamentos conforme o número de critérios aumenta. Dessa forma, utiliza-se a razão de consistência RC para considerar a dificuldade das comparações em relação ao número de critérios. A variável RC é dada pela Equação (3.8).

$$RC = \frac{IC}{IR} \quad (3.8)$$

Em (3.8), IR é o índice randômico de consistência, definido de acordo com a Tabela 6.

Para julgar se a matriz A é consistente, compara-se o valor obtido de RC com o valor máximo definido na Tabela 7, de acordo com o número de critérios n . Uma matriz inconsistente deve ter seus julgamentos reavaliados para adequá-la.

Tabela 6 – Relação do número de critério com o índice randômico.

Quantidade de critérios	Valor de IR
1	0,00
2	0,00
3	0,52
4	0,89
5	1,11
6	1,25
7	1,35
8	1,40
9	1,45
10	1,49
11	1,52
12	1,54
13	1,56
14	1,58
15	1,58

Fonte: Adaptado de Silva (2011).

Tabela 7 – Relação do número de critérios com o valor máximo de RC .

Quantidade de critérios	RC máximo
1	0,00
2	0,00
3	0,05
4	0,08
5 a 15	0,10

Fonte: Adaptado de Silva (2011).

Na tomada de decisões, cada alternativa possui uma pontuação em cada critério. Assim, o método AHP utiliza os pesos p_k para calcular o quanto cada alternativa pontua. A alternativa com a maior pontuação representa a melhor decisão (WOLFF, 2008).

Para a aplicação proposta neste trabalho, utiliza-se apenas o grau de importância de cada critério, ou seja, os pesos p_k . Estes pesos definem a potência mínima a ser enviada para uma frota de VEPs de acordo com as prioridades de recarga.

3.7 CONSIDERAÇÕES FINAIS

Neste Capítulo, as principais características dos diferentes veículos elétricos foram descritas. Além disso, apresentaram-se as projeções de crescimento das frotas e os benefícios que motivam a ampla difusão dos VEPs. Na sequência, as principais interfaces de um sistema de inferência fuzzy foram expostas, seguidas da apresentação dos conceitos básicos de dois métodos de otimização: o algoritmo genético e a otimização por enxame de partículas. Por fim, o método de auxílio à tomada de decisões AHP foi descrito, expondo o passo-a-passo da sua operação.

Todos os conceitos vistos neste Capítulo foram apresentados de tal forma a fornecer conhecimentos básicos para o entendimento da proposta desta Dissertação.

No Capítulo seguinte é apresentada uma nova metodologia para o controle inteligente da recarga de veículos elétricos *plug-in*. Propõe-se uma metodologia que visa beneficiar a concessionária de energia elétrica, o sistema elétrico de potência e o consumidor. Para tal metodologia proposta, utilizam-se os conceitos fundamentais apresentados neste Capítulo.

4 PROPOSTA PARA O CONTROLE INTELIGENTE DA RECARGA DE VEPS

4.1 CONSIDERAÇÕES GERAIS

Na revisão bibliográfica realizada, verificou-se que diversos trabalhos não consideram a vontade do proprietário do VEP em fornecer o mesmo para uma estratégia de recarga inteligente, levando em consideração somente a necessidade do veículo após a recarga. Os trabalhos que consideram o interesse do proprietário levam em conta apenas a hora que o veículo será desconectado. Sendo assim, este trabalho assume a variável prioridade como sendo de suma importância para o sistema. A prioridade é considerada importante levando em conta um cenário em que o consumidor poderá receber algum incentivo da concessionária para disponibilizar seu VEP para auxiliar a rede elétrica. Dessa forma, se ele optar, por exemplo, por ter um desconto na sua fatura de energia elétrica, pode definir uma prioridade baixa para a recarga de seu VEP.

Considerando as duas abordagens de recarga coordenada centralizada e descentralizada apresentadas anteriormente, o presente trabalho propõe uma combinação dos dois conceitos. A abordagem centralizada é considerada pelo fato do agregador reunir as informações sobre a rede, carga e geração, além de enviar comandos para cada VEP. Já a segunda abordagem é levada em conta pelo fato de incluir a vontade do proprietário do VEP em ter sua bateria totalmente recarregada.

O fluxo de potência unidirecional foi verificado como sendo o mais viável quando considerada a degradação da bateria, sendo este considerado neste trabalho. Além disso, a implementação do fluxo bidirecional está mais distante do que o unidirecional, dado o fato de que a rede deverá passar por melhorias, assim como o mercado elétrico terá que passar por adaptações.

Nesse contexto, o presente Capítulo propõe uma metodologia para o controle inteligente da recarga de VEPs, levando em consideração a prioridade do consumidor e visando o benefício da rede elétrica.

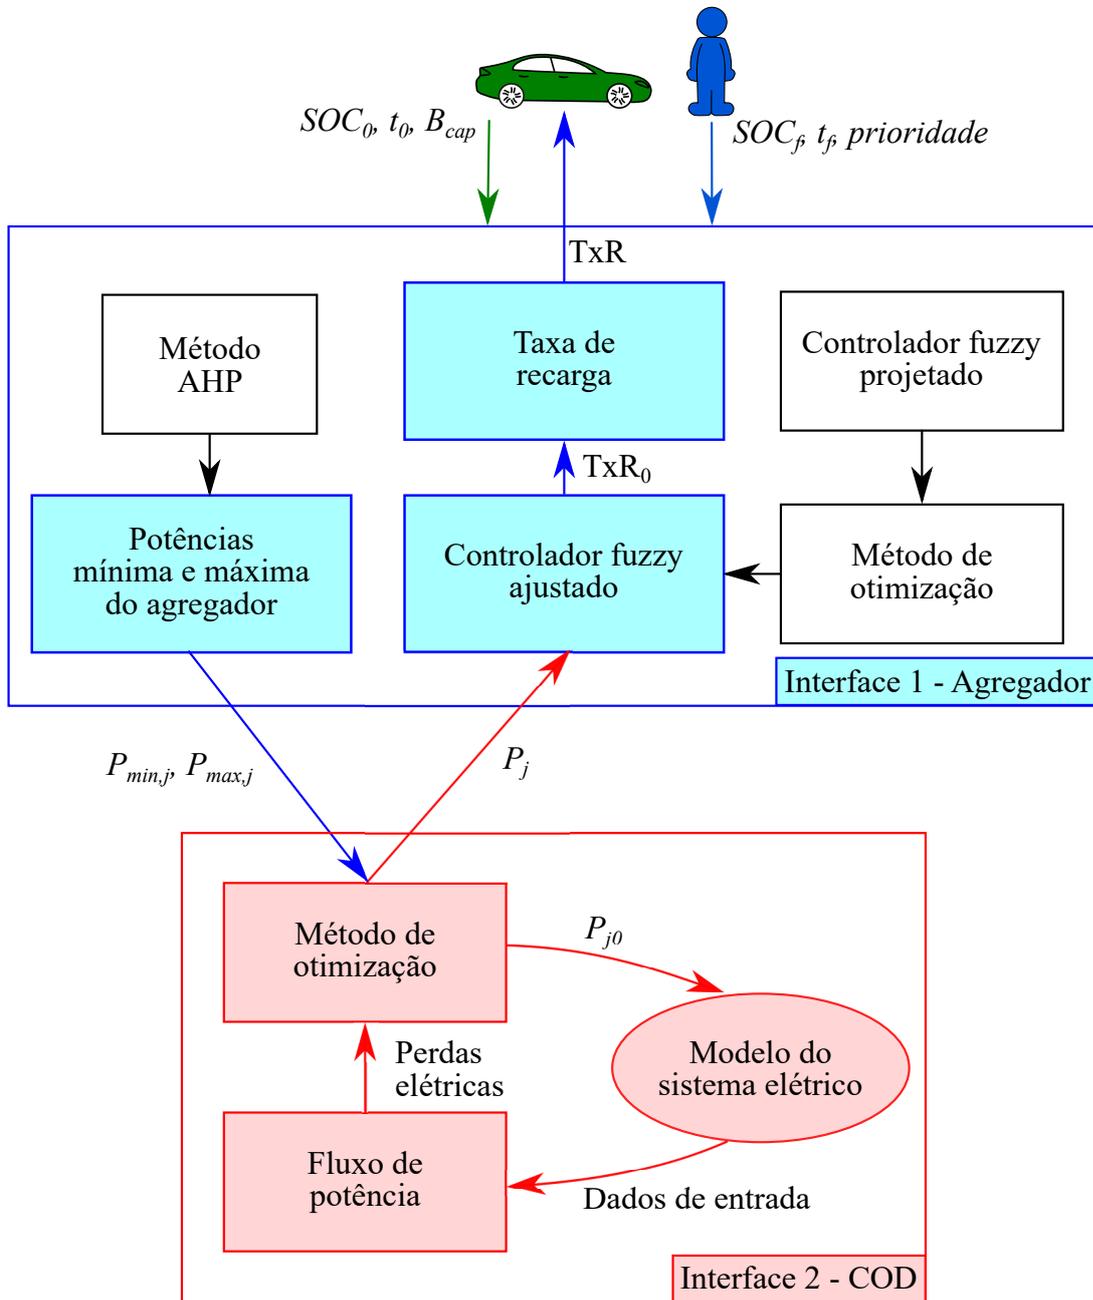
4.2 ESTRUTURA GERAL DA PROPOSTA

A metodologia proposta possui duas interfaces: o agregador e o centro de operação da distribuição (COD). O agregador é responsável por reunir informações dos VEPs e dos consumidores, o qual recebe um valor de potência do COD para distribuir entre os veículos, buscando atender as prioridades inseridas. Já o COD, atua visando cumprir as exigências de todos os agregadores sob seu comando, determinando valores de potência para cada agregador, de modo a otimizar a operação da rede elétrica.

Para o entendimento da proposta desta Dissertação, expõem-se as Figuras 5 e 6. Na Figura 5, apresenta-se o esquema geral da proposta para o controle inteligente da recarga dos VEPs. Neste esquema, ilustra-se a troca de informações entre o COD e um agregador. O fluxograma da Figura 6 apresenta o passo-a-passo da troca de dados entre

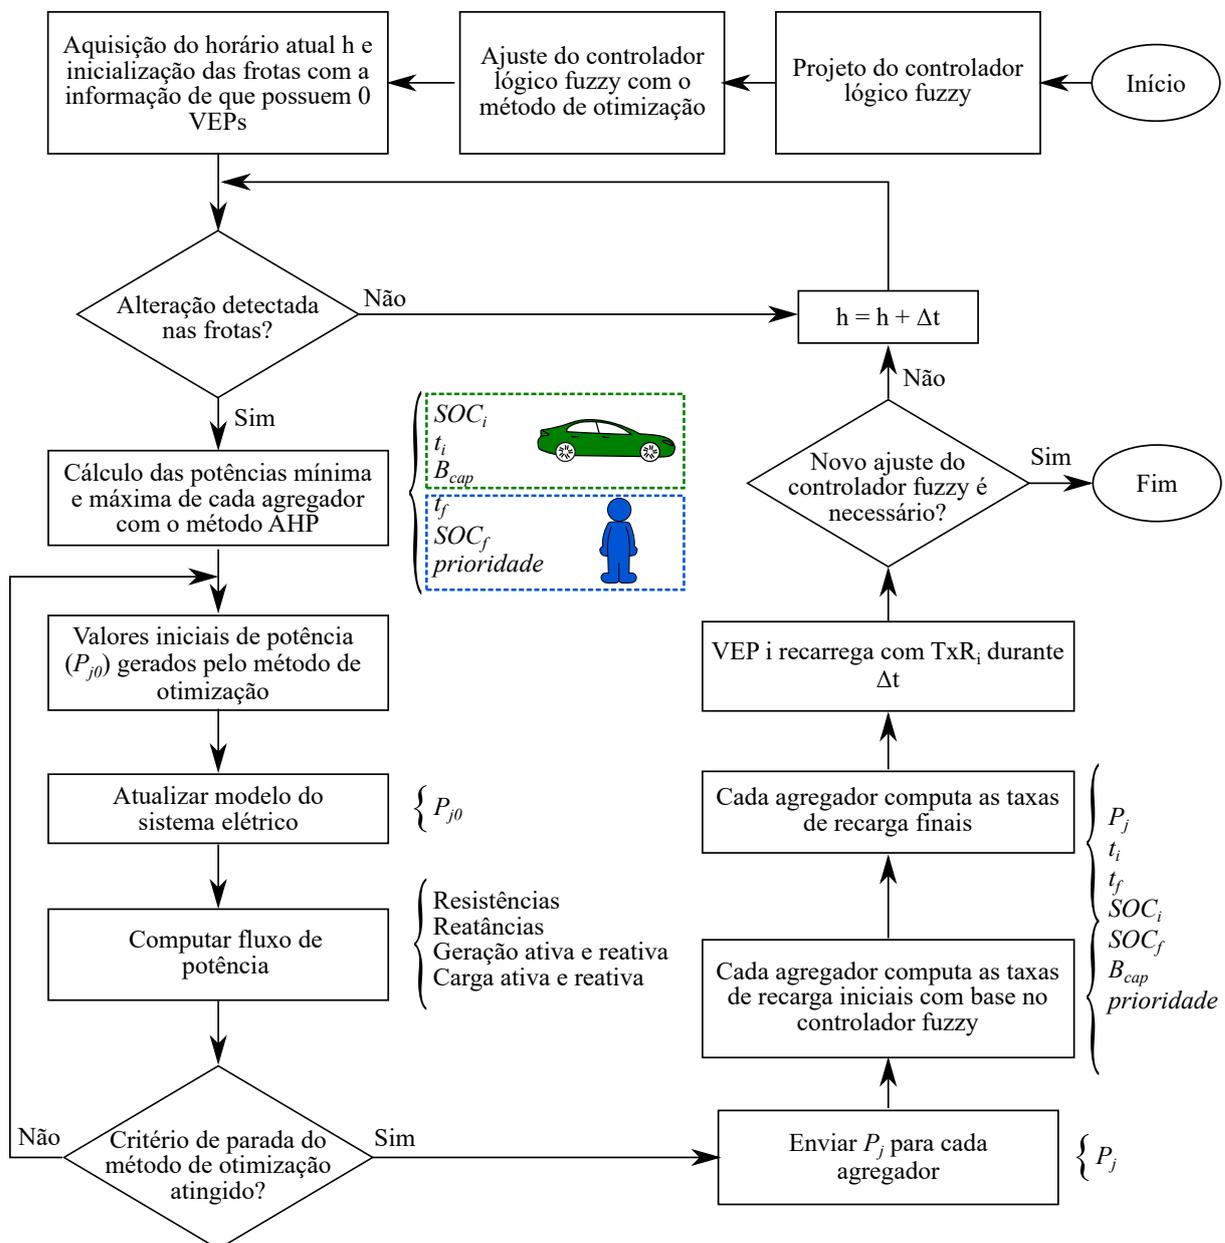
um COD e vários agregadores.

Figura 5 – Arquitetura da proposta para o controle inteligente da recarga de VEPs.



Legenda: TxR - Taxa de recarga; TxR_0 - Taxa de recarga inicial; SOC_0 - Estado de carga inicial; SOC_f - Estado de carga final; t_0 - Hora da conexão do VEP; t_f - Hora da desconexão do VEP; B_{cap} - Capacidade da bateria do VEP; $P_{min,j}$ - Potência mínima do agregador j ; $P_{max,j}$ - Potência máxima do agregador j ; P_{j0} - Potência atribuída para o agregador j durante o processo de otimização; P_j - Potência atribuída para o agregador j no final do processo de otimização.

Figura 6 – Funcionamento geral da proposta para o controle inteligente da recarga de VEPs.



Fonte: Elaborado pelo autor.

O primeiro passo consiste no projeto de um controlador lógico para cada agregador. Cada controlador atuará no controle posterior da taxa de recarga de cada veículo elétrico *plug-in*. O projeto do controlador é realizado por um especialista no assunto. Ele deve considerar os possíveis valores das variáveis de entrada e quais os valores que a variável de saída deve assumir para cada condição.

Após, o projetista define qual é a saída desejada que o controlador deveria retornar.

Com a saída desejada e a saída da inferência do controlador fuzzy projetado, um método de otimização é utilizado para ajustar a base de conhecimento do controlador. A otimização busca aproximar a saída da inferência do controlador fuzzy com a saída desejada informada pelo projetista. Com o controlador fuzzy otimizado, o processo de recarga dos VEPs é começado.

Com o controlador fuzzy ajustado, o sistema adquire o horário atual h e inicializa as frotas com a informação de que elas não possuem nenhum VEP requisitando recarga. A primeira informação é necessária para manter o controle da simulação e efetuar o registro de dados ao longo do tempo. Já a inicialização das frotas é realizada para que o algoritmo detecte a inserção de n VEPs no primeiro intervalo de tempo, entrando, conseqüentemente, no laço principal.

A cada instante de tempo Δt , o sistema verifica se alguma alteração nas frotas foi detectada. Caso nenhuma mudança ocorra, o algoritmo somente incrementa o horário h . Este processo é repetido até que alguma alteração aconteça. Caso alguma mudança ocorra, executam-se o gerenciamento das potências das frotas e a recarga dos VEPs. Ao final, o horário h é incrementado em Δt e testa-se, novamente, se ocorreu alguma alteração nas frotas.

As alterações monitoradas são: inserção de algum VEP requisitando recarga; desconexão de algum VEP, tanto antes quanto após o horário final de recarga; variação no SOC de algum VEP em relação ao instante de tempo anterior e; variação no período de conexão de algum VEP para a recarga.

Logo que conectado na rede elétrica para a recarga, o VEP i comunica ao agregador os seguintes dados: 1) o estado de carga inicial (SOC_0), indicando a porcentagem de carga que a bateria possui no começo da recarga; 2) o horário inicial da recarga (t_0), representando o horário que foi conectado para a recarga e; 3) a capacidade da bateria (B_{cap}), ou seja, a capacidade de energia que a bateria pode armazenar.

Também no momento da conexão, o proprietário do veículo informa três dados para o agregador: 1) o estado de carga final (SOC_f) desejado para a recarga da bateria; 2) o horário em que o veículo será desconectado da rede elétrica (t_f) e; 3) a prioridade na qual deseja que a bateria seja recarregada até o estado de carga final, durante o período de conexão à rede elétrica.

Recebidos os valores das seis variáveis de todos os VEPs, o agregador determina um intervalo de potências mínima e máxima ($P_{min,j}$) e ($P_{max,j}$), respectivamente, para o agregador j . Este intervalo visa informar ao COD um valor de potência adequado a ser repassado para o agregador. A potência mínima é o valor que ele deve receber para atender uma porcentagem mínima das recargas no tempo de conexão dos VEPs à rede elétrica. Já a potência máxima é o valor a ser recebido pelo agregador para recarregar todos os veículos no tempo de recarga.

Com os intervalos de potência de cada agregador j , o COD determina um valor de

potência otimizado para cada agregador. Os valores de potência otimizados são calculados pelo método de otimização implementado na interface COD. Para esta otimização, o COD também possui informações sobre o sistema elétrico sob estudo.

Cada agregador recebe então, o valor de potência otimizado calculado pelo COD. Este valor é utilizado para calcular as taxas de recarga de cada VEP. É a partir do controlador lógico fuzzy com a base de conhecimento ajustada que as taxas de recarga são determinadas pelo agregador. Os VEPs são então recarregados com a taxa de recarga calculada durante o intervalo Δt .

O cálculo dos intervalos de potência, o gerenciamento das potências dos agregadores e o cálculo das taxas de recarga são executados a cada intervalo Δt e enquanto existirem VEPs a serem recarregados.

Caso a base de conhecimento do controlador fuzzy necessite ser reajustada para uma nova saída desejada, o fluxograma da Figura 6 é iniciado novamente. Ou seja, projeta-se o controlador fuzzy (ou carrega-se o controlador projetado anteriormente) e então o mesmo é otimizado com a nova saída desejada. Na sequência, as potências mínima e máxima são calculadas, o COD gerencia os agregadores e as taxas de recarga são determinadas enquanto existirem VEPs a serem recarregados.

4.3 CONTROLE DA RECARGA DOS VEPS

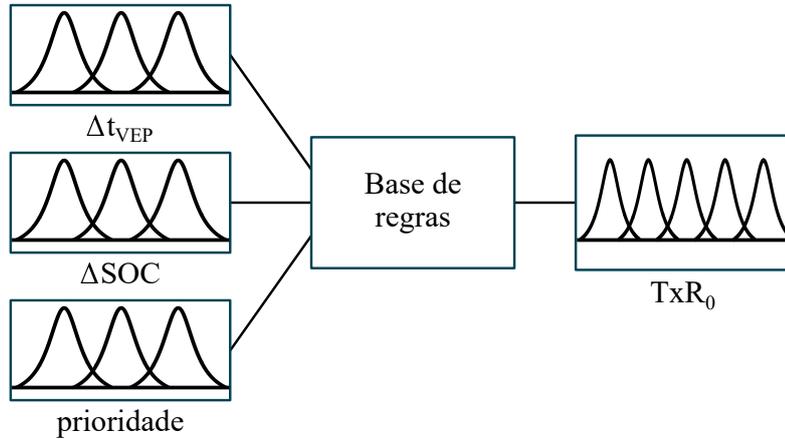
4.3.1 PROJETO DO CONTROLADOR LÓGICO FUZZY

O controlador lógico fuzzy apresenta-se como uma ferramenta eficaz para incorporar o conhecimento humano na resolução de um problema, sendo ele complexo ou não (ROSS, 2010). Dessa forma, ele foi escolhido para compor o núcleo do controle da recarga proposto, dado que a prioridade inserida pelo consumidor passa a ser parte do sistema. Uma abordagem geral dos sistemas de inferência fuzzy foram apresentados no Capítulo 3.

O controlador lógico fuzzy projetado possui a estrutura apresentada na Figura 7. As três variáveis de entrada são: o período que o VEP ficará conectado para a recarga (Δt_{VEP}); a porcentagem do estado de carga da bateria que precisa ser recarregada (ΔSOC) e a prioridade definida pelo consumidor (prioridade). A saída do controlador é a taxa de recarga inicial (TxR_0). Ambas as variáveis prioridade e TxR_0 foram definidas no intervalo de $[0, 1]$. Já a região de interesse de ΔSOC é estabelecida entre 0 e 100%, incluindo ambos os limites. Por fim, $\Delta t_{VEP} \in [0, 24]$ horas.

A variável de entrada do período de conexão para a recarga, Δt_{VEP} , foi representada por três conjuntos fuzzy: pouco, médio e alto. A função de pertinência de entrada ΔSOC , que representa a porcentagem da bateria a ser recarregada, foi dividida em três conjuntos fuzzy: baixa, média e alta. A terceira variável de entrada, prioridade, foi definida com três conjuntos fuzzy: não, talvez e sim. Por último, a variável de saída da taxa de recarga inicial, TxR_0 , foi dividida em cinco conjuntos fuzzy: zero, baixa, média, média-alta

Figura 7 – Arquitetura do controlador lógico fuzzy para a aplicação.



Fonte: Elaborado pelo autor.

e alta.

Cada conjunto fuzzy foi representado pela função de pertinência expressa na Equação (4.1). Esta função é definida pelos parâmetros a , b e x_0 , onde: a e b são constantes que controlam a abertura do conjunto fuzzy e x_0 é a localização do pico. Dessa forma, a função de pertinência permite o deslocamento do conjunto fuzzy no seu domínio modificando o valor de x_0 , facilitando o ajuste do controlador lógico fuzzy.

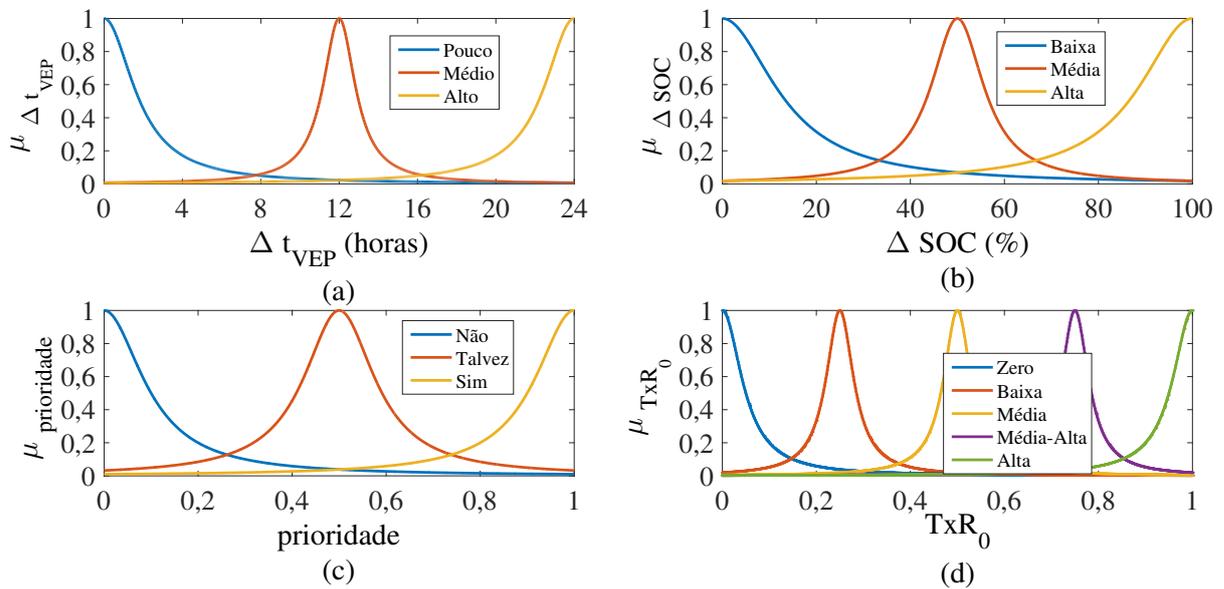
$$\mu(x) = \frac{a}{a + b(x - x_0)^2} \quad (4.1)$$

Após testes, obtiveram-se as disposições dos conjuntos fuzzy apresentadas na Figura 8. Os parâmetros definidos empiricamente que geraram as curvas para cada conjunto são apresentados na Tabela 8.

As regras que relacionam as variáveis de entradas com a variável de saída do controlador fuzzy são apresentadas na Tabela 9. A base de regras foi montada de forma a retornar uma taxa de recarga alta para o VEP com pouco tempo para recarga, alto ΔSOC e com alta prioridade de recarga. Por exemplo, se o VEP irá ficar pouco tempo para recarregar uma diferença de SOC considerada alta e o usuário definir uma prioridade alta para o processo, então a taxa de recarga inicial será alta (pela Tabela 9: SE Δt_{VEP} é pouco E ΔSOC é baixa E prioridade é sim, ENTÃO TxR_0 é alta). Por outro lado, com os mesmos dados anteriores, mas considerando um usuário que não possui prioridade, a taxa de recarga inicial será baixa (pela tabela: SE Δt_{VEP} é pouco E ΔSOC é baixa E prioridade é não, ENTÃO TxR_0 é baixa).

O método de inferência escolhido foi o de Mamdani, pois a saída do controlador deve possuir funções de pertinência que não sejam somente constantes ou lineares (MAMDANI; ASSILIAN, 1975). Utilizou-se o operador de minimização para os métodos AND e

Figura 8 – Disposições dos conjuntos fuzzy para as três variáveis de entrada e a variável de saída.



Fonte: Elaborado pelo autor.

Tabela 8 – Parâmetros dos conjuntos fuzzy projetado.

Conjunto fuzzy		a	b	x_0
Δt_{VEP}	Pouco	10	3	0
	Médio	10	10	12
	Alto	10	3	24
ΔSOC	Baixa	184	1	0
	Média	184	4	50
	Alta	184	1	100
prioridade	Não	5	500	0
	Talvez	5	600	0,5
	Sim	5	500	1
TxR_0	Zero	0,5	200	0
	Baixa	0,5	400	0,25
	Média	0,5	400	0,5
	Média-Alta	0,5	400	0,75
	Alta	0,5	200	1

Fonte: Elaborado pelo autor.

implicação. Ainda, o operador de maximização foi utilizado para o método de agregação. Para a defuzzificação, utilizou-se o método do centroide (SIMÕES; SHAW, 2007).

Tabela 9 – Base de regras para a saída TxR_0 .

Δt_{VEP} é pouco				
ΔSOC \	prioridade	Não	Talvez	Sim
Baixa		Baixa	Média	Alta
Média		Média	Média-alta	Alta
Alta		Média	Média-alta	Alta
Δt_{VEP} é médio				
ΔSOC \	prioridade	Não	Talvez	Sim
Baixa		Zero	Baixa	Média
Média		Baixa	Média	Média-alta
Alta		Média	Média-alta	Alta
Δt_{VEP} é alto				
ΔSOC \	prioridade	Não	Talvez	Sim
Baixa		Zero	Baixa	Média
Média		Zero	Baixa	Média
Alta		Baixa	Média	Média-alta

Fonte: Elaborado pelo autor.

4.3.2 OTIMIZAÇÃO DE UM CONTROLADOR LÓGICO FUZZY

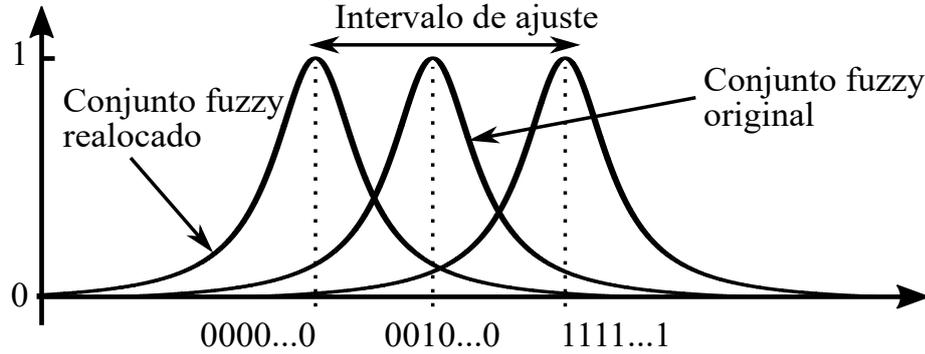
4.3.2.1 FUNÇÃO OBJETIVO DO AJUSTE DO CONTROLADOR LÓGICO FUZZY

Com o controlador lógico fuzzy inicialmente projetado, as localizações dos picos das variáveis linguísticas são deslocadas pelo método de otimização. É através destas realocações que a base de conhecimento do controlador fuzzy é ajustada.

O método proposto por Gurocak (1999) ajusta a base de conhecimento movimentando a localização dos picos dos conjuntos fuzzy, tanto nos conjuntos fuzzy de entrada, quanto nos conjuntos fuzzy de saída. A Figura 9 ilustra um exemplo de ajuste de um pico de um conjunto, respeitando um determinado intervalo de ajuste.

Supõe-se que o controlador fuzzy a ser ajustado possui m variáveis de entrada e somente uma variável de saída. Ou seja, é um sistema MISO (*multiple-input and single-output*, ou, múltiplas-entradas e única-saída). Entre as configurações possíveis, o sistema MISO é amplamente utilizado na literatura. Em adição à consideração anterior, a base com o conjunto de regras inicialmente projetada não é modificada pelo método. Ou seja, as regras definidas pelo projetista continuarão inalteradas durante o processo de otimização e, assim, continuarão no controlador fuzzy ajustado.

Figura 9 – Realocação de um conjunto fuzzy dentro de um intervalo de ajuste.



Fonte: Adaptado de Gurocak (1999).

Para realocar cada conjunto fuzzy, somente a localização do pico é necessária. Dessa forma, o número total de parâmetros de ajuste pode ser obtido pela Equação (4.2).

$$t_p = \sum_{j=1}^m n^{(j)} + q \quad (4.2)$$

Em (4.2), m é o número de variáveis de entrada do sistema fuzzy, $n^{(j)}$ é o número de conjuntos fuzzy para a variável linguística de entrada j e q é o número de conjuntos fuzzy para a variável de saída.

O ajuste da base de regras do controlador fuzzy, conforme descrito acima, é alcançado realocando os picos dos conjuntos fuzzy em todas as variáveis de entrada e na variável de saída. Entretanto, os movimentos dos conjuntos fuzzy devem ser restritos para que o controlador resultante, após as realocações, não possua valores linguísticos sem significado. Dessa forma, um conjunto de restrições de desigualdade denominado intervalo de ajuste é adicionado ao método. É dentro do intervalo de ajuste que a manipulação da localização do pico de um conjunto fuzzy é permitida, conforme visualizado na Figura 9. A Equação (4.3) define o intervalo de ajuste para a localização do pico k .

$$l_0^k < z^k < l_h^k \quad (4.3)$$

Em (4.3), z^k é a localização do pico k no vetor \mathbf{z} , l_0^k é o limite inferior do intervalo de ajuste, l_h^k é o limite superior do intervalo de ajuste e k representa cada pico no vetor \mathbf{z} ($k = 1, 2, 3, \dots, t_p$).

O vetor \mathbf{z} contém as localizações dos picos de todos os conjuntos fuzzy. Os elementos deste vetor são explicitados em (4.4).

$$\mathbf{z} = [a_{11}, a_{12}, \dots, a_{1n^{(1)}}, a_{21}, a_{22}, \dots, a_{2n^{(2)}}, \dots, a_{m1}, a_{m2}, \dots, a_{mn^{(j)}}, b_1, b_2, \dots, b_q]_{1 \times t_p} \quad (4.4)$$

Onde: $n^{(j)}$ é o número de conjuntos fuzzy para a variável linguística de entrada j ($j = 1, 2, 3, \dots, m$), m é o número de variáveis de entrada do sistema fuzzy, q é o número de conjuntos fuzzy da variável de saída do sistema fuzzy e t_p é o número de parâmetros de ajuste.

O objetivo do método é minimizar a diferença entre a saída do controlador lógico fuzzy y e a saída desejada do controlador y_d para todos os possíveis valores de entrada, de acordo com a Equação (4.5).

$$\min_{\mathbf{z}} C_1 = \min_{\mathbf{z}} k_1 |y - y_d| \quad (4.5)$$

Onde $k_1 > 0$ é uma constante de escala.

A saída desejada y_d é inserida pelo projetista do controlador lógico fuzzy, para um dado conjunto de variáveis de entradas, conforme a Equação (4.6).

$$y_d = f(x_1, x_2, x_3, \dots, x_m) \quad (4.6)$$

Já a saída y é retornada pelo controlador fuzzy projetado inicialmente. Esta saída também é função do conjunto das variáveis de entrada. Além disso, ela depende dos picos das funções de pertinência, conforme expresso na Equação (4.7).

$$y = f(x_1, x_2, x_3, \dots, x_m, \mathbf{z}) \quad (4.7)$$

Conforme as Equações (4.6) e (4.7), observa-se que a função objetivo C_1 da Equação (4.5), é uma função das entradas do sistema e das localizações dos picos. Entretanto, o método busca ajustar a base de regras para todas as entradas possíveis. Dessa forma, a subtração entre y e y_d na função objetivo deve ser independente das entradas e dependente das localizações dos picos. A Equação (4.8) realiza a eliminação desta dependência, deixando a diferença entre y e y_d somente em função da localização dos picos dos conjuntos fuzzy.

$$\min_{\mathbf{z}} C_2 = \min_{\mathbf{z}} k_1 \cdot L_2 \quad (4.8)$$

Onde:

$$L_2 = \sqrt{\int_{j=1} \int_{j=2} \dots \int_{j=m} (y - y_d)^2 dx_m dx_{m-1} \dots dx_1} \quad (4.9)$$

Além disso, $dx_m, dx_{(m-1)}, \dots, dx_1$ são elementos infinitesimais das variáveis linguísticas de entrada $m, (m - 1), \dots, 1$.

A nova função objetivo na Equação (4.8) é função somente da localização dos picos de \mathbf{z} . Com isso, ela pode ser considerada como uma medida de distância entre as funções multivariadas y e y_d .

As restrições de (4.3) são incorporadas na função objetivo na Equação (4.8) na forma de uma função de penalidade global. A vantagem é que esta nova função objetivo pode ser tratada como um problema de otimização global. Sua forma final é exposta na Equação (4.10).

$$\min_{\mathbf{z}} C = \min_{\mathbf{z}} \left[k_1 L_2 + k_2 \sum_{k=1}^{t_p} \left(\frac{1}{z^k - l_0^k} + \frac{1}{l_h^k - z^k} \right) \right] \quad (4.10)$$

Em (4.10), $k_2 > 0$ é uma constante de escala. A parte da penalidade aumenta rapidamente se os limites dos intervalos de ajuste são aproximados, enquanto as localizações dos picos no vetor parâmetro são alteradas pelo método de otimização.

Aplicado ao ajuste do controlador fuzzy projetado anteriormente, a função objetivo de (4.10) passa a ser definida por (4.11).

$$\min_{\mathbf{z}} \left[k_1 \sqrt{\int_0^{24} \int_0^{100} \int_0^1 (y - y_d)^2 dprioridade \cdot d\Delta SOC \cdot d\Delta t_{VEP}} + k_2 \sum_{k=1}^{t_p} \left(\frac{1}{z^k - l_0^k} + \frac{1}{l_h^k - z^k} \right) \right] \quad (4.11)$$

Onde: y é a saída da inferência do controlador lógico fuzzy, y_d é a saída desejada do controlador lógico fuzzy, $prioridade$ é a prioridade de recarga, ΔSOC é o estado de carga que deve ser recarregado, Δt_{VEP} é o intervalo de tempo que o VEP ficará conectado para recarga, \mathbf{z} é o vetor com as localizações dos picos, t_p é o número de picos que podem ser ajustados, z^k é a localização do pico k , l_0^k é o limite inferior do intervalo de ajuste do pico k , l_h^k é o limite superior do intervalo de ajuste do pico k e $k_1 > 0$ e $k_2 > 0$ são constantes de escala.

4.3.2.2 ALGORITMO GENÉTICO PARA O AJUSTE DO CONTROLADOR FUZZY

Para a utilização do algoritmo genético (AG) no ajuste do controlador fuzzy, uma consideração sobre a codificação deve ser feita. Isto ocorre porque o AG requer que o espaço de busca seja codificado como uma string de bits. Nesta Dissertação, considera-se o espaço de busca como os intervalos de ajuste do controlador lógico fuzzy.

O intervalo de busca de cada conjunto fuzzy é codificado como uma string de zeros e uns, sendo que a string 0000...0 representa o valor inferior do intervalo e a string 1111...1 representa o valor superior do intervalo. Dentro deste intervalo, a localização do pico do conjunto fuzzy é também representada por uma string de zeros e uns.

O processo de codificação é realizado com as seguintes variáveis: valor decimal do pico (*pico*), número de bits da string binária a ser gerada (*nBits*), limite inferior de ajuste (l_0) e limite superior de ajuste (l_h). Primeiramente, uma normalização matemática é aplicada para normalizar o pico recebido para o intervalo de mínima e máxima representação da

string binária de $nBits$, ou seja, $\in [0, maxValor]$. A Equação (4.12) representa o processo de codificação.

$$novoPico = \frac{(pico - l_0) \cdot maxValor}{(l_h - l_0)} \quad (4.12)$$

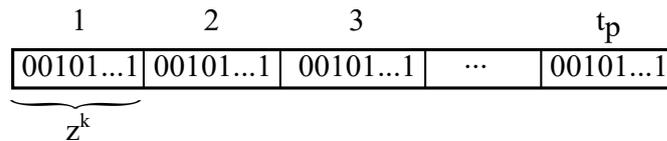
Onde:

$$maxValor = 2^{nBits} - 1 \quad (4.13)$$

O $novoPico$ normalizado entre $[0, maxValor]$ é então convertido para uma representação binária de $nBits$.

Para cada conjunto fuzzy na base de regras, uma string de bits é formada, representando a localização do pico deste conjunto. Então, um cromossomo \mathbf{z} com todas estas strings é formado, conforme ilustrado na Figura 10. Este cromossomo possui o equivalente a t_p picos codificados e z^k indica a string equivalente ao pico k ($k = 1, 2, 3, \dots, t_p$).

Figura 10 – Cromossomo \mathbf{z} com os genes codificados (picos dos conjuntos fuzzy).



Fonte: Adaptado de Gurocak (1999).

Conhecendo como codificar e decodificar os picos, pode-se seguir com o processo do AG.

Para inicializar o algoritmo, uma população inicial de cromossomos é necessária. Neste trabalho, um cromossomo indica um controlador lógico fuzzy e uma população é uma coleção de controladores lógicos fuzzy, dentre os quais o método procura pelo melhor. Para gerar a população inicial, pode-se codificar a base de regras inicialmente definida pelo projetista ou gerar as localizações dos picos randomicamente, dentro dos intervalos de ajuste, de modo que estas informações sejam usadas na base de regras. Na proposta apresentada, a segunda opção é utilizada.

Após gerada a população inicial, o AG cria a próxima geração utilizando três operadores: 1) reprodução, 2) recombinação e 3) mutação.

Aplicados os operadores, a próxima geração é composta por alguns cromossomos da geração anterior, cromossomos filhos e algumas perturbações em toda população devido à mutação (caso ela tenha ocorrido). A evolução da população termina após um número pré-definido de gerações. O cromossomo com o menor valor de aptidão contém a base de regras do controlador fuzzy ajustado. A string de zeros e uns resultante é decodificada para obter as localizações dos picos otimizadas dos conjuntos fuzzy.

A decodificação ocorre inversamente ao processo de codificação descrito. As variáveis utilizadas são: a string de bits (*palavra*), o número de bits (*nBits*) e os intervalos de ajuste inferior (l_0) e superior (l_h).

Primeiramente, decodifica-se o valor binário recebido para um valor decimal correspondente (*picoDecimal*). Após, a normalização matemática também é aplicada, mas obedecendo a Equação (4.14).

$$pico = l_0 + \frac{picoDecimal \cdot (l_h - l_0)}{maxValor} \quad (4.14)$$

4.3.2.3 PSO PARA O AJUSTE DO CONTROLADOR FUZZY

A aplicação do PSO para ajustar a base de conhecimento do controlador lógico fuzzy é mais direta do que o algoritmo genético. Isto acontece porque este não necessita de variáveis codificadas para sua execução. Assim, o PSO pode ser diretamente aplicado.

Para inicializar o PSO, uma população inicial de partículas é necessária. Para a metodologia proposta, cada partícula indica um controlador lógico fuzzy, pois a mesma carrega as localizações dos picos dos conjuntos fuzzy. Dessa forma, uma população é uma coleção de controladores lógico fuzzy e o método de otimização busca pelo mais apto. A população inicial é gerada aleatoriamente dentro dos limites inferior e superior do intervalo de ajuste.

Após, até que um número pré-determinado de iterações seja alcançado, o algoritmo atualiza as velocidades, as posições e as aptidões das partículas. Além disso, atualiza também o melhor valor de aptidão na história de cada partícula e a melhor partícula de todas. Por fim, a partícula com a menor aptidão contém a base de conhecimento ajustada do controlador lógico fuzzy. Ou seja, a partícula carrega as localizações dos picos realocados dos conjuntos fuzzy.

4.3.3 CÁLCULO DA TAXA DE RECARGA FINAL

A taxa final que recarrega o VEP só é definida após o balanço de potência entre todos os veículos no agregador e a potência que este último teve disponibilizada pelo COD, conforme a Equação (4.15). Este balanço de potência é um fator chave para coordenar o carregamento dos VEPs com a condição atual da rede elétrica repassada pelo centro de operação da distribuição.

$$\sum_{i=1}^{n_{VEP}} P_{req,i} = P_D \quad (4.15)$$

Na Equação (4.15), $P_{req,i}$ é a potência requisitada pelo VEP i , em watts, n_{VEP} é o número de VEPs no agregador e P_D é a potência disponibilizada pelo COD para o agregador.

Em busca de balancear a potência fornecida pelo COD com a potência recebida por todos os VEPs, primeiramente, calcula-se a potência requerida inicialmente por cada VEP com a taxa de recarga inicial. A Equação (4.16) mostra como este cálculo é realizado.

$$P_{req,i}^0 = TxR_{0,i} \cdot P_D \quad (4.16)$$

Onde: $TxR_{0,i}$ é a taxa de recarga inicial gerada pelo controlador fuzzy do veículo i , P_D é potência disponível no agregador, em watts, e $P_{req,i}^0$ é a potência inicialmente requisitada pelo VEP i antes do balanço de potência.

O próximo passo consiste em normalizar matematicamente a potência inicialmente requisitada por cada VEP em função da potência disponível no agregador. Esta normalização é realizada para cada veículo i conforme a Equação (4.17).

$$\bar{P}_{req,i} = \frac{P_{req,i}^0 \cdot P_D}{\sum_i P_{req,i}^0} \quad (4.17)$$

Onde $\bar{P}_{req,i}$ é a potência do VEP i normalizada em função da potência P_D disponibilizada para o agregador. Desta forma, o balanço de potência de (4.15) é alcançado.

Com os valores das potências normalizadas em função da potência disponível no agregador, aplica-se o processo inverso da Equação (4.16) para recalculer a taxa de recarga, como mostrado na Equação (4.18).

$$TxR_i = \frac{\bar{P}_{req,i}}{P_D} \quad (4.18)$$

Em (4.18), TxR_i é a taxa de recarga final do VEP i .

Dessa forma, o valor recalculado da taxa de recarga inicial está finalizado para recarregar o VEP. Este é o valor final da taxa de recarga retornada pelo sistema de controle da recarga.

4.4 GERENCIAMENTO DAS FROTAS DE VEPS

4.4.1 DETERMINAÇÃO DAS POTÊNCIAS DOS AGREGADORES

A potência máxima indica o valor necessário para recarregar todos os VEPs, em seus respectivos períodos de conexão à rede elétrica, independentemente das prioridades. Seu valor é obtido somando as potências de cada VEP, conforme a Equação (4.19).

$$P_{max} = \sum_{i=1}^{n_{VEP}} P_{VEP,i} \quad (4.19)$$

Em (4.19), $P_{VEP,i}$ é a potência que deve ser demandada pelo VEP i , a cada Δt , visando recarregar a bateria até SOC_f durante o período de conexão à rede elétrica. A

Equação (4.20) apresenta o cálculo de $P_{VEP,i}$.

$$P_{VEP,i} = \frac{B_{cap,i}}{\Delta t_{VEP,i}} \cdot \frac{\Delta SOC_i}{100} \cdot \Delta t \quad (4.20)$$

Onde $B_{cap,i}$ é a capacidade da bateria do VEP i , em watts, $\Delta t_{VEP,i}$ é o tempo que o VEP i ficará conectado para a recarga ($\Delta t_{VEP,i} = t_f - t_0$), em horas, ΔSOC_i é a porcentagem do estado de carga que deve ser recarregado ($\Delta SOC_i = SOC_f - SOC_0$), em %, e Δt é o intervalo de discretização, em horas.

A potência mínima representa um valor mínimo que o agregador demanda do COD para garantir a recarga de apenas uma parcela da frota. Este valor é obtido em função da potência demandada da Equação (4.20) e das prioridades dos consumidores, ou seja, $P_{min} = f(P_{VEP,i}, prioridade)$.

Dividiu-se o intervalo de prioridades em cinco categorias: máxima, alta, média, baixa e mínima. A Tabela 10 define os intervalos de valores da prioridade para cada categoria criada.

Tabela 10 – Intervalo atribuído a cada categoria de prioridade.

Categoria de prioridade	Intervalo
Máxima	[1,00, 0,90)
Alta	[0,90, 0,65)
Média	[0,65, 0,35]
Baixa	(0,35, 0,10]
Mínima	(0,10, 0,00]

Fonte: Elaborado pelo autor.

A potência mínima é definida como a soma de todas as potências, conforme apresentado na Equação (4.21). Cada potência é ponderada pelo peso correspondente a categoria que sua prioridade se enquadra.

$$P_{min} = w_1 \cdot \sum_i^{0,9 < prioridade \leq 1} P_{VEP,i} + w_2 \cdot \sum_i^{0,65 < prioridade \leq 0,9} P_{VEP,i} + w_3 \cdot \sum_i^{0,35 < prioridade \leq 0,65} P_{VEP,i} + w_4 \cdot \sum_i^{0,10 < prioridade \leq 0,35} P_{VEP,i} + w_5 \cdot \sum_i^{0 \leq prioridade < 0,1} P_{VEP,i} \quad (4.21)$$

Em (4.21), w_1 , w_2 , w_3 , w_4 e w_5 são os pesos que limitam as potências a serem requisitadas por cada categoria de prioridade. Estes pesos são obtidos utilizando o método de auxílio à tomada de decisões AHP, conforme exposto na sequência.

Comparando as categorias de prioridade par a par e com o auxílio da escala numérica de comparações e julgamentos, montou-se a matriz de julgamentos conforme exposto na Tabela 11.

Tabela 11 – Matriz de julgamentos das categorias da prioridade.

Prioridade	Máxima	Alta	Média	Baixa	Mínima
Máxima	1	3	5	7	9
Alta	1/3	1	3	5	7
Média	1/5	1/3	1	3	5
Baixa	1/7	1/5	1/3	1	3
Mínima	1/9	1/7	1/5	1/3	1

Fonte: Elaborado pelo autor.

Alguns exemplos de interpretação da Tabela 11 são:

- A prioridade máxima possui a mesma importância que a prioridade máxima (comparando uma categoria com ela mesma);
- A prioridade máxima é moderadamente mais importante que a prioridade alta (valor numérico 3);
- A prioridade máxima é extremamente mais importante que a prioridade mínima (valor numérico 9);
- A prioridade alta é muito fortemente mais importante que a prioridade mínima (valor 7);
- A prioridade média é fortemente mais importante que a prioridade mínima e assim por diante.

Utilizando a metodologia de Wang et al. (2008) e Pamplona (1999), encontram-se os pesos para cada categoria de prioridade de acordo com a matriz de julgamentos definida anteriormente. Estes pesos são apresentados na Tabela 12.

Dessa forma, a categoria máxima possui a maior importância (51,28%), sendo seguida pela categoria alta com 26,15% de importância. Em terceiro lugar, com 12,90%, apresenta-se a prioridade média, seguida pela prioridade baixa com 6,34%. Por último, com 3,33%, tem-se a prioridade mínima.

A utilização do método AHP para determinar os pesos w_1 , w_2 , w_3 , w_4 e w_5 está terminada, com os valores para cada peso, expressos na Tabela 12. Entretanto, antes de atribuir os valores para os pesos, deve-se avaliar se a matriz da Tabela 11 é consistente. Caso não seja, a matriz deve ter seus julgamentos reavaliados buscando a devida consistência.

Tabela 12 – Pesos resultantes para a matriz de julgamentos definida.

Categoria da prioridade	Peso
Máxima	0,512813
Alta	0,261499
Média	0,128976
Baixa	0,0633765
Mínima	0,0333352

Fonte: Elaborado pelo autor.

O índice de consistência obtido com os pesos anteriores foi $IC = 0,0593688$. Sabendo que são 5 critérios (categorias) utilizadas, tem-se que o índice randômico de consistência é $IR = 1,11$. Com isso, a razão de consistência é $RC = IC/IR = 0,053485$. Por fim, comparando a razão de consistência obtida ($RC = 0,053485$) com o máximo valor que ela pode assumir para 5 critérios ($RC_{máximo} = 0,10$), uma vez que RC é menor que RC máximo, tem-se que a matriz de julgamentos montada é consistente.

Desta forma, os pesos para o cálculo da potência mínima são atribuídos como: $w_1 = 0,5128130$, $w_2 = 0,2614990$, $w_3 = 0,1289760$, $w_4 = 0,0633765$ e $w_5 = 0,0333352$.

4.4.2 FUNÇÃO OBJETIVO PARA O GERENCIAMENTO DOS AGREGADORES

O gerenciamento dos agregadores é realizado pelo COD através de um método de otimização. Este método determina as potências que cada agregador irá receber, dentro do intervalo de potências mínima e máxima apresentadas anteriormente. Como objetivo da otimização, definiu-se por minimizar as perdas de energia no sistema elétrico de potência. Com base nisso, tem-se a função objetivo e a restrição apresentadas na Equação (4.22).

$$\begin{aligned} \min \sum_{l=1}^{n_l} R_l I_l^2 \Delta t \\ \text{s.a. } P_{min,j} \leq P_j \leq P_{max,j}, 1 \leq j \leq n_A \end{aligned} \quad (4.22)$$

Em (4.22), l é o índice que indica a linha da rede elétrica, n_l é o número total de linhas do sistema sob estudo, R_l é a resistência da linha l , I_l é a corrente elétrica na linha, Δt é o intervalo de discretização, $P_{min,j}$ e $P_{max,j}$ são as potências mínima e máxima que o agregador j calculou, respectivamente, P_j é a potência que o agregador j irá receber do COD e n_A é o número total de agregadores considerados.

Dado que a otimização é realizada a cada intervalo de tempo Δt , pode-se aplicar a mesma para analisar as perdas de energia em horas, dias, meses ou anos.

O VEP foi inserido no sistema elétrico através do modelo de carga com potência constante. Este é o modelo mais típico para estudos de fluxo de potência. Além disso, ele

relaciona diretamente a potência demandada pelo veículo com seu estado de carga e a taxa de recarga final.

As demais restrições do sistema elétrico de potência são consideradas diretamente na ferramenta computacional de execução do fluxo de potência. Estas restrições são apresentadas nas Equações (4.23) a (4.27), descritas nos itens abaixo.

- Balanço de potência da carga e geração:

$$\begin{aligned} P_i &= \sum \sum P_{ij} \\ Q_i &= \sum \sum Q_{ij} \end{aligned} \quad (4.23)$$

Nas equações acima, P_i é a potência ativa injetada na barra i , Q_i é a potência reativa injetada na barra i , P_{ij} é a potência ativa que flui entre a barra i para a barra j e Q_{ij} é a potência reativa que flui entre a barra i para a barra j .

- Módulo da tensão em cada barra:

$$V_i^{min} \leq |V_i| \leq V_i^{max} \quad (4.24)$$

Sendo V_i^{min} o menor módulo de tensão permitido na barra i e V_i^{max} o maior módulo de tensão permitido na barra i .

- Tap do transformador e dos reguladores de tensão:

$$a_{ij,min} \leq a_{ij} \leq a_{ij,max} \quad (4.25)$$

Onde $a_{ij,min}$ é o menor tap possível no transformador ou regulador de tensão do circuito ij e $a_{ij,max}$ é o maior tap permitido no transformador ou regulador de tensão do circuito ij .

- Potência reativa capacitiva:

$$0 \leq Q_{C,i} \leq Q_{C,i}^{max} \quad (4.26)$$

Com $Q_{C,i}^{max}$ sendo o maior valor da potência reativa capacitiva permitida na barra i .

- Carregamento dos circuitos:

$$\sqrt{P_{ij}^2 + Q_{ij}^2} \leq S_{ij}^{max} \quad (4.27)$$

Sendo que S_{ij}^{max} é o máximo carregamento permitido no circuito ij , P_{ij} é a potência ativa no circuito ij e Q_{ij} é a potência reativa no circuito ij .

4.4.3 MÉTODO DE OTIMIZAÇÃO PARA O GERENCIAMENTO DOS AGREGADORES

Resultados obtidos por Esmín, Lambert-Torres e Zambroni de Souza (2005), Ghani, Gan e Hasan (2014) e Sanz et al. (2017) mostram que o PSO é muito adequado para aplicações buscando minimizar perdas de energia em sistemas elétricos. Desta forma, o método de otimização utilizado para gerenciar as frotas de VEPs em ambos os casos é o PSO.

Utilizando a função objetivo e restrição da Equação (4.22), o PSO atribui potências para os agregadores. Na sequência, o fluxo de potência é executado e o total de perdas de energia do circuito é obtido. Faz-se isso para um determinado número de iterações, atualizando as posições e velocidades das partículas em cada iteração. Ao final da otimização, tem-se o conjunto de potências que retornam as menores perdas de energia. Estas potências são então repassadas para os agregadores realizarem o controle da taxa de recarga.

4.5 CONSIDERAÇÕES FINAIS

Neste Capítulo foi apresentada a metodologia proposta para o controle inteligente da recarga de veículos elétricos *plug-in*.

A metodologia proposta auxilia a mitigar os impactos da recarga dos VEPs na rede elétrica. Para tal, utiliza-se um método de otimização para ajustar um controlador fuzzy e um método de otimização para gerenciar as potências dos agregadores. Além disso, o método de auxílio à tomada de decisões AHP também é utilizado para determinar a potência mínima a ser recebida por cada agregador.

No Capítulo seguinte, são apresentados os resultados obtidos, os quais comprovam a qualidade da metodologia proposta.

5 RESULTADOS E DISCUSSÕES

5.1 CONSIDERAÇÕES GERAIS

Este Capítulo apresenta os resultados obtidos com a implementação da metodologia proposta. Apresentam-se os resultados do controlador lógico fuzzy projetado, evidenciando a influência da prioridade na recarga dos VEPs. Ainda, registra-se o ajuste do controlador projetado com o método de otimização por enxame de partículas. Com o controlador fuzzy ajustado, discute-se a diferença apresentada por ambos os controladores projetado e ajustado. Resultados obtidos com o gerenciamento das frotas de VEPs também são expostos.

5.2 CONSIDERAÇÕES INICIAIS

O cálculo das potências mínima e máxima, a execução do controlador fuzzy, o cálculo das taxas de recarga e a estratégia de otimização foram construídas e testadas no ambiente de programação MATLAB[®] 8 (R2012b), sendo que o toolbox de lógica fuzzy foi utilizado para projetar o controlador. Já o fluxo de potência do sistema teste com a penetração das frotas de VEPs foi executado no software OpenDSS.

Todos os algoritmos e softwares foram executados em um computador com processador AMD Phenom[®] II X3 B77 Processor de 3,2 GHz e com 4,00 GB de memória RAM instalada, com o sistema operacional Windows 10 Pro.

5.3 GERENCIAMENTO DE UMA FROTA DE VEPS

5.3.1 VEPS SE RECARREGANDO COM CONTROLADOR LÓGICO FUZZY PROJETADO

Após o projeto inicial do controlador lógico fuzzy, o seu funcionamento foi testado para uma frota de veículos elétricos *plug-in* requisitando recarga. Simulou-se um controlador fuzzy recarregando 20 VEPs com as características apresentadas no Apêndice B. Consideraram-se que os veículos foram todos conectados no mesmo horário para a recarga, sendo esta feita até o estado final de carga (SOC) de 90%. Os VEPs foram inseridos para a recarga com diferentes SOCs iniciais e desconectados da rede elétrica em horários diferentes. Em adição, os mesmos possuíam prioridades de recargas diversificadas.

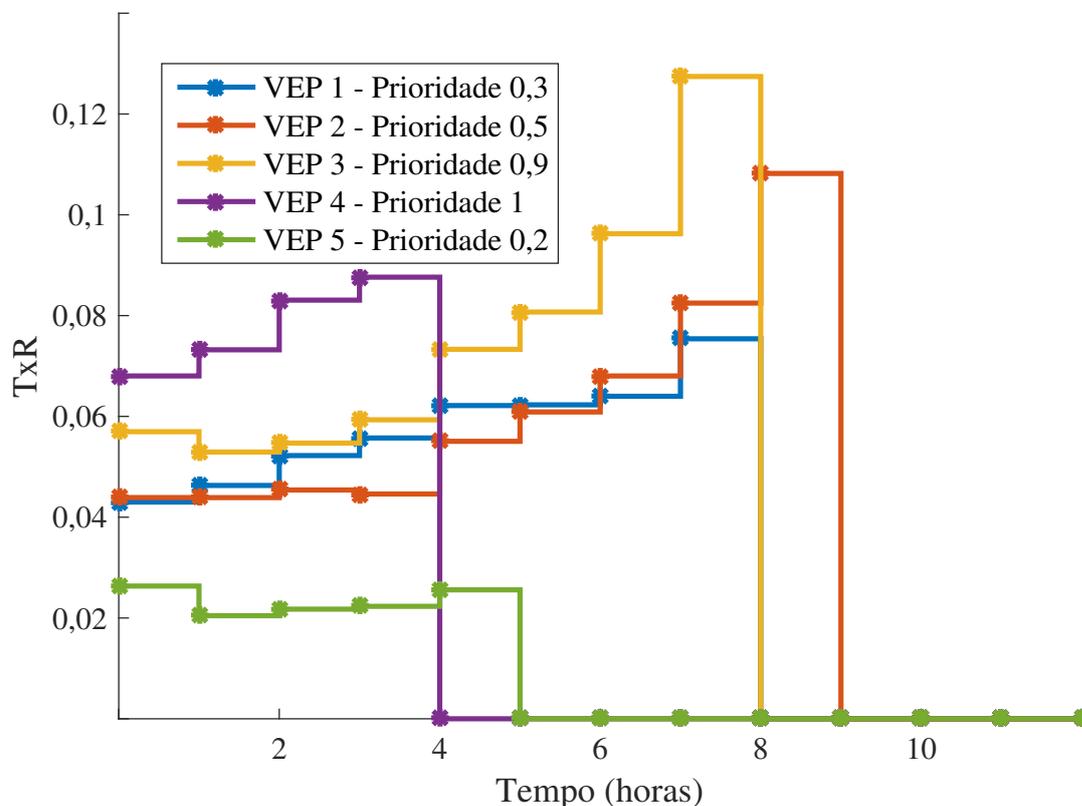
A Figura 11 mostra as taxas de recargas calculadas dos cinco primeiros VEPs nesta frota. Foram escolhidos apenas os cinco veículos visando melhor clareza na exposição dos resultados. A Figura 20 do Apêndice A apresenta as taxas de recarga de todos os 20 VEPs.

Para as situações expostas na Figura 11, verifica-se que as taxas de recarga permanecem aproximadamente constantes durante as cinco primeiras horas da recarga. Após, quando as taxas de recarga dos veículos 4 e 5 caem para zero, os demais VEPs

recebem um incremento em suas taxas de recarga. Analisando apenas os VEPs apresentados na referida figura, pode-se afirmar que isto acontece porque a partir da quinta hora a potência disponível no agregador será distribuída entre os três veículos restantes.

Além disso, nota-se que as curvas das taxas de recarga estão ordenadas de acordo com a prioridade inserida pelo consumidor (exceto para o VEP 2, que ficará mais tempo recarregando). Isto implica que quanto maior a prioridade, maior é a taxa de recarga retornada pelo controlador lógico fuzzy. Na Figura 11, o VEP 4 possui uma prioridade máxima de 1 e é a curva com a maior taxa de recarga até a hora 5. Já o veículo 5, com a menor prioridade da amostragem representada no gráfico, possui sua taxa de recarga reduzida em relação aos outros durante o mesmo período.

Figura 11 – Taxas de recarga para alguns dos VEPs da frota sob estudo.



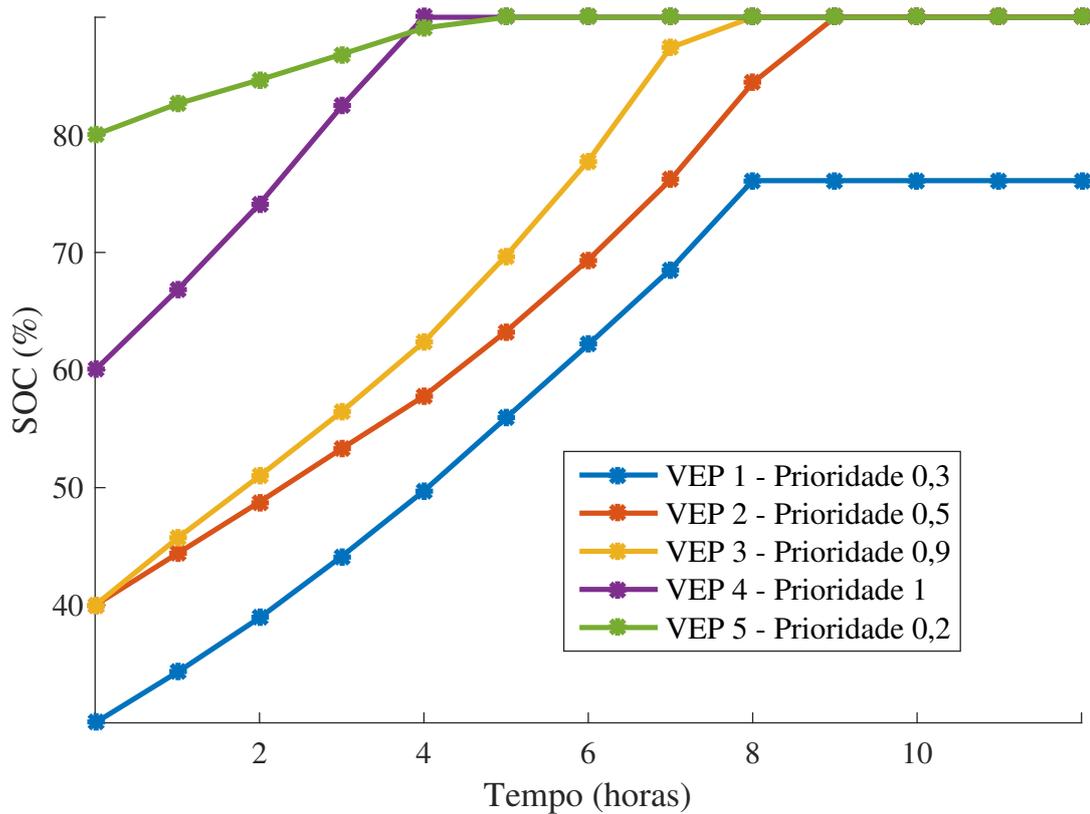
Fonte: Elaborado pelo autor.

Outra maneira de visualizar a resposta do controlador lógico fuzzy é através da visualização do incremento do estado de carga de cada VEP durante o seu período de recarga. A Figura 12 apresenta a variação do estado de carga das baterias dos VEPs considerados anteriormente. Na Figura 21 do Apêndice A são apresentados os estados de carga de todos os 20 VEPs.

Observa-se na Figura 12 que o estado de carga do veículo 1 aumenta de forma aproximadamente linear e após atingir aproximadamente 75% se estabiliza nesse valor. A

prioridade para este veículo é 0,3, a qual pode ser classificada entre baixa e média. Dessa forma, o controlador fuzzy não foi projetado para atingir o SOC final, mas deve fornecer energia com uma taxa de recarga aceitável. Esta é exatamente a resposta do sistema, elevando a carga da bateria de 30 para aproximadamente 70%, mesmo com a prioridade adotada para o respectivo veículo. A recarga só não é completada até o SOC final de 90% porque o veículo é desconectado da rede antes de atingir esse nível de carga.

Figura 12 – Estados de carga atualizados para alguns dos VEPs da frota sob estudo.

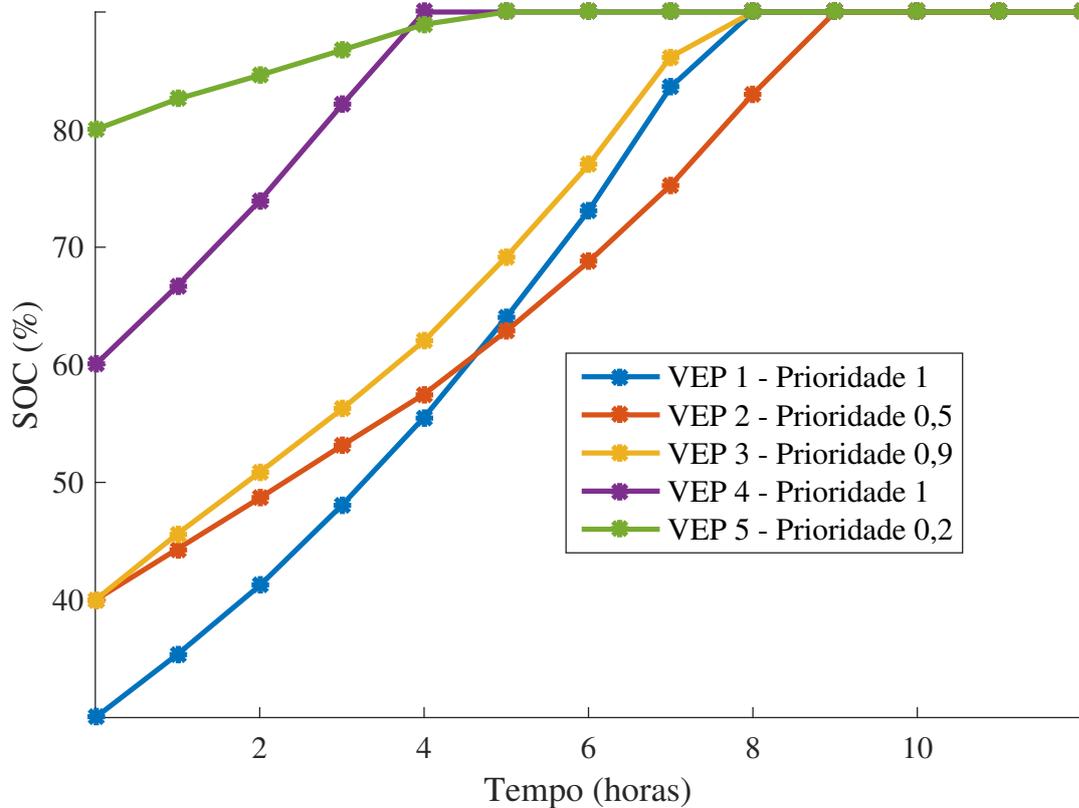


Fonte: Elaborado pelo autor.

Caso o consumidor queira que a bateria seja totalmente recarregada no intervalo de conexão, ele deve aumentar a prioridade no início da recarga. Fazendo esta mudança da prioridade para o VEP 1, a resposta do sistema irá se alterar conforme ilustrado na Figura 13.

Comparando as Figuras 12 e 13, observa-se que o VEP 1 é recarregado até o estado de carga final quando sua prioridade é alterada para o valor 1. Ou seja, com uma prioridade máxima, o controlador retorna taxas de recarga maiores para o VEP 1 em comparação com a prioridade da Figura 12. Tem-se, então, que a prioridade está influenciando diretamente no cálculo da taxa de recarga, ou seja: uma prioridade maior indica elevada garantia em recarregar totalmente a bateria durante o período de conexão à rede elétrica.

Figura 13 – Estados de carga atualizados para alguns dos VEPs da frota sob estudo considerando uma mudança na prioridade do VEP 1.



Fonte: Elaborado pelo autor.

5.3.2 OTIMIZAÇÃO DO CONTROLADOR LÓGICO FUZZY

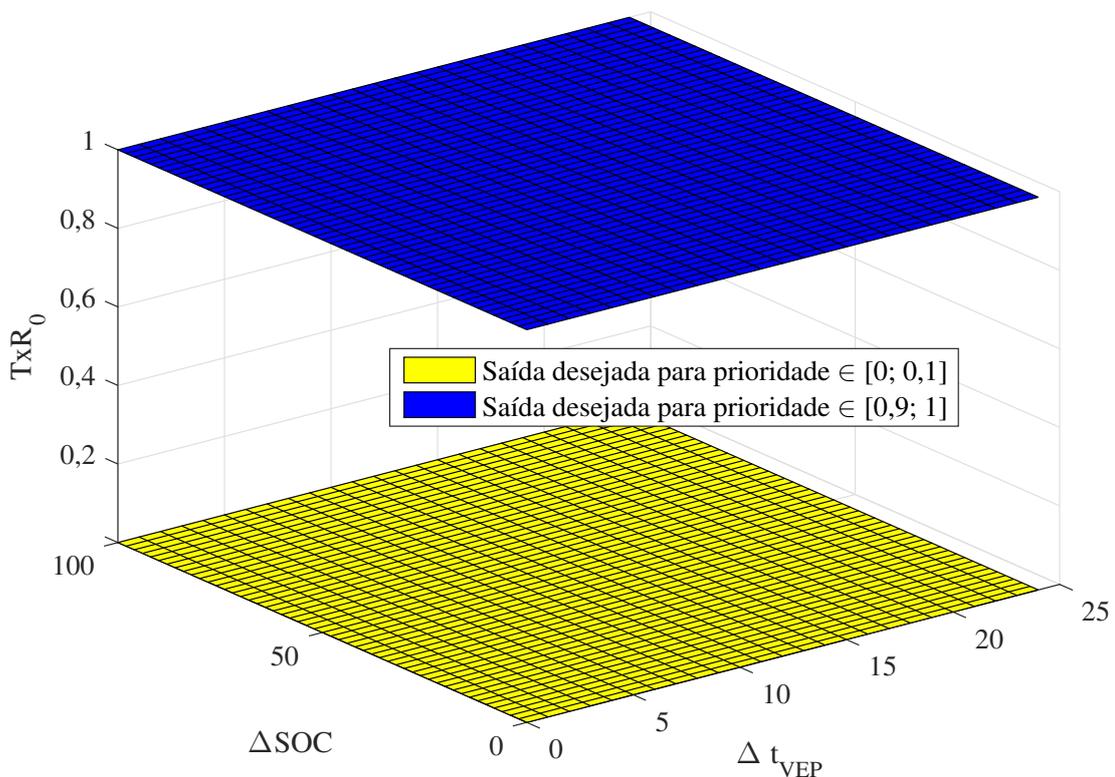
Após o projeto do controlador lógico fuzzy, ajusta-se a base de conhecimento com um método de otimização. Este método tem a Equação (4.11) como função objetivo. Nela, busca-se minimizar a diferença entre a saída da inferência do controlador fuzzy e a saída desejada.

As integrais da função objetivo foram resolvidas utilizando o método de integração numérica trapezoidal implementado no MATLAB[®] pela função `trapz`. Utilizaram-se passos de integração de 2, 1 e 0,1 para ΔSOC , Δt_{VEP} e prioridade, respectivamente. E, após diversas simulações, obtiveram-se os valores de $k_1 = 0,5$ e $k_2 = 0,5$ como sendo as constantes de escalas que melhor reduziram os valores da função objetivo.

Para a aplicação do método de otimização na recarga de VEPs, busca-se otimizar o controlador lógico fuzzy para que uma prioridade no intervalo $[0; 0, 1]$ implique em uma taxa de recarga aproximadamente zero, independente de Δt_{VEP} e ΔSOC . Da mesma forma, a otimização buscará retornar uma taxa de recarga unitária para os VEPs com prioridade em $[0, 9; 1]$. As superfícies da Figura 14 ilustram as saídas desejadas para os casos em que a prioridade encontra-se no intervalo $[0; 0, 1]$ ou $[0, 9; 1]$.

Dois métodos de otimização foram utilizados para ajustar a base de conhecimento do controlador lógico fuzzy: algoritmo genético (AG) e otimização por enxame de partículas (PSO). Estes métodos foram implementados e comparados de modo a determinar qual executa esta tarefa de forma mais adequada. Os resultados e discussões obtidos destas comparações são apresentados no Apêndice C.

Figura 14 – Saídas desejadas para as prioridades no intervalo $[0; 0, 1]$ ou $[0, 9; 1]$.



Fonte: Elaborado pelo autor.

Após o ajuste do controlador com os dois métodos e as comparações subsequentes do Apêndice C, o PSO se apresenta como tendo o melhor desempenho em relação aquele atingido pelo algoritmo genético. Os parâmetros da Tabela 13 gerados a partir do PSO foram utilizados para criar o controlador fuzzy ajustado. Nesta Tabela, apresentam-se também os intervalos de ajuste e os parâmetros iniciais do controlador lógico fuzzy.

Na Tabela 20, a e b são constantes que controlam a abertura do conjunto fuzzy, x_0 representa a localização do pico do conjunto fuzzy antes da otimização e $x_{0,PSO}^*$ indica a localização do pico do conjunto fuzzy após o ajuste com o PSO.

Tabela 13 – Parâmetros dos conjuntos fuzzy antes e após a otimização com o PSO.

Conjunto fuzzy		a	b	Intervalo de ajuste do pico	x_0	$x_{0,PSO}^*$
Δt_{VEP}	Pouco	10	3	[0,5]	0	1,8679
	Médio	10	10	[7,17]	12	15,3153
	Alto	10	3	[19, 24]	24	22,1868
ΔSOC	Baixa	184	1	[0, 20]	0	11,2591
	Média	184	4	[40, 65]	50	48,0412
	Alta	184	1	[80, 100]	100	87,5361
prioridade	Não	5	500	[0, 0,20]	0	0,0939
	Talvez	5	600	[0,35, 0,55]	0,5	0,4674
	Sim	5	500	[0,7, 1]	1	0,9889
TxR_0	Zero	0,5	200	[0, 0,08]	0	0,0359
	Baixa	0,5	400	[0,15, 0,35]	0,25	0,2479
	Média	0,5	400	[0,42, 0,60]	0,5	0,5054
	Média-Alta	0,5	400	[0,68, 0,80]	0,75	0,7435
	Alta	0,5	200	[0,90, 1]	1	0,948

Fonte: Elaborado pelo autor.

5.3.3 VEPS SE RECARREGANDO COM CONTROLADOR LÓGICO FUZZY OTIMIZADO PELO PSO

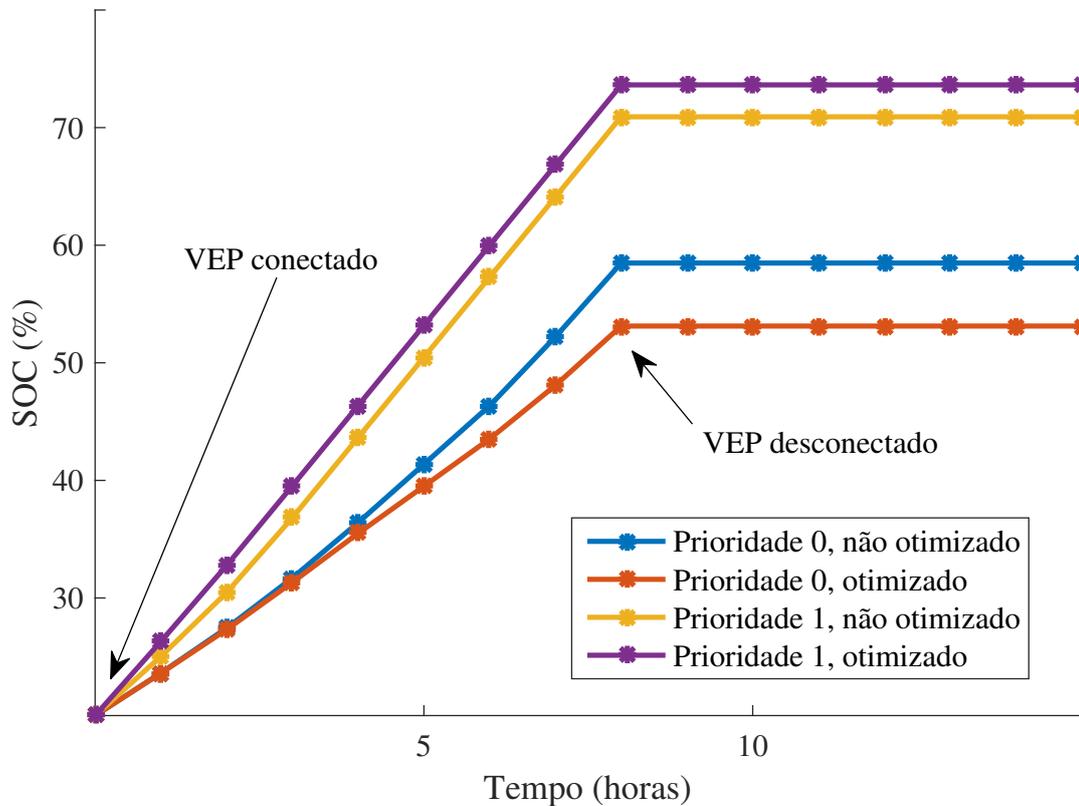
Após o ajuste da base de conhecimento com o PSO, simulou-se um mesmo VEP se recarregando com as prioridades 0 e 1, antes e após a otimização. Os outros veículos da frota não tiveram seus dados alterados. Dessa forma, é possível avaliar a influência da prioridade e da otimização do controlador fuzzy na recarga do VEP. A Figura 15 apresenta a resposta obtida para o VEP com diferentes prioridades e com o controlador lógico fuzzy otimizado e não otimizado.

Considerando o controlador fuzzy não otimizado, a Figura 15 mostra que um VEP com prioridade baixa (valor 0) se desconecta da rede elétrica com SOC de aproximadamente 58%. Em contrapartida, com uma prioridade alta (valor 1), o VEP é recarregado até o SOC de aproximadamente 70%. Este comportamento mostra que a prioridade influencia diretamente na recarga do VEP, lembrando que uma prioridade pequena implica em uma taxa de recarga pequena e, em contrapartida, uma prioridade elevada produz uma taxa de recarga também elevada.

O controlador lógico fuzzy, com sua base de conhecimento ajustada, também apresenta o comportamento descrito anteriormente. Entretanto, o controlador otimizado retorna uma taxa de recarga maior para o VEP com prioridade 1. No caso oposto, o VEP recebe uma quantidade menor de energia total da rede elétrica quando possui prioridade 0. Dessa forma, o método baseado em PSO otimizou a recarga do VEP de acordo com a prioridade inserida.

Para verificar a influência do controlador ajustado em relação ao controlador

Figura 15 – Resposta de um controlador fuzzy projetado e otimizado na recarga de um VEP com prioridades 0 e 1.



Fonte: Elaborado pelo autor.

projetado para diversos veículos, simulou-se a frota com os 20 VEPs expostos na Subseção 5.3.1. A Figura 16 apresenta os estados de carga das baterias dos cinco primeiros veículos sendo recarregados: (a) com o controlador fuzzy projetado e (b) com o controlador fuzzy ajustado.

Pela Figura 16 observa-se que o VEP 3, com prioridade 0,9, é recarregado mais rápido pelo controlador ajustado em comparação ao controlador projetado. Este veículo completa sua carga com uma hora de antecedência no controlador ajustado em relação ao comparador projetado.

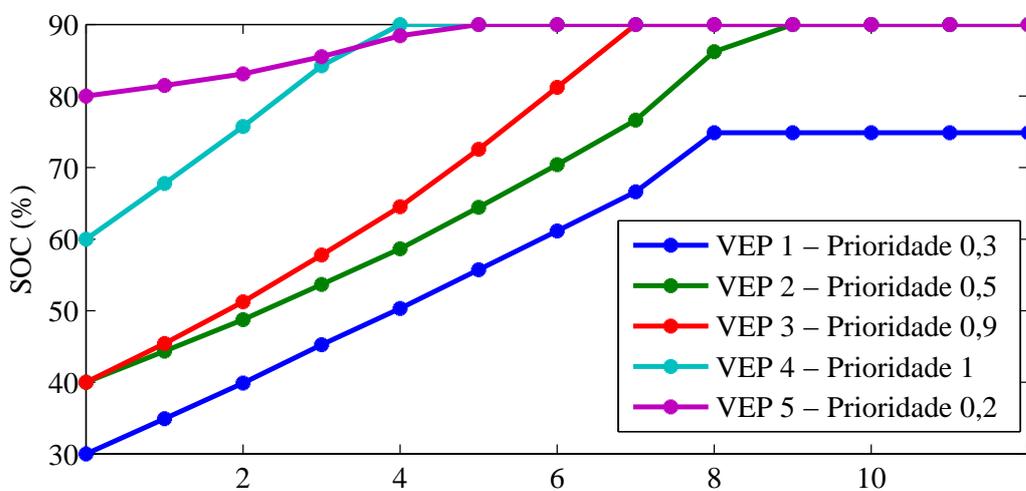
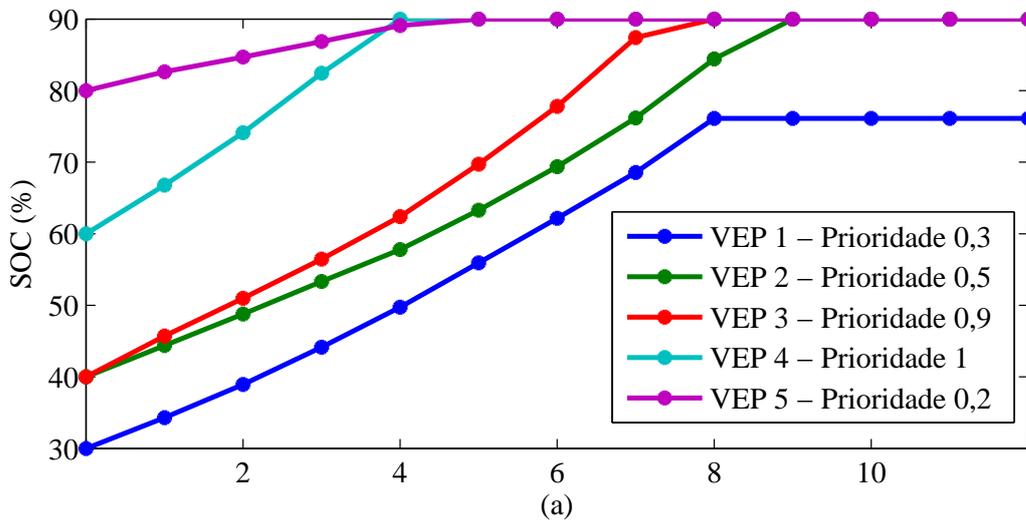
Ainda na mesma Figura, o VEP 4, com prioridade 1, possui uma taxa de recarga levemente maior calculada pelo controlador ajustado em relação ao projetado. O VEP 2, com prioridade 0,5, também tem sua taxa de recarga incrementada.

Em contrapartida, os VEPs 1 e 5, com prioridades 0,3 e 0,3, respectivamente, possuem suas taxas de recarga decrementadas pelo controlador ajustado em relação ao controlador projetado.

Os resultados anteriores evidenciam que o controlador ajustado, comparado com o controlador projetado está aumentando a taxa de recarga dos veículos com prioridade

alta e reduzindo a taxa de recarga dos veículos com prioridade baixa.

Figura 16 – Estados de carga atualizados para alguns VEPs com: (a) controlador fuzzy projetado e (a) controlador fuzzy ajustado.

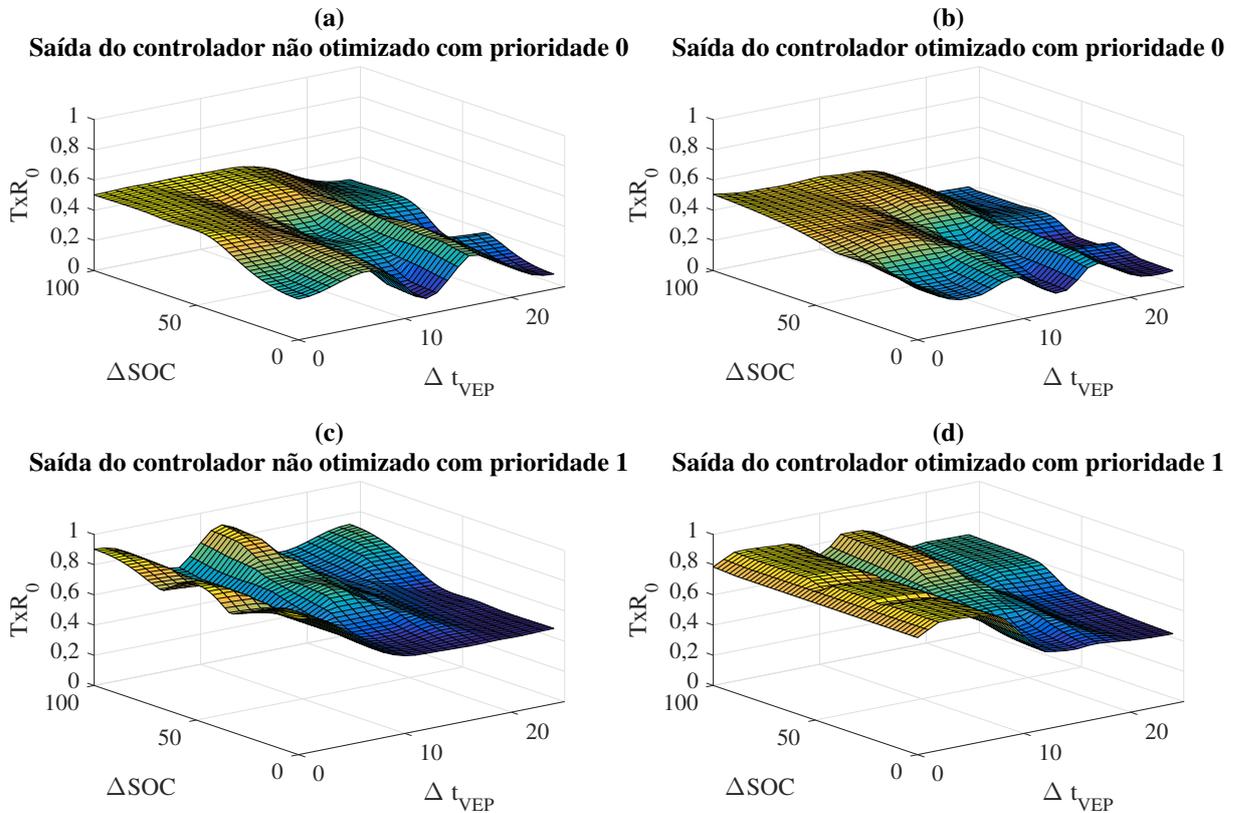


Fonte: Elaborado pelo autor.

As superfícies para a taxa de recarga do controlador fuzzy projetado e o controlador fuzzy otimizado para as prioridades 0 e 1 são apresentadas na Figura 17.

Observa-se que a superfície de saída do controlador projetado (Figura 17 (a)) foi aproximada da superfície desejada para a prioridade $\in [0; 0, 1]$ (Figura 14), conforme mostra a superfície da Figura 17 (b). O somatório das distâncias euclidianas entre os pontos da superfície do controlador projetado e a superfície desejada foi de 444,04. Já a mesma medida entre o controlador otimizado e a superfície desejada foi de 410,83. Estes

Figura 17 – Superfície de saída do controlador fuzzy: não otimizado com prioridade 0; otimizado com prioridade 0; não otimizado com prioridade 1; otimizado com prioridade 1.



Fonte: Elaborado pelo autor.

valores absolutos mostram que a saída do controlador otimizado está mais próxima da superfície desejada quando comparada com a do controlador projetado.

O mesmo comportamento apresentado acima é visualizado para a prioridade $\in [0, 9; 1]$. Ou seja, a superfície do controlador projetado (Figura 17 (c)) é aproximada da superfície desejada (Figura 14), conforme exposto pela Figura 17 (d). A distância entre a superfície do controlador projetado e a saída desejada é de 432,96. Já, entre a saída desejada e a superfície otimizada, mede-se uma distância de 388,24. Desta forma, estes valores indicam que a superfície de saída do controlador otimizado está mais próxima da superfície desejada quando comparando com o controlador fuzzy projetado.

Por fim, vale ressaltar que o ajuste da base de conhecimento do controlador lógico fuzzy acontece na realocação dos picos de todos os conjuntos fuzzy. Ou seja, a base de regras inicialmente projetada não é modificada durante o processo de otimização. Dessa forma, uma base de regras consistente e robusta deve ser fornecida para o correto funcionamento do método.

5.4 GERENCIAMENTO DOS AGREGADORES

5.4.1 GERENCIAMENTO DOS AGREGADORES NO SISTEMA TESTE DE 123 BARRAS

Conforme mostrado anteriormente, o controle da taxa de recarga dos VEPs é realizado em cada agregador com base no controlador fuzzy e utilizando os valores de potência recebidos do COD. É no COD que está o método de otimização que define os valores de potência para cada agregador, dentro do intervalo das potências mínima e máxima. O COD realiza isto com base nas condições do sistema visando minimizar as perdas elétricas. A função objetivo e as restrições utilizadas foram apresentadas na Seção 4.4.2 do Capítulo 4.

Para a aplicação do método de otimização no COD visando minimizar perdas de energia, utilizou-se o alimentador teste de distribuição 123 barras do IEEE Power & Energy Society disponível em PES (2010), representado esquematicamente na Figura 18. Esta rede elétrica é um alimentador típico de distribuição, caracterizando-se por ser radial, com linhas de distribuição aéreas e subterrâneas, cargas desbalanceadas do tipo PQ, corrente constante e impedância constante, quatro reguladores de tensão, bancos de capacitores e chaves de manobra. Os parâmetros do alimentador utilizado também estão disponíveis em PES (2010).

Este sistema teste foi implementado e seu fluxo de potência foi resolvido no OpenDSS. O OpenDSS é um software específico para simulação de sistemas de distribuição de energia elétrica, auxiliando na integração de recursos distribuídos e na modernização da rede elétrica para um ambiente *smart grid*. Dentre suas principais funcionalidades, ele permite a integração de suas simulações com outras ferramentas computacionais.

Alocaram-se 30 frotas de veículos elétricos *plug-in* com número variável de veículos nas barras destacadas da Figura 18. Os dados de cada frota foram gerados aleatoriamente e se encontram no Apêndice D. As potências mínima e máxima calculadas de cada agregador são apresentadas na Tabela 14.

Primeiramente, computou-se o fluxo de potência da rede elétrica teste pelo OpenDSS sem a inserção de nenhum veículo elétrico *plug-in*. Obteve-se 95,77 kW de perdas elétricas nas linhas e transformadores. A potência total da carga neste sistema é de 3512,5 kW. Logo, as perdas percentuais totalizam 2,73% para o circuito sob estudo.

Na sequência, as potências mínimas obtidas através do AHP foram atribuídas para cada agregador. Um total de 102,1 kW foi obtido de perdas elétricas, com a resolução do fluxo de potência. A carga instalada passou a ser 3630,4 kW. Com isso, as perdas de energia totalizam 2,81% para o sistema teste. Recebendo potência mínima, os agregadores totalizam 117,9 kW de carga, ou seja, 3,25% de toda a carga instalada.

Após, atribuíram-se as potências máximas para cada agregador. Nesta condição, o sistema passa a ter 136,46 kW de perdas de energia, representando 3,24% da carga. A

Tabela 14 – Potências mínima e máxima (em kW) de cada agregador.

Barra	2	6	11	16	22	29	32	37	43	46
P_{min}	5,1	5,28	5,75	1,74	4,25	0,46	3,43	2,2	2,2	4,11
P_{max}	26,04	25,21	32,93	7,74	29,18	3,39	37,59	23,99	18,2	21,15
Barra	50	56	59	60	64	69	71	74	77	80
P_{min}	1,6	0,66	2,97	1,48	0,48	6,56	0,07	11,88	2,03	6,83
P_{max}	15,76	3,10	13,37	7,36	4,01	37,22	2,11	37,50	17,22	50,95
Barra	85	88	92	99	100	102	106	109	111	114
P_{min}	5,94	10,18	0,53	2,58	1,42	7,3	5,94	3,52	3,01	8,41
P_{max}	34,82	58,47	4,41	13,67	14,25	38,22	38,63	18,06	20,18	46,42

Fonte: Elaborado pelo autor.

cada agregador dentro dos intervalos da Tabela 14. Para cada conjunto de potências dos trinta agregadores, computou-se o fluxo de potência e armazenou-se os valores das perdas elétricas totais.

Das simulações realizadas, o conjunto de potências dos agregadores que forneceram as menores perdas elétricas foram são apresentadas na Tabela 15.

Tabela 15 – Potências calculadas para cada agregador (kW).

Barra	2	6	11	16	22	29	32	37	43	46
P_D	9,43	16,51	25,82	2,07	24,92	2,41	32,51	7,08	10,85	18,05
Barra	50	56	59	60	64	69	71	74	77	80
P_D	13,90	2,72	7,30	4,91	1,92	25,12	1,76	13,21	7,86	38,86
Barra	85	88	92	99	100	102	106	109	111	114
P_D	21,01	15,75	2,08	8,87	5,27	14,74	34,76	8,70	10,43	14,01

Fonte: Elaborado pelo autor.

Este caso retornou 116,74 kW de perdas elétricas, representando 2,98% de toda a carga instalada. A carga total requisitada pelos agregadores foi de 402,80 kW, contabilizando 10,29% da carga instalada, que era 3915,3 kW.

A Tabela 16 apresenta os principais resultados obtidos com os casos simulados.

As perdas elétricas aumentaram em aproximadamente 6% entre o caso com as potências mínimas e o caso otimizado. Entretanto, a potência entregue para os VEPs aumentou 241,65% para os mesmos casos. Desta forma, a perda total elevou-se pouco, enquanto a energia entregue para os agregadores aumentou significativamente.

Da mesma maneira entre o caso com as potências máximas e o caso otimizado,

Tabela 16 – Potência recebida pelo agregador e perdas elétricas do sistema.

	Sem VEP	P_{min}	P_{max}	Caso otimizado
$\sum P_D$ (kW)	0	117,9	701,12	402,8
$\sum P_D$ (%)	0	3,25	16,63	10,29
Perdas totais (kW)	95,77	102,1	136,46	116,74
Perdas totais (%)	2,73	2,81	3,24	2,98

Fonte: Elaborado pelo autor.

tem-se uma redução de 8,03% de perdas de energia. Já a redução da energia entregue aos VEPs é de 42,55%. Obteve-se uma maior redução das perdas totais em relação à comparação anterior, enquanto a energia entregue para os VEPs foi reduzida em pequena escala.

Ressalta-se que o conjunto de potências otimizadas geradas pelo PSO está dentro do intervalo limitado pelos valores verificados para os casos em os agregadores recebem P_{min} e P_{max} , respectivamente. Desta forma, o menor valor de perdas retornado pelo PSO também estará dentro das perdas constadas para este intervalo de potências recebidas pelos agregadores. Como visto na Tabela 16, a menor perda seria gerada pelo caso de P_{min} , mas este caso somente atenderia uma pequena parcela dos VEPs. Já o caso oposto, com os agregadores recebendo potência máxima, atenderia todos os VEPs indiferentemente da prioridade sem otimizar a operação da rede. Assim, o método de otimização retorna as perdas minimizadas no intervalo $[P_{min}, P_{max}]$, enquanto aumenta a energia entregue às frotas de VEPs.

Desta forma, o método de otimização reduziu as perdas elétricas do sistema teste em relação ao caso de máximas potências, sem ocasionar uma diferença elevada na energia entregue aos VEPs. Em adição, com o caso das potências mínimas, as perdas elétricas retornadas são pequenas quando comparando com o aumento na energia entregue às frotas.

5.4.2 GERENCIAMENTO DOS AGREGADORES NO SISTEMA TESTE DE 34 BARRAS

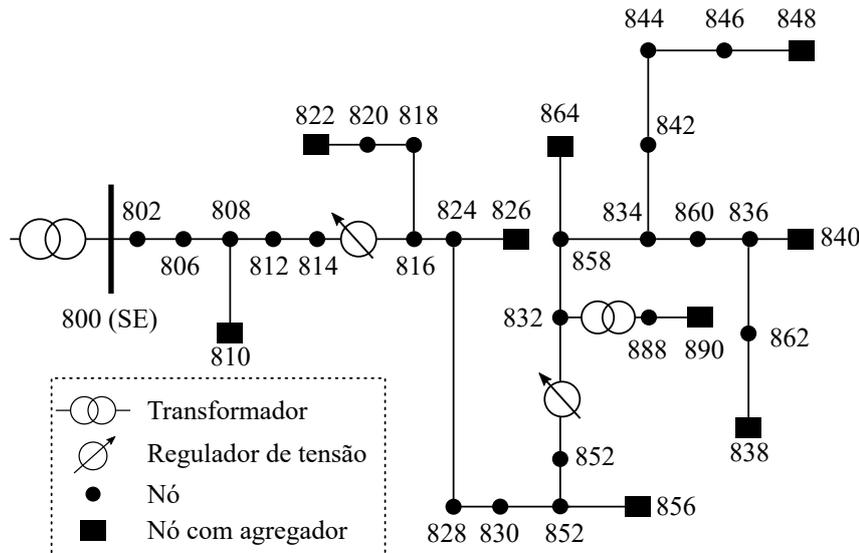
Da mesma forma que anteriormente, as potências de cada frota são determinadas pelo COD através do PSO. Entretanto, agora, o COD realiza a distribuição de potências visando minimizar as perdas de energia em outro sistema teste.

Para as simulações nesta aplicação, utilizou-se a rede elétrica teste de 34 barras do IEEE Power & Energy Society disponível em PES (2010), apresentada na Figura 19. Esta rede teste é um sistema típico de distribuição de energia elétrica, sendo um alimentador real do Arizona, EUA. Essa rede caracteriza-se por ser radial, longa, levemente carregada, com dois reguladores de tensão, um transformador alimentando uma barra em 4,16 kV,

cargas desequilibradas e capacitores *shunt*. O sistema teste foi implementado e o fluxo de potência foi resolvido pelo software OpenDSS.

Alocaram-se 9 frotas de VEPs no alimentador de 34 barras, conforme apresenta a Figura 19. As potências mínimas e máximas de cada agregador foram gerados aleatoriamente e são expostas na Tabela 17.

Figura 19 – Alimentador teste do IEEE de 34 barras utilizado para gerenciamento dos agregadores visando minimizar perdas de energia.



Fonte: Adaptado de PES (2010).

Tabela 17 – Potências mínima e máxima (em kW) de cada agregador no sistema teste IEEE 34 barras.

Barra	810	822	826	838	840	848	856	864	890
P_{min}	20	30	10	25	15	30	20	50	5
P_{max}	100	80	50	50	95	90	55	70	20

Fonte: Elaborado pelo autor.

Com o sistema teste, computaram-se os fluxos de potência para os seguintes casos: 1) sem a inserção de nenhum VEP; 2) com penetração das frotas de VEPs recebendo potência mínima, 3) com penetração das frotas de VEPs recebendo potência máxima e; 4) com penetração das frotas de VEPs recebendo potências calculadas pelo PSO no melhor caso retornado pelas simulações computacionais.

O PSO foi escolhido com base em Ghani, Gan e Hasan (2014) e Sanz et al. (2017). Nesses trabalhos, mostra-se que o PSO é muito adequado para aplicações buscando

minimizar desvios de tensão em sistemas elétricos. Os componentes cognitivo e social foram atribuídos como 2 e 2, seguindo as recomendações de Kennedy e Eberhart (1995). Já, o número de partículas e o critério de parada foram definidos empiricamente como 60 partículas e 30 iterações, respectivamente.

A simulação sem a inserção de nenhum VEP resultou em 272,28 kW de perdas de energia. Neste caso, as perdas percentuais representam 13,35% para o circuito sob estudo.

Com os agregadores recebendo as potências mínimas calculadas pelo AHP, um total de 333,68 kW de perdas elétricas foi computada com o OpenDSS. Isto equivale a 14,55% da carga instalada do sistema teste.

Já para o caso dos agregadores recebendo as potências máximas calculadas, um total de 469,73 kW de perdas de energia foi contabilizado, equivalendo a 16,94% da carga total da rede elétrica.

Por último, o melhor caso obtido pelo PSO de todas as simulações realizadas, retornou um total de 345,67 kW de perdas de energia. Neste caso, as perdas percentuais representam 14,86% da carga instalada do sistema elétrico sob estudo.

A carga referente à inserção dos VEPs, no caso das potências mínimas, totalizou 205 kW. Este valor equivale a 9,13% da carga total instalada do sistema teste. Para o caso das potências máximas, a carga total dos VEPs somou 610 kW, o que representa 23,02% da carga instalada. Já o caso otimizado pelo PSO, calculou 285,62 kW de potência total para os agregadores, o que equivale a 12,30% da carga instalada.

A Tabela 18 apresenta os resultados obtidos com os quatro casos relatados. Nessa Tabela, observa-se que as perdas de energia foram reduzidas pelo caso otimizado, quando comparado com o caso de potências máximas. Além disso, a carga entregue aos agregadores pelo PSO aumentou 30%, em comparação ao caso de potências mínimas.

Tabela 18 – Potência recebida pelo agregador e perdas elétricas no sistema teste de 34 barras.

	Sem VEP	P_{min}	P_{max}	Caso otimizado
$\sum P_D$ (kW)	0	205	610	285,62
$\sum P_D$ (%)	0	9,13	23,02	12,30
Perdas totais (kW)	272,28	333,68	469,73	345,67
Perdas totais (%)	13,55	14,55	16,94	14,86

Fonte: Elaborado pelo autor.

Da mesma forma que o sistema teste de 123 barras, o conjunto de potências geradas pelo PSO está dentro do intervalo de valores verificados para os agregadores recebendo P_{min} e P_{max} . Com isto, o menor valor de perdas retornado pelo PSO também estará dentro do intervalo de perdas limitados pelas referidas potências. Conforme a Tabela

18, a menor perda seria gerada pelo caso de P_{min} . Entretanto, ressalta-se que este caso somente atenderia uma pequena parcela dos VEPs. De forma análoga, o caso com os agregadores recebendo potência máxima atenderia todos os VEPs indiferentemente da prioridade, porém, sem otimizar a operação da rede. Desta forma, como no caso anterior, o método de otimização retorna as perdas minimizadas no intervalo $[P_{min}, P_{max}]$, enquanto aumenta a energia entregue às frotas de VEPs.

Com isso, o PSO aplicado ao gerenciamento dos agregadores também reduziu as perdas de energia do sistema teste em relação aos demais casos simulados. Além disso, a potência total calculada para o caso otimizado foi consideravelmente maior que o verificado para o caso das potências mínimas.

5.5 CONSIDERAÇÕES FINAIS

Neste Capítulo, apresentaram-se os principais resultados obtidos com o sistema proposto. No geral, verificou-se que o sistema proposto apresentou bons resultados no controle da recarga de VEPs, tanto antes do ajuste do controlador quanto depois. Entretanto, verificou-se que com o controlador ajustado a resposta é mais próxima do desejado. Em adição, o COD atuou como esperado no gerenciamento das frotas dos VEPs, onde reduziram-se as perdas de energia do sistema elétrico, com um significativo aumento da energia entregue para os agregadores. O Capítulo seguinte apresenta as conclusões e sugestões para trabalhos futuros.

6 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

6.1 CONCLUSÕES

Este trabalho apresentou um sistema para o controle inteligente da recarga de veículos elétricos *plug-in*, visando o benefício do sistema elétrico de potência e do consumidor. Consideraram-se informações como os estados de carga da bateria, o período de conexão para a recarga, a prioridade do consumidor e os parâmetros da rede elétrica.

Uma vez que os impactos da recarga dos VEPs na rede elétrica podem ser expressivos e diversos benefícios podem ser explorados, tem-se a fundamental importância de controlar a recarga dos veículos elétricos *plug-in*. Nesse contexto, o trabalho propõe uma nova metodologia para o controle inteligente da recarga de VEPs.

Inicialmente, apresentou-se a revisão bibliográfica contendo os principais impactos ocasionados no sistema elétrico pelos VEPs e os benefícios que os veículos podem fornecer. Abordaram-se também os desafios a serem superados para uma ampla difusão dos VEPs. Adicionalmente, as principais estratégias para a recarga dos VEPs foram apresentadas. Na sequência, a fundamentação teórica para o desenvolvimento e entendimento da proposta foi apresentada. Mostrou-se, então, a metodologia proposta. Em seguida, os resultados obtidos com ela foram apresentados.

Nos resultados, primeiramente correlacionou-se diretamente a influência da prioridade inserida pelo consumidor na recarga da bateria. Verificou-se ainda que uma prioridade maior implica em uma taxa de recarga maior e, conseqüentemente, o estado de carga da bateria sendo atualizado mais rápido.

Após o projeto de um controlador fuzzy, o mesmo foi ajustado usando dois métodos de otimização, os quais tiveram seus desempenhos comparados, de modo a determinar qual destes desempenha melhor a função a qual foi destinado. Nesse teste, verificou-se que o PSO obteve melhores resultados em relação aos atingidos pelo AG, sendo este escolhido para atuar no agregador como controlador de taxa de recarga.

Com o controlador ajustado, verificou-se a influência na recarga de uma frota de VEPs com prioridades mínima e máxima. O método de otimização escolhido ajustou a recarga dos VEPs de acordo com uma saída desejada, recarregando de forma mais rápida um veículo com prioridade alta e mais lentamente um com prioridade baixa, quando comparado com o desempenho do controlador inicialmente projetado.

No COD, o método de otimização por enxame de partículas atuou gerenciando as potências de cada agregador dentro de seus limites mínimo e máximo. Observou-se que esta interface de gerenciamento minimizou as perdas de energia elétrica no sistema teste sob estudo. Ao mesmo tempo, entregou uma quantidade total de energia significativa para os VEPs comparando com os casos sem otimização.

Desta forma, tendo em vista os resultados alcançados, acredita-se que a metodologia proposta nesta Dissertação ajuda a reduzir os impactos da recarga dos VEPs na rede

elétrica, enquanto levando em consideração os requerimentos do consumidor. O primeiro foi mostrado através da considerável redução das perdas de energia e dos desvios de tensão nas barras do sistema teste. Já o segundo, através da prioridade inserida pelo consumidor, influenciando diretamente na recarga dos VEPs. Assim, a proposta auxilia o agregador a reduzir o impacto, bem como permite beneficiar a rede elétrica, realizando a recarga de forma planejada, controlada e otimizada.

6.2 SUGESTÕES PARA TRABALHOS FUTUROS

Como sugestões para continuidade deste trabalho e com relação aos temas de VEPs no SEP, sugere-se:

- Utilizar os VEPs para injetar energia ativa na rede elétrica (descarga do veículo), possibilitando o fluxo de potência bidirecional;
- Realizar a recarga e descarga dos VEPs buscando minimizar a degradação das baterias;
- Incluir outras funções objetivo no gerenciamento dos agregadores, por exemplo: maximizar a energia entregue aos VEPs, minimizar o custo da recarga, reduzir o pico de carga, entre outros;
- Analisar a influência da utilização dos VEPs para auxiliar a rede elétrica na proteção do sistema elétrico;
- Coordenar a recarga e a descarga dos VEPs em uma rede elétrica com geração distribuída e sistemas de armazenamento de energia;
- Analisar a metodologia proposta para diferentes tipos de veículos elétricos;
- Coordenar os VEPs para o controle de reativo da rede elétrica;
- Integrar no sistema proposto a resposta a demanda através da tarifa incentivada.

REFERÊNCIAS

- AHMAD, M. R.; OTHMAN, M. M. Optimal charging strategy for plug-in hybrid electric vehicle using evolutionary algorithm. In: *IEEE International Power Engineering and Optimization Conference*. Langkawi: IEEE, 2014. p. 557–562. ISBN 9781479924226.
- ALONSO, J. A.; LAMATA, M. T. Consistency in the analytic hierarchy process: a new approach. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, v. 14, n. 04, p. 445–459, 2006. Disponível em: <<http://www.worldscientific.com/doi/abs/10.1142/S0218488506004114>>.
- ANSARI, M. et al. Coordinated bidding of ancillary services for vehicle-to-grid using fuzzy optimization. *IEEE Transactions on Smart Grid*, v. 6, n. 1, p. 261–270, 2015.
- AUPETIT, B.; GENEST, C. On some useful properties of the Perron eigenvalue of a positive reciprocal matrix in the context of the analytic hierarchy process. *European Journal of Operational Research*, v. 70, n. 2, p. 263–268, 1993. ISSN 03772217.
- AXSEN, J.; KURANI, K. S. Anticipating plug-in hybrid vehicle energy impacts in California: constructing consumer-informed recharge profiles. *Transportation Research Part D: Transport and Environment*, Elsevier Ltd, v. 15, n. 4, p. 212–219, 2010. ISSN 13619209. Disponível em: <<http://dx.doi.org/10.1016/j.trd.2010.02.004>>.
- BAI, X.; QIAO, W. Robust optimization for bidirectional dispatch coordination of large-scale V2G. *IEEE Transactions on Smart Grid*, v. 6, n. 4, p. 1944–1954, 2015.
- BANKS, A.; VINCENT, J.; ANYAKOHA, C. A review of particle swarm optimization. part I: background and development. *Natural Computing*, Springer, v. 6, n. 4, p. 467–484, 2007.
- BARAN, R.; LEGEY, L. F. L. Veículos elétricos: história e perspectivas no Brasil. *XIII Congresso Brasileiro de Energia*, v. 33, p. 207–224, 2010. Disponível em: <http://www.bndespar.com.br/SiteBNDES/export/sites/default/bndes{_}pt/Galerias/Arquivos/conhecimento/bnset/set3306>.
- BASSO, C. *O impacto dos veículos elétricos plug-in no sistema elétrico de potência*. Alegrete: Universidade Federal do Pampa, 2011. 66 p. Disponível em: <https://docs.google.com/open?id=0B13shT{_}nfa0DaURkVTVQZjhl>.
- BRINKMAN, N. et al. *Well-to-wheels analysis of advanced fuel/vehicle systems - a North American study of energy use, greenhouse gas emissions, and criteria pollutant emissions*. [S.l.], 2005. Disponível em: <<http://www.transportation.anl.gov/pdfs/TA/339.pdf>>.
- CHAN, C. C. An overview of electric vehicle technology. *Proceedings of the IEEE*, v. 81, n. 9, p. 1202–1213, 1993. ISSN 00189219.
- CHAN, C. C.; BOUSCAYROL, A.; CHEN, K. Electric, hybrid, and fuel-cell vehicles: architectures and modeling. *IEEE Transactions on Vehicular Technology*, v. 59, n. 2, p. 589–598, 2010.
- CLEMENT-NYNS, K.; HAESSEN, E.; DRIESEN, J. The impact of charging plug-in hybrid electric vehicles on a residential distribution grid. *IEEE Transactions on Power Systems*, v. 25, n. 1, p. 371–380, 2010. ISSN 08858950.

- COLLINS, M. M.; MADER, G. H. The timing of EV recharging and its effect on utilities. *IEEE Transactions on Vehicular Technology*, v. 32, n. 1, p. 90–97, 1983. ISSN 19399359.
- DEILAMI, S. et al. Real-time coordination of plug-in electric vehicle charging in smart grids to minimize power losses and improve voltage profile. *IEEE Transactions on Smart Grid*, v. 2, n. 3, p. 456–467, 2011. ISSN 19493053.
- DENHOLM, P.; KUSS, M.; MARGOLIS, R. M. Co-benefits of large scale plug-in hybrid electric vehicle and solar PV deployment. *Journal of Power Sources*, Elsevier B.V, v. 236, p. 350–356, 2013. ISSN 03787753. Disponível em: <<http://dx.doi.org/10.1016/j.jpowsour.2012.10.007>>.
- DENHOLM, P.; SHORT, W. An evaluation of utility system impacts and benefits of optimally dispatched plug-in hybrid electric vehicles. *NREL Report noTP-620*, n. October, p. 41, 2006. ISSN NREL/TP-620-40293;. Disponível em: <<http://www.nrel.gov/docs/fy07osti/40293.pdf>>.
- DUVALL, M.; KNIPPING, E. *Environmental assessment of plug-in hybrid electric vehicles - volume 1: nationwide greenhouse gas emissions*. Palo Alto, CA, 2007. v. 1, 56 p.
- ELNOZAHY, M. S.; SALAMA, M. M. a. A comprehensive study of the impacts of PHEVs on residential distribution networks. *IEEE Transactions on Sustainable Energy*, v. 5, n. 1, p. 332–342, 2014. ISSN 19493029.
- ESMIN, a. a. a.; LAMBERT-TORRES, G.; Zambroni de Souza, a. C. A hybrid particle swarm optimization applied to loss power minimization. *IEEE Transactions on Power Systems*, v. 20, n. 2, p. 859–866, 2005. ISSN 0885-8950.
- GAN, L.; TOPCU, U.; LOW, S. Optimal decentralized protocol for electric vehicle charging. In: *IEEE Conference on Decision and Control*. Orlando, FL: IEEE, 2013. p. 5798–5804. ISBN 9781612848006. ISSN 08858950.
- GENG, B.; MILLS, J. K.; SUN, D. Two-stage charging strategy for plug-in electric vehicles at the residential transformer level. *IEEE Transactions on Smart Grid*, v. 4, n. 3, p. 1442–1452, 2013. ISSN 19493053.
- GHANI, M. A.; GAN, C.; HASAN, I. Optimum distributed generation allocation using pso in order to reduce losses and voltage improvement. *3rd IET International Conference on Clean Energy and Technology (CEAT) 2014*, p. 29 (6 .)–29 (6 .), 2014. Disponível em: <<http://digital-library.theiet.org/content/conferences/10.1049/cp.2014.1476>>.
- GHOFRANI, M.; ARABALI, A.; GHAYEKHLOO, M. Optimal charging/discharging of grid-enabled electric vehicles for predictability enhancement of PV generation. *Electric Power Systems Research*, Elsevier B.V., v. 117, p. 134–142, 2014. ISSN 03787796. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0378779614003046>>.
- GIGLIOLI, R. et al. Impact of a large fleet of EVs on the efficiency and reliability of an electric power system. In: *IEEE International Electric Vehicle Conference*. Florence: IEEE, 2014. p. 1–7. ISBN 9781479960750.
- GREFENSTETTE, J. J. Optimization of control parameters for genetic algorithms. *IEEE Transactions on Systems, Man and Cybernetics*, v. 16, n. 1, p. 122–128, 1986. ISSN 0018-9472.

- GUILLE, C.; GROSS, G. A conceptual framework for the vehicle-to-grid (V2G) implementation. *Energy Policy*, Elsevier, v. 37, n. 11, p. 4379–4390, 2009. ISSN 03014215. Disponível em: <<http://dx.doi.org/10.1016/j.enpol.2009.05.053>>.
- GUROCAK, H. B. A genetic-algorithm-based method for tuning fuzzy logic controllers. *Fuzzy Sets and Systems*, v. 108, n. 1, p. 39–47, 1999. ISSN 0165-0114. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0165011497003096>>.
- HADDADIAN, G. et al. Optimal scheduling of distributed battery storage for enhancing the security and the economics of electric power systems with emission constraints. *Electric Power Systems Research*, Elsevier B.V., v. 124, p. 152–159, 2015. ISSN 03787796. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0378779615000620>>.
- HAJFOROOSH, S.; MASOUM, M. a.S.; ISLAM, S. M. Real-time charging coordination of plug-in electric vehicles based on hybrid fuzzy discrete particle swarm optimization. *Electric Power Systems Research*, Elsevier B.V., v. 128, p. 19–29, 2015. ISSN 03787796. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0378779615001959>>.
- HALBLEIB, A.; TURNER, M.; NABER, J. Control of battery electric vehicle charging for commercial time of day demand rate payers. In: *2012 IEEE PES Innovative Smart Grid Technologies, ISGT 2012*. Washington, DC: IEEE, 2012. p. 1–5. ISBN 9781457721588.
- HAN, S.; HAN, S.; SEZAKI, K. Development of an optimal vehicle-to-grid aggregator for frequency regulation. *IEEE Transactions on Smart Grid*, v. 1, n. 1, p. 65–72, 2010. ISSN 19493053.
- HU, J. et al. Coordinated charging of electric vehicles for congestion prevention in the distribution grid. *IEEE Transactions on Smart Grid*, v. 5, n. 2, p. 703–711, 2014. ISSN 19493053.
- ILIĆ, D.; KARNOUSKOS, S.; BEIGL, M. Improving accuracy of energy forecasting through the presence of an electric vehicle fleet. *Electric Power Systems Research*, v. 120, p. 32–38, 2015. ISSN 03787796. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0378779614003629>>.
- IPAKCHI, A.; ALBUYEH, F. Grid of the future. *IEEE Power and Energy Magazine*, v. 7, n. 2, p. 52–62, 2009. ISSN 15407977.
- JIANG, C. et al. Method to assess the power-quality impact of plug-in electric vehicles. *IEEE Transactions on Power Delivery*, v. 29, n. 2, p. 958–965, 2014. ISSN 08858977.
- JOURABCHI, J. *Impact of plug-in hybrid vehicles on Northwest power system: a preliminary assessment*. Portland, OR, 2008.
- KAVOUSI-FARD, A. et al. Reliability-oriented reconfiguration of vehicle-to-grid networks. *IEEE Transactions on Industrial Informatics*, v. 11, n. 3, p. 682–691, 2015.
- KEMPTON, W.; TOMIĆ, J. Vehicle-to-grid power fundamentals: calculating capacity and net revenue. *Journal of Power Sources*, v. 144, n. 1, p. 268–279, 2005. ISSN 03787753.
- KEMPTON, W.; TOMIĆ, J. Vehicle-to-grid power implementation: from stabilizing the grid to supporting large-scale renewable energy. *Journal of Power Sources*, v. 144, n. 1, p. 280–294, 2005. ISSN 03787753.

KENNEDY, J.; EBERHART, R. Particle swarm optimization. *Neural Networks, 1995. Proceedings., IEEE International Conference on*, v. 4, p. 1942–1948 vol.4, 1995. ISSN 19353812.

KINTNER-MEYER, M.; SCHNEIDER, K.; PRATT, R. *Impacts assessment of plug-in hybrid vehicles on electric utilities and regional U.S. power grids*. Richland, WA, 2007. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.105.663&rep=rep1&ty>>.

LIU, H. et al. Vehicle-to-grid control for supplementary frequency regulation considering charging demands. *IEEE Transactions on Power Systems*, v. 30, n. 6, p. 3110–3119, 2015.

MAMDANI, E. H.; ASSILIAN, S. An experiment in linguistic synthesis with a fuzzy logic controller. *International journal of man-machine studies*, Elsevier, v. 7, n. 1, p. 1–13, 1975.

MANZ, D. et al. The grid of the future. *IEEE Power and Energy Magazine*, v. 12, n. 3, p. 26–36, 2014.

MASOUM, M. a. S.; MOSES, P. S.; HAJFOROOSH, S. Distribution transformer stress in smart grid with coordinated charging of plug-in electric vehicles. In: *IEEE PES Innovative Smart Grid Technologies*. Washington, DC: IEEE, 2012. p. 1–8. ISBN 9781457721588.

MATHWORKS. *Fuzzy inference process*. 2017. Disponível em: <<https://www.mathworks.com/help/fuzzy/fuzzy-inference-process.html>>.

MELIOPOULOS, S. et al. *Power system level impacts of plug-in hybrid vehicles*. Atlanta, Georgia, 2009. 86 p.

NGUYEN, H. N. T.; ZHANG, C.; MAHMUD, A. Optimal coordination of G2V and V2G to support power grids with high penetration of renewable energy. *IEEE Transactions on Transportation Electrification*, v. 1, n. 2, p. 188–195, 2015.

OLIVEIRA, D. Q.; SOUZA, A. C. Z. D.; DELBONI, L. N. Optimal plug-in hybrid electric vehicles recharge in distribution power systems. *Electric Power Systems Research*, Elsevier B.V., v. 98, p. 77–85, 2013. ISSN 03787796. Disponível em: <<http://dx.doi.org/10.1016/j.epsr.2012.12.012>>.

ORR, J. A.; EMANUEL, A. E.; OBERG, K. W. Current harmonics generated by a cluster of electric vehicle battery chargers. *IEEE Transactions on Power Apparatus and Systems*, PAS-101, n. 3, p. 691–700, 1982. ISSN 00189510.

PAMPLONA, E. D. O. Avaliação qualitativa de cost drivers pelo método ahp. In: *Anais do Congresso Brasileiro de Custos-ABC*. [S.l.: s.n.], 1999.

PAPADOPOULOS, P. et al. Coordination of the charging of electric vehicles using a multi-agent system. *IEEE Transactions on Smart Grid*, v. 4, n. 4, p. 1802–1809, 2013. ISSN 1949-3053. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-84883893747&partnerID=40&md5=07bf07b4ba8042a60c17580b90>>.

PES, I. *Distribution test feeders*. 2010. Disponível em: <<http://ewh.ieee.org/soc/pes/dsacom/testfeeders/>>.

- QIAN, K. et al. Modeling of load demand due to EV battery charging in distribution systems. *IEEE Transactions on Power Systems*, v. 26, n. 2, p. 802–810, 2011. ISSN 08858950.
- RAHMAN, S.; SHRESTHA, G. B. An investigation into the impact of electric vehicle load on the electric utility distribution system. *IEEE Transactions on Power Delivery*, v. 8, n. 2, p. 591–597, 1993. ISSN 08858977.
- RAJABI, M.; ESMALI, M. Optimal charging of plug-in electric vehicles observing power grid constraints. *IET Generation, Transmission & Distribution*, v. 8, n. 4, p. 583–590, 2014. ISSN 1751-8687. Disponível em: <<http://digital-library.theiet.org/content/journals/10.1049/iet-gtd.2013.0628>>.
- RAMTEEN, S.; DENHOLM, P. Emissions impacts and benefits of plug-in hybrid electric vehicles and vehicle-to-grid services emissions impacts and benefits of plug-in hybrid electric vehicles and vehicle-to-grid services. *Environmental Science & Technology*, v. 43, n. 4, p. 1199–1204, 2009.
- RAO, S. S. *Engineering optimization: theory and practice*. 4. ed. New Jersey: John Wiley & Sons, 2009. 830 p.
- RAUTIAINEN, A. et al. Plug-in vehicle ancillary services for a distribution network. In: *8th International Conference and Exhibition on Ecological Vehicles and Renewable Energies*. Monte Carlo: IEEE, 2013. p. 1–8. ISBN 9781467352703.
- REZNIK, L. *Fuzzy controllers handbook*. 1. ed. Newnes: Oxford, 1997. 240 p.
- RÍOS, A. D. L. et al. Economic analysis of vehicle-to-grid (V2G)-enabled fleets participating in the regulation service market. In: *IEEE PES Innovative Smart Grid Technologies*. Washington, DC: IEEE, 2012. p. 1–8. ISBN 9781457721588.
- ROSS, T. *Fuzzy logic with engineering applications*. 3. ed. Oxford: John Wiley & Sons, Inc., 2010. 606 p. ISBN 9780470743768.
- SAATY, T. L.; TRAN, L. T. On the invalidity of fuzzifying numerical judgments in the Analytic Hierarchy Process. *Mathematical and Computer Modelling*, v. 46, n. 7-8, p. 962–975, 2007. ISSN 08957177.
- SALDANHA, J. J. A. et al. Control strategies for smart charging and discharging of plug-in electric vehicles. In: *Smart Cities Technologies*. Croatia: InTech, 2016.
- SANZ, I. et al. Reconfiguration algorithm to reduce power losses in offshore hvdc transmission lines. *IEEE Transactions on Power Electronics*, v. 8993, n. c, p. 1–1, 2017. ISSN 0885-8993. Disponível em: <<http://ieeexplore.ieee.org/document/7934344/>>.
- SHAABAN, M. F. et al. Real-time PEV charging/discharging coordination in smart distribution systems. *IEEE Transactions on Smart Grid*, v. 5, n. 4, p. 1797–1807, 2014. ISSN 19493053.
- SHAFIEE, S.; FOTUHI-FIRUZABAD, M.; RASTEGAR, M. Investigating the impacts of plug-in hybrid electric vehicles on power distribution systems. *IEEE Transactions on Smart Grid*, v. 4, n. 3, p. 1351–1360, 2013. ISSN 1949-3053.

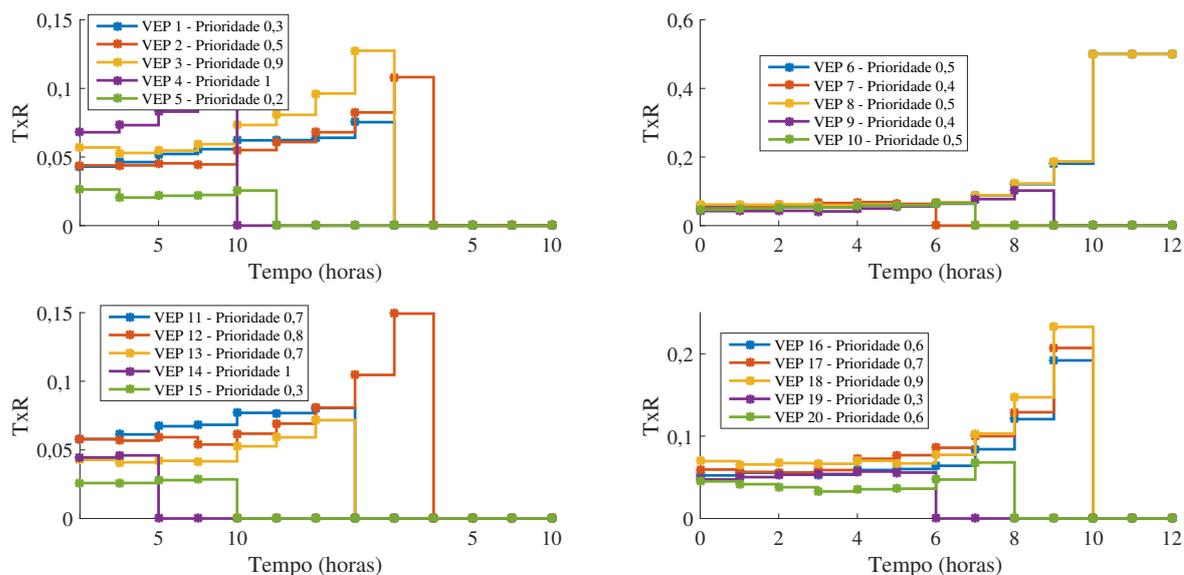
- SILVA, P. A. S. d. *Metodologia para tomada de decisão multicriterial no processo de restabelecimento automático de energia elétrica*. Alegrete: Universidade Federal do Pampa, 2011. 90 p.
- SIMÕES, M. G.; SHAW, I. S. *Controle e modelagem fuzzy*. 2. ed. São Paulo: Blucher, 2007. 186 p.
- SINGH, M. et al. Real-time coordination of electric vehicles to support the grid at the distribution substation level. *IEEE Systems Journal*, v. 9, n. 3, p. 1000–1010, 2015.
- SOARES, F. J.; ALMEIDA, P. M. R.; LOPES, J. a. P. Quasi-real-time management of electric vehicles charging. *Electric Power Systems Research*, v. 108, p. 293–303, 2014. ISSN 03787796.
- SORTOMME, E.; EL-SHARKAWI, M. A. Optimal charging strategies for unidirectional vehicle-to-grid. *IEEE Transactions on Smart Grid*, v. 2, n. 1, p. 119–126, 2011. ISSN 19493053.
- SORTOMME, E.; EL-SHARKAWI, M. A. Optimal scheduling of vehicle-to-grid energy and ancillary services. *IEEE Transactions on Smart Grid*, v. 3, n. 1, p. 351–359, 2012. ISSN 19493053.
- SPERANDIO, M.; SALDANHA, J. J. A.; BASSO, C. O Impacto dos Veículos Elétricos Plug-In no Sistema de Transmissão. In: *XIX Congresso Brasileiro de Automática*. Campina Grande: UFCG, 2012. p. 1–6.
- STEPHAN, C. H.; SULLIVAN, J. Environmental and energy implications of plug-in hybrid electric vehicles. *Environmental Science & Technology*, v. 42, n. 4, p. 1185–1190, 2008.
- TOMIĆ, J.; KEMPTON, W. Using fleets of electric-drive vehicles for grid support. *Journal of Power Sources*, v. 168, n. 2, p. 459–468, 2007. ISSN 03787753.
- TUTTLE, D. P.; BALDICK, R. The evolution of plug-in electric vehicle-grid interactions. *IEEE Transactions on Smart Grid*, v. 3, n. 1, p. 500–505, 2012. ISSN 19493053.
- VAYÁ, M. G.; ANDERSSON, G. Self scheduling of plug-in electric vehicle aggregator to provide balancing services for wind power. *IEEE Transactions on Sustainable Energy*, v. 7, n. 2, p. 886–899, 2016. ISSN 19493029.
- VELDMAN, E.; VERZIILBERGH, R. a. Distribution grid impacts of smart electric vehicle charging from different perspectives. *IEEE Transactions on Smart Grid*, v. 6, n. 1, p. 333–342, 2015. ISSN 1949-3053.
- VITHAYASRICHAREON, P.; MILLS, G.; MACGILL, I. F. Impact of electric vehicles and solar PV on future generation portfolio investment. *IEEE Transactions on Sustainable Energy*, v. 6, n. 3, p. 899–908, 2015.
- WANG, J. et al. Impact of plug-in hybrid electric vehicles on power systems with demand response and wind power. *Energy Policy*, Elsevier, v. 39, n. 7, p. 4016–4021, 2011. ISSN 03014215. Disponível em: <<http://dx.doi.org/10.1016/j.enpol.2011.01.042>>.

- WANG, Y. et al. Research of AHP model on combination between the social responsibility and the economic benefits in corporation. In: IEEE. *Business and Information Management, 2008. ISBIM'08. International Seminar on*. Wuhan, Hubei, China, 2008. v. 2, p. 449–452.
- WANG, Z.; WANG, S. Grid power peak shaving and valley filling using vehicle-to-grid systems. *IEEE Transactions on Power Delivery*, v. 28, n. 3, p. 1822–1829, 2013. ISSN 08858977.
- WARAICH, R. A. et al. Plug-in hybrid electric vehicles and smart grids: investigations based on a microsimulation. *Transportation Research Part C: Emerging Technologies*, v. 28, p. 74–86, 2013. ISSN 0968090X. Disponível em: <<http://dx.doi.org/10.1016/j.trc.2012.10.011>>.
- WEIHAO, H. et al. Optimal operation of plug-in electric vehicles in power systems with high wind power penetrations. *IEEE Transactions on Sustainable Energy*, v. 4, n. 3, p. 577–585, 2013. ISSN 1949-3029. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-84880261770&partnerID=40&md5=4168bdf909c45dce5c79de713e>>.
- WILLIAMSON, S.; EMADI, a. Comparative assessment of hybrid electric and fuel cell vehicles based on comprehensive well-to-wheels efficiency analysis. *IEEE Transactions on Vehicular Technology*, v. 54, n. 3, p. 856–862, 2005. ISSN 0018-9545.
- WOLFF, C. S. *O método AHP - revisão conceitual e proposta de simplificação*. Rio de Janeiro: Pontifícia Universidade Católica do Rio de Janeiro, 2008. 138 p.
- WU, D. et al. Transient stability analysis of SMES for smart grid with vehicle-to-grid operation. *IEEE Transactions on Applied Superconductivity*, v. 22, n. 3, 2012. ISSN 10518223.
- YILMAZ, M.; KREIN, P. T. Review of the impact of vehicle-to-grid technologies on distribution systems and utility interfaces. *IEEE Transactions on Power Electronics*, v. 28, n. 12, p. 5673–5689, 2013. ISSN 08858993.
- ZHANG, C. et al. Impacts of electric vehicles on the transient voltage stability of distribution network and the study of improvement measures. In: *IEEE PES Asia-Pacific Power and Energy Engineering Conference*. Hong Kong: IEEE, 2014. p. 1–6. ISBN 9781479975372.
- ZOU, S.; LIU, X. A distributed charging coordination for large-scale plug-in electric vehicles considering battery degradation cost. *IEEE Transactions on Control Systems Technology*, v. 23, n. 5, p. 2044–2052, 2015.

APÊNDICE A – TAXAS DE RECARGAS E ESTADOS DE CARGA DOS 20 VEPs

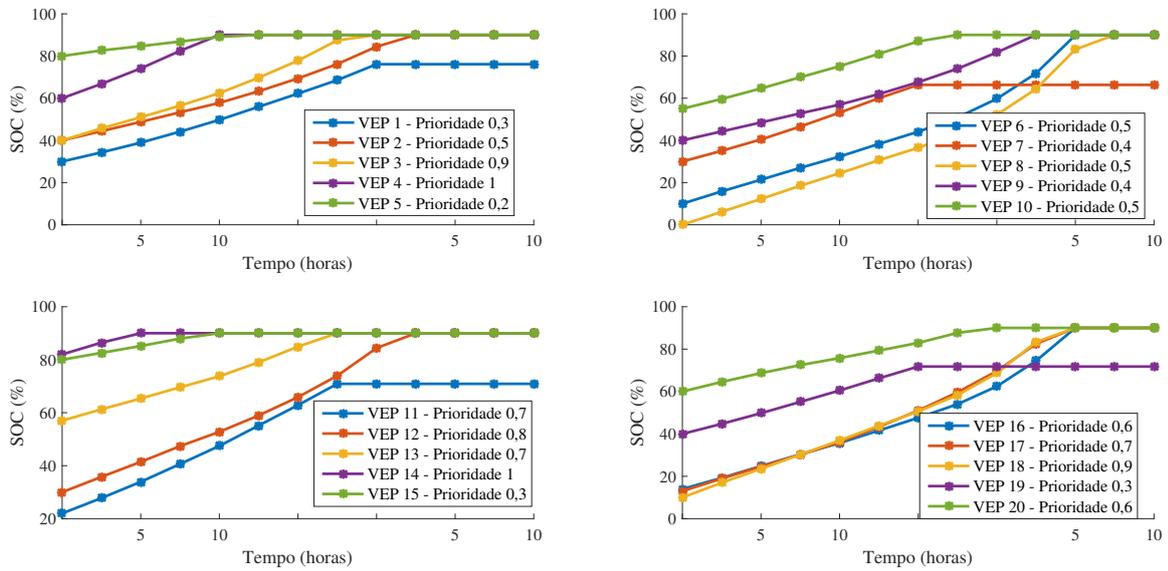
As Figuras 20 e 21 apresentam, respectivamente, as taxas de recarga e os estados de carga das baterias dos 20 VEPs utilizados para a validação do controlador fuzzy projetado.

Figura 20 – Taxas de recarga para os 20 VEPs da frota estudada.



Fonte: Elaborado pelo autor.

Figura 21 – Estados de carga das baterias dos 20 VEPs da frota estudada.



Fonte: Elaborado pelo autor.

APÊNDICE B – DADOS DOS 20 VEPs UTILIZADOS EM UM AGREGADOR

O estado de carga final (SOC_f) e a capacidade da bateria (B_{cap}) de cada VEP, foram definidos como 90% e 22 kW, respectivamente.

Tabela 19 – Frota de VEPs utilizada no controlador lógico fuzzy projetado.

VEP	1	2	3	4	5	6	7	8	9
SOC_0	30	40	40	60	80	10	30	0	40
Δt	8	13	10	4	15	13	5	13	12
prioridade	0,30	0,50	0,90	1,00	0,20	0,50	0,40	0,50	0,40
VEP	10	11	12	13	14	15	16	17	18
SOC_0	55	22	30	57	82	80	14	13	10
Δt	7	6	12	13	11	14	15	10	13
prioridade	0,50	0,70	0,80	0,70	1,00	0,30	0,60	0,70	0,90
VEP	19	20							
SOC_0	40	60							
Δt	5	16							
prioridade	0,30	0,60							

APÊNDICE C – COMPARAÇÃO ENTRE O AG E O PSO PARA O AJUSTE DO CONTROLADOR FUZZY PROJETADO

Para a utilização do AG, codificou-se cada localização do pico em uma string de 12 bits. O controlador fuzzy projetado anteriormente possui 14 conjuntos fuzzy distintos, logo cada cromossomo tem comprimento de 168 bits. O algoritmo genético foi executado com uma população de 20 cromossomos, 30 gerações, uma taxa de mutação de 2% e uma taxa de recombinação de 75%. Estes parâmetros foram definidos conforme recomendações iniciais de Grefenstette (1986) e após diversas simulações computacionais.

Com o PSO, utilizou-se uma população com 20 partículas, os coeficientes cognitivo e social foram ajustados com valor 2 e critério de parada de 30 iterações. Ambos os coeficientes foram estabelecidos com estes valores seguindo recomendações de Kennedy e Eberhart (1995). O número de partículas e o critério de parada foram definidos empiricamente. As posições das partículas foram limitadas entre os valores mínimo e máximo conforme o intervalo de ajuste apresentado na Tabela 20. Desta forma, permite-se a manipulação de cada pico sem que uma inferência sem significado seja gerada. Além disto, as velocidades das partículas também foram limitadas no valor 10.

As melhores aptidões resultantes para os dois métodos foram obtidas com os parâmetros apresentados na Tabela 20. As aptidões foram, para o AG e PSO, respectivamente, 243,5460 e 233,1889. Na tabela apresentam-se os intervalos de ajuste, os parâmetros iniciais do controlador lógico fuzzy e os resultados da otimização.

Tabela 20 – Parâmetros dos conjuntos fuzzy antes e após a otimização com AG e PSO.

Conjunto fuzzy		a	b	Intervalo de ajuste do pico	x_0	$x_{0,AG}^*$	$x_{0,PSO}^*$
Δt_{VEP}	Pouco	10	3	[0,5]	0	4,81	1,8679
	Médio	10	10	[7,17]	12	13,29	15,3153
	Alto	10	3	[19, 24]	24	22,48	22,1868
ΔSOC	Baixa	184	1	[0, 20]	0	4,376	11,2591
	Média	184	4	[40, 65]	50	41,78	48,0412
	Alta	184	1	[80, 100]	100	84,99	87,5361
prioridade	Não	5	500	[0, 0,20]	0	0,0469	0,0939
	Talvez	5	600	[0,35, 0,55]	0,5	0,4315	0,4674
	Sim	5	500	[0,7, 1]	1	0,8536	0,9889
TxR_0	Zero	0,5	200	[0, 0,08]	0	0,0526	0,0359
	Baixa	0,5	400	[0,15, 0,35]	0,25	0,1671	0,2479
	Média	0,5	400	[0,42, 0,60]	0,5	0,4666	0,5054
	Média-Alta	0,5	400	[0,68, 0,80]	0,75	0,7124	0,7435
	Alta	0,5	200	[0,90, 1]	1	0,9855	0,948

Fonte: Elaborado pelo autor.

Na Tabela 20, a e b são constantes que controlam a abertura do conjunto fuzzy, x_0 representa a localização do pico do conjunto fuzzy antes da otimização, $x_{0,AG}^*$ indica

a localização do pico do conjunto fuzzy após a otimização com o AG e $x_{0,PSO}^*$ indica a localização do pico do conjunto fuzzy após o ajuste com o PSO.

Visando obter maiores informações sobre o desempenho de cada método, apresentam-se na sequência outras comparações entre os métodos, como em relação ao tempo computacional, bem como sobre a média e o desvio padrão das aptidões.

O controlador lógico fuzzy foi ajustado 20 vezes por cada método de otimização, sendo estas independentes umas das outras, com diferentes valores iniciais da população, os quais foram aleatoriamente escolhidos. Para cada algoritmo, em cada execução, a solução ótima encontrada foi armazenada. Após, calculou-se a média e o desvio padrão populacional das 20 execuções para cada método de otimização. A Tabela 21 apresenta os resultados obtidos.

Tabela 21 – Média e desvio padrão populacional das aptidões finais em 20 execuções independentes de cada algoritmo.

	AG	PSO
Média (μ)	287,0358	236,9428
Desvio padrão populacional (σ)	30,1083	2,3766

Fonte: Elaborado pelo autor.

A Tabela 21 mostra que o PSO apresentou a melhor média das aptidões no ajuste do controlador fuzzy. Além disso, o desvio padrão populacional deste método também é expressivamente menor dentre os dois algoritmos comparados. Desta forma, o PSO retornou soluções otimizadas mais próximas umas das outras, enquanto o AG desviou-se mais durante as 20 execuções.

A otimização do controlador fuzzy não necessita ser realizada em tempo real, pois seu ajuste é realizado antes da execução do sistema de controle da recarga dos VEPs. Desta forma, o tempo computacional de execução não tem grande importância nesta aplicação. Entretanto, para fins de comparação entre os métodos de otimização, o tempo de uma única execução da melhor solução encontrada para ambos são apresentados na Tabela 22.

Tabela 22 – Tempo de uma única execução dos métodos para o ajuste do controlador lógico fuzzy.

	AG	PSO
Tempo de uma única execução (segundos)	988,3463	950,4188

Fonte: Elaborado pelo autor.

Pela Tabela 22, percebe-se que o PSO necessitou de menos tempo para uma única

execução quando comparado com o algoritmo genético. Assim, em termos de tempo de execução, o PSO é o melhor entre os dois métodos.

Apesar de serem tempos relativamente grandes ($\sim 15-17$ minutos para uma execução), o ajuste do controlador não é invalidado em nenhum dos métodos. Mesmo que uma nova saída desejada do controlador fuzzy seja definida e o controlador necessite ser ajustado novamente, não haverá problemas. Isto porque o ajuste é realizado antes da execução da recarga dos VEPs. Em adição, caso uma nova saída desejada seja requerida durante a recarga dos VEPs, o controlador com o ajuste antigo é utilizado, enquanto o novo controlador é otimizado paralelamente.

O tempo de execução é diretamente influenciado pela discretização dos intervalos de ΔSOC , Δt_{VEP} e prioridade. Os resultados da Tabela 22 foram obtidos discretizando os intervalos desses parâmetros com passos de 2, 1 e 0,1, respectivamente. Ou seja, os valores de cada variável são: $[0, 2, 4, 6, \dots, 96, 98, 100]_{1 \times 51}$ para o ΔSOC , $[0, 1, 2, 3, \dots, 8, 9, 10]_{1 \times 25}$ para o Δt_{VEP} e $[0; 0, 1; 0, 2; 0, 3; \dots; 0, 8; 0, 9; 1]_{1 \times 11}$ para a prioridade.

Para se obter a aptidão de cada cromossomo (ou partícula) em cada iteração (ou geração), o controlador fuzzy deve ser avaliado para todas as possíveis entradas das três variáveis. Ou seja:

$$\begin{aligned}
 TxR_0 &= f(\Delta SOC; \Delta t_{VEP}; \text{prioridade}) \\
 TxR_0(0; 0; 0) &= f(0; 0; 0) \\
 TxR_0(0; 0; 0, 1) &= f(0; 0; 0, 1) \\
 TxR_0(0; 0; 0, 2) &= f(0; 0; 0, 2) \\
 &\vdots \\
 TxR_0(0; 0; 1) &= f(0; 0; 1) \\
 TxR_0(0; 1; 0) &= f(0; 1; 0) \\
 TxR_0(0; 1; 0, 1) &= f(0; 1; 0, 1) \\
 TxR_0(0; 1; 0, 2) &= f(0; 1; 0, 2) \\
 &\vdots \\
 TxR_0(0; 1; 1) &= f(0; 1; 1) \\
 &\vdots \\
 TxR_0(2; 0; 0) &= f(2; 0; 0) \\
 &\vdots \\
 TxR_0(100; 24; 1) &= f(100; 24; 1)
 \end{aligned}$$

Desta forma, são 14.025 conjuntos de entradas ($51 \cdot 25 \cdot 11 = 14.025$) que devem ser avaliados no controlador fuzzy para cada partícula em cada iteração.

Caso os passos de ΔSOC , Δt_{VEP} e prioridade passem a ser 10, 2 e 0,1, respecti-

vamente, então as possíveis entradas passam a ser 1.573 conjuntos ($11 \cdot 13 \cdot 11 = 1.573$). O tempo de uma única execução da melhor solução encontrada neste caso para os dois algoritmos são apresentados na Tabela 23. Percebe-se, uma diminuição expressiva no tempo de execução de ambos os algoritmos, dado que o controlador fuzzy é executado para menos conjuntos comparando com o caso anterior.

Tabela 23 – Tempo de uma única execução dos métodos para o ajuste do controlador lógico fuzzy com 1.573 conjuntos de entrada.

	AG	PSO
Tempo de uma única execução (segundos)	116,3676	110,6903

Fonte: Elaborado pelo autor.

Cabe ressaltar que, com menos conjuntos de entrada, o tempo de execução é reduzido, mas a qualidade das soluções é comprometida. A superfície da saída do controlador possuirá menos pontos para a aproximação da saída desejada e, conseqüentemente, o valor ótimo da aptidão é pior. A Tabela 24 ilustra este último comportamento, onde as médias e os desvios padrões populacionais são maiores nos dois métodos quando comparados com os valores da Tabela 21.

Tabela 24 – Média e desvio padrão populacional das aptidões finais em 20 execuções independentes de cada algoritmo com 1.573 conjuntos de entrada.

	AG	PSO
Média (μ)	297,2352	238,2567
Desvio padrão populacional (σ)	40,0488	3,6609

Fonte: Elaborado pelo autor.

Apesar de piores resultados, mesmo com menos conjuntos, a qualidade das soluções ainda é válida. Para o PSO, percebe-se que a diferença na média das aptidões é pequena. O desvio padrão populacional aumenta um pouco, mas ainda é pequeno comparado com o aumento ocasionado no AG. Desta forma, com passos menores, o PSO retorna resultados aceitáveis em um tempo de execução, aproximadamente, 8,60 vezes menor para o caso com 14.025 conjuntos de entrada. Já o AG tem uma perda de qualidade considerável, apresentando um aumento no desvio padrão de aproximadamente 33%.

Ainda buscando comparar ambos os métodos, geraram-se os gráficos das Figuras 22 e 23. Nessas figuras, apresentam-se as convergências das soluções dos métodos ao longo de 1000 iterações para 14.025 conjuntos de entrada. O número de partículas (ou

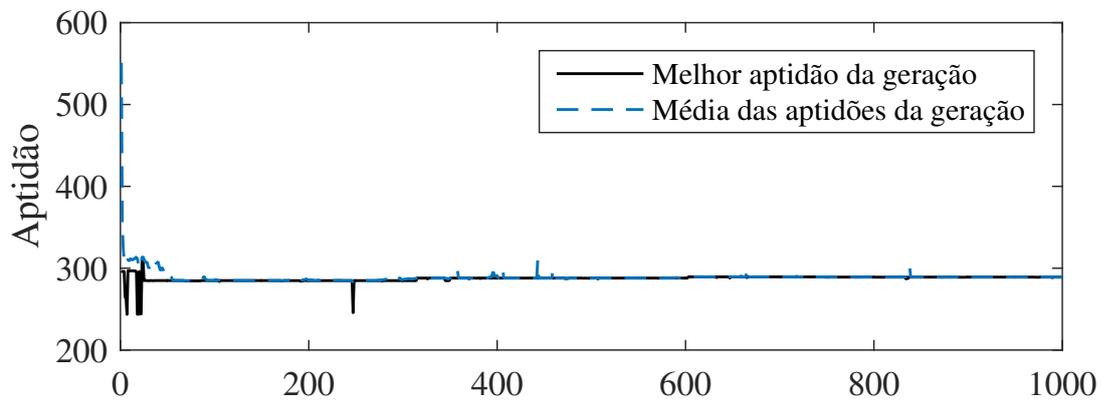
cromossomos) e os demais parâmetros de cada algoritmo são conservados como iguais aos dos experimentos anteriores.

O melhor cromossomo de cada geração do AG possui uma certa dificuldade para estabilizar em um valor, conforme mostra a Figura 22. Entretanto, o AG tende a convergir a média das aptidões em cada geração para uma solução comum, conforme Figura 22. Estes comportamentos representam que o AG possui uma tendência de levar toda a população para um mesmo valor de aptidão com o passar das gerações, mas o cromossomo com a melhor aptidão da geração atual pode se perder na próxima geração. Este último comportamento é ocasionado pelos operadores genéticos, que podem atuar em um cromossomo com a melhor aptidão, piorando-o. Além do apresentado aqui, este fenômeno também é descrito por Rao (2009).

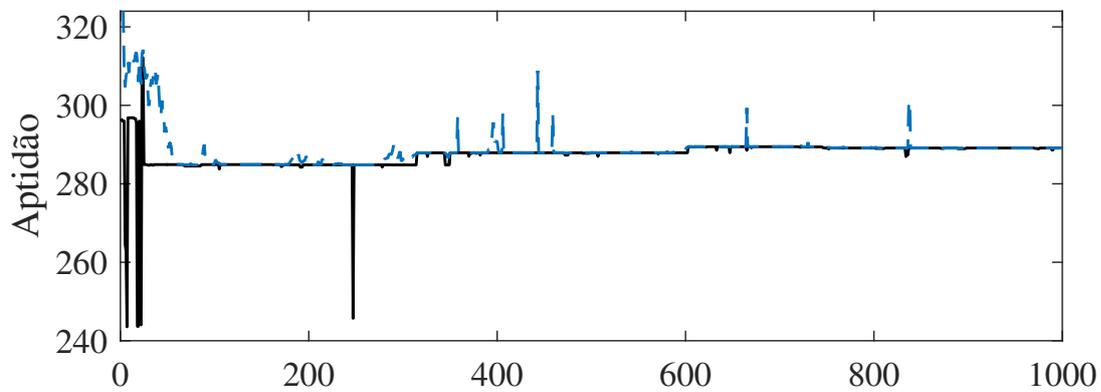
Em contrapartida ao exposto anteriormente, ao encontrar uma partícula mais apta, o PSO a mantém até que uma melhor seja encontrada. Ou seja, o comportamento da Figura 23 é obtido a partir de onde a melhor aptidão está decrescendo, até se estabilizar no menor valor encontrado durante a simulação. A convergência da média das aptidões por geração apresenta uma dificuldade maior para estabilizar, conforme a Figura 23. Este comportamento indica que algumas das partículas estão se aproximando dos valores limites do intervalo de ajuste, elevando o valor da função objetivo. Desta forma, a média tende a demorar mais para convergir conforme se passam as iterações. Entretanto, as partículas ainda tendem a se concentrar em um único ponto, sendo poucas as que estão fora das proximidades desta região.

Ressalta-se que, entre os fatores que afetam a qualidade das soluções encontradas, destacam-se as condições iniciais geradas aleatoriamente para a população, o tamanho da população, o intervalo do espaço de busca de cada uma das três variáveis de entrada bem como a discretização deste intervalo, o número máximo de iterações e os valores dos parâmetros de cada algoritmo (probabilidades de mutação e recombinação e coeficientes social e cognitivo). Dessa forma, os resultados apresentados foram os melhores encontrados após os fatores acima terem sido empiricamente definidos. Com isso, os resultados encontrados podem ser diferentes caso os parâmetros sejam modificados. Entretanto, com as soluções aqui apresentadas, ambos os métodos se mostraram eficientes, levando as soluções para regiões com pontos ótimos aceitáveis. Por fim, a modificação dos fatores citada pode ser utilizada para refinar a solução do processo de otimização.

Figura 22 – Convergências da média das aptidões e da melhor aptidão do AG. O gráfico em (b) é uma aproximação das curvas de (a).



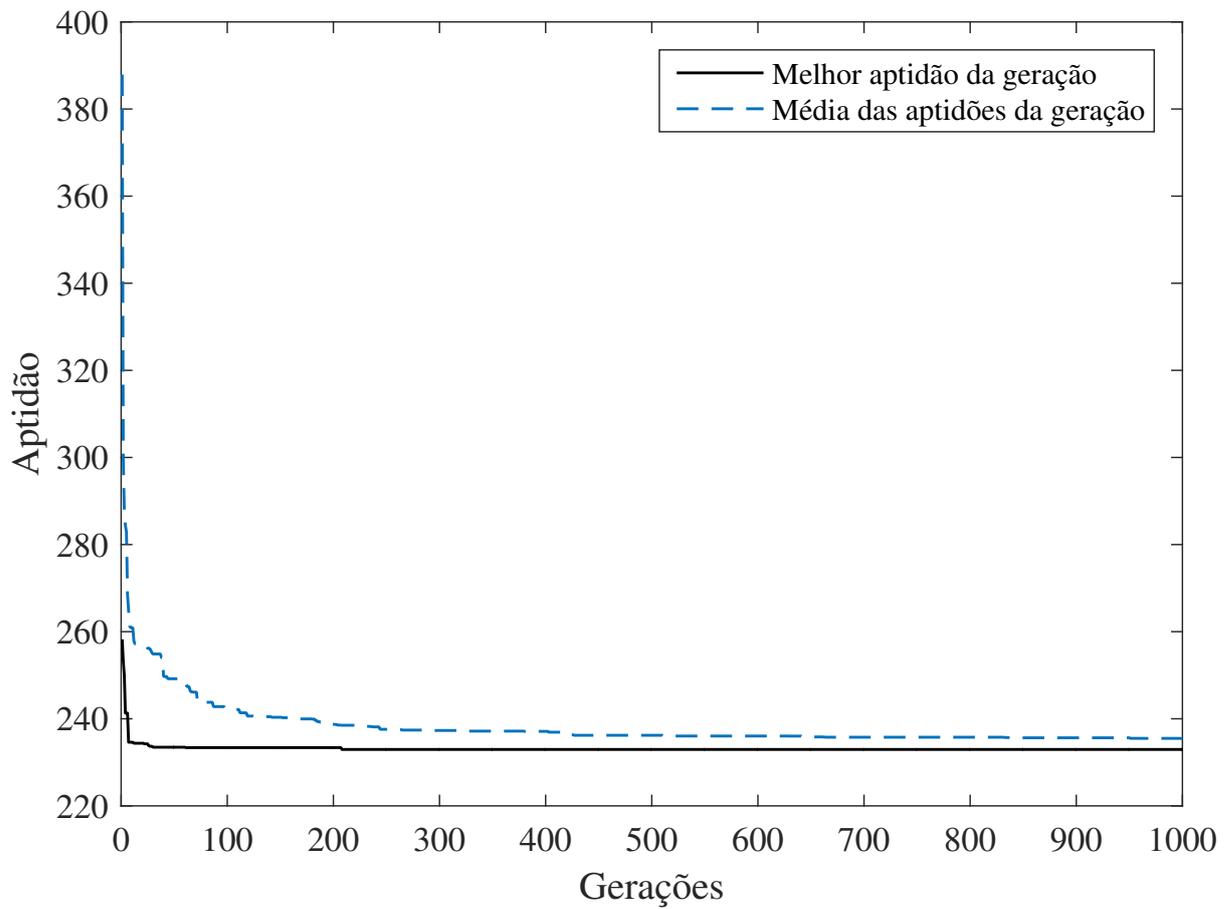
(a)



(b)

Fonte: Elaborado pelo autor.

Figura 23 – Convergências da média das aptidões e da melhor aptidão do PSO.



Fonte: Elaborado pelo autor.

APÊNDICE D – DADOS DAS FROTAS DE VEPs UTILIZADAS NO COD

O estado de carga final (SOC_f) e a capacidade da bateria (B_{cap}) de cada VEP, foram definidos como 90% e 22 kW, respectivamente.

Tabela 25 – Frota de VEPs na barra 2

VEP	1	2	3	4	5	6	7	8	9
SOC_0	40,65	12,79	68,82	67,30	74,94	66,17	17,91	65,04	50,73
Δt_{VEP}	20	12	9	18	13	12	12	6	19
prioridade	0,15	0,64	0,54	0,75	0,84	0,95	0,25	0,74	0,26
VEP	10	11	12	13	14	15	16	17	18
SOC_0	34,30	82,55	20,74	83,96	52,89	45,41	36,23	60,11	22,15
Δt_{VEP}	5	19	13	16	11	3	10	3	22
prioridade	0,18	0,45	0,74	0,88	0,08	0,58	0,32	0,79	0,37
VEP	19	20	21	22	23	24	25	26	
SOC_0	31,24	55,15	69,58	38,84	33,78	20,47	24,42	52,17	
Δt_{VEP}	23	5	9	14	6	20	10	22	
prioridade	0,03	0,96	0,91	0,94	0,79	0,79	0,40	0,23	

Tabela 26 – Frota de VEPs na barra 6

VEP	1	2	3	4	5	6	7	8	9
SOC_0	54,18	23,67	58,87	62,03	67,33	40,55	7,54	20,61	82,20
Δt_{VEP}	5	7	4	4	21	14	14	40	21
prioridade	0,11	0,78	0,39	0,24	0,40	0,10	0,13	0,94	0,96
VEP	10	11	12	13	14	15	16	17	18
SOC_0	13,71	74,32	48,45	89,65	7,04	39,84	9,60	86,57	0,42
Δt_{VEP}	15	9	13	10	3	7	4	5	7
prioridade	0,58	0,06	0,23	0,35	0,82	0,02	0,04	0,17	0,65
VEP	19	20	21	22	23	24	25	26	27
SOC_0	69,74	73,56	78,18	7,60	35,98	23,39	72,01	38,83	81,96
Δt_{VEP}	11	2	22	23	12	12	9	22	9
prioridade	0,73	0,65	0,45	0,55	0,30	0,74	0,19	0,69	0,18

Tabela 27 – Frota de VEPs na barra 11

VEP	1	2	3	4	5
SOC_0	33,1636	56,3057	70,2205	7,3013	83,6447
Δt_{VEP}	19	12	11	11	8
prioridade	0,5085	0,5108	0,8176	0,7948	0,6443

Tabela 28 – Frota de VEPs na barra 16

VEP	1	2	3	4	5	6	7	8	9
SOC_0	34,07	73,04	47,95	31,57	84,51	78,83	49,51	56,02	52,83
Δt_{VEP}	7	10	15	7	15	17	6	4	8
prioridade	0,62	0,68	0,40	0,37	0,99	0,04	0,89	0,91	0,80
VEP	10	11	12	13	14	15	16	17	18
SOC_0	18,70	27,11	42,38	20,74	75,99	17,53	20,33	15,36	20,49
Δt_{VEP}	8	11	13	3	7	19	2	22	18
prioridade	0,10	0,26	0,34	0,68	0,14	0,72	0,11	0,65	0,49
VEP	19	20	21	22	23	24	25	26	27
SOC_0	39,21	28,00	83,10	38,72	16,63	81,44	88,18	39,50	10,00
Δt_{VEP}	12	14	6	12	23	14	13	6	12
prioridade	0,78	0,72	0,90	0,89	0,33	0,70	0,20	0,03	0,74

Tabela 29 – Frota de VEPs na barra 22

VEP	1	2	3	4	5	6	7	8	9
SOC_0	45,00	43,19	81,43	54,89	55,59	77,35	72,49	51,90	16,46
Δt_{VEP}	17	2	3	13	3	20	20	18	4
prioridade	0,17	0,39	0,83	0,80	0,06	0,40	0,53	0,42	0,66
VEP	10	11	12	13	14	15	16	17	18
SOC_0	21,59	79,79	2,58	44,09	15,11	88,08	64,14	45,04	42,40
Δt_{VEP}	16	13	23	16	19	11	11	20	3
prioridade	0,63	0,29	0,43	0,02	0,98	0,17	0,11	0,37	0,20
VEP	19								
SOC_0	5,37								
Δt_{VEP}	4								
prioridade	0,49								

Tabela 30 – Frota de VEPs na barra 29

VEP	1	2	3	4
SOC_0	30,55	85,65	82,83	4,74
Δt_{VEP}	18	7	11	14
prioridade	0,94	0,42	0,98	0,30

Tabela 31 – Frota de VEPs na barra 32

VEP	1	2	3	4	5	6	7	8	9
SOC_0	63,10	59,97	48,52	62,83	59,99	16,03	11,52	89,92	15,40
Δt_{VEP}	2	14	21	16	5	9	12	24	5
prioridade	0,86	0,64	0,38	0,19	0,43	0,48	0,12	0,59	0,23

Tabela 32 – Frota de VEPs na barra 37

VEP	1	2	3	4	5	6	7	8	9
SOC_0	34,62	52,47	22,66	26,14	55,54	23,88	74,19	88,44	65,72
Δt_{VEP}	2	11	8	5	5	11	3	15	12
prioridade	0,41	0,82	0,72	0,97	0,53	0,33	0,11	0,61	0,78
VEP	10	11	12	13	14	15	16	17	
SOC_0	30,95	52,57	9,70	81,57	79,17	73,60	23,47	53,49	
Δt_{VEP}	17	17	16	2	3	8	13	16	
prioridade	0,42	0,09	0,27	0,15	0,28	0,44	0,53	0,46	

Tabela 33 – Frota de VEPs na barra 43

VEP	1	2	3	4	5	6	7	8	9
SOC_0	78,78	46,62	84,93	57,39	86,19	21,66	60,85	26,02	60,46
Δt_{VEP}	12	2	5	18	12	5	9	15	5
prioridade	0,12	0,61	0,45	0,46	0,66	0,77	0,35	0,66	0,42
VEP	10	11	12	13	14	15	16	17	18
SOC_0	62,56	6,12	22,93	20,16	60,10	76,00	31,00	70,25	60,78
Δt_{VEP}	18	7	22	7	19	5	8	3	14
prioridade	0,84	0,83	0,26	0,61	0,58	0,54	0,87	0,26	0,32
VEP	19	20	21	22	23	24	25	26	27
SOC_0	0,60	54,20	34,81	82,44	0,10	41,62	38,19	41,48	69,31
Δt_{VEP}	17	14	11	16	16	17	16	23	6
prioridade	0,12	0,94	0,65	0,48	0,64	0,54	0,65	0,54	0,72
VEP	28	29							
SOC_0	29,02	70,63							
Δt_{VEP}	17	6							
prioridade	0,52	0,99							

Tabela 34 – Frota de VEPs na barra 46

VEP	1	2	3	4	5	6	7	8	9
SOC_0	19,68	9,52	9,87	5,72	36,41	40,35	32,92	68,72	56,51
Δt_{VEP}	18	7	11	17	9	18	10	17	17
prioridade	0,44	0,83	0,77	0,17	0,86	0,99	0,51	0,88	0,59
VEP	10	11	12	13	14	15	16	17	18
SOC_0	69,48	83,96	87,55	17,28	12,50	62,66	8,44	47,29	47,73
Δt_{VEP}	11	1	9	11	7	6	20	11	21
prioridade	0,15	0,20	0,41	0,75	0,83	0,79	0,32	0,53	0,09
VEP	19	20	21	22	23	24	25	26	27
SOC_0	77,50	43,64	35,41	60,43	66,71	46,80	31,29	13,50	52,75
Δt_{VEP}	10	19	10	20	18	10	6	19	23
prioridade	0,11	0,14	0,68	0,50	0,19	0,50	0,15	0,06	0,85
VEP	28	29							
SOC_0	23,59	4,00							
Δt_{VEP}	9	16							
prioridade	0,56	0,93							

Tabela 35 – Frota de VEPs na barra 50

VEP	1	2	3	4	5	6
SOC_0	62,70	52,45	73,39	79,11	89,00	0,05
Δt_{VEP}	21	15	24	13	12	19
prioridade	0,23	0,50	0,90	0,57	0,85	0,74

Tabela 36 – Frota de VEPs na barra 56

VEP	1	2	3	4	5	6	7	8	9
SOC_0	52,74	22,21	59,98	7,51	56,34	59,49	65,68	80,17	88,41
Δt_{VEP}	4	5	2	16	7	13	17	12	13
prioridade	0,73	0,74	0,06	0,86	0,93	0,98	0,86	0,79	0,51
VEP	10	11	12	13	14	15	16	17	18
SOC_0	69,21	52,33	83,55	52,21	1,53	10,88	77,64	43,59	76,04
Δt_{VEP}	11	4	12	21	21	7	6	14	16
prioridade	0,18	0,40	0,13	0,03	0,94	0,30	0,30	0,33	0,47
VEP	19	20	21	22	23	24	25	26	27
SOC_0	18,85	49,71	56,69	2,88	55,32	32,62	4,46	44,06	17,33
Δt_{VEP}	11	6	23	3	3	4	5	15	14
prioridade	0,65	0,03	0,84	0,56	0,85	0,35	0,45	0,05	0,18
VEP	28	29							
SOC_0	11,08	18,49							
Δt_{VEP}	2	22							
prioridade	0,66	0,33							

Tabela 37 – Frota de VEPs na barra 59

VEP	1	2	3	4	5	6	7	8	9
SOC_0	80,86	10,63	88,96	48,60	63,62	89,95	25,91	37,31	41,84
Δt_{VEP}	8,00	4,00	6,00	22,00	3,00	7,00	2,00	11,00	1,00
prioridade	0,11	0,83	0,34	0,29	0,75	0,01	0,05	0,67	0,60
VEP	10	11	12	13	14	15	16	17	18
SOC_0	68,76	73,64	9,02	16,03	32,37	5,10	46,97	30,23	15,81
Δt_{VEP}	22,00	6,00	3,00	8,00	11,00	3,00	24,00	9,00	8,00
prioridade	0,53	0,73	0,71	0,78	0,29	0,69	0,56	0,40	0,06
VEP	19	20	21	22	23	24	25	26	27
SOC_0	18,81	81,46	60,79	42,16	82,09	9,36	67,10	66,26	50,57
Δt_{VEP}	2,00	8,00	2,00	13,00	19,00	16,00	3,00	3,00	19,00
prioridade	0,78	0,34	0,61	0,74	0,10	0,13	0,55	0,49	0,89
VEP	28	29							
SOC_0	16,58	53,75							
Δt_{VEP}	22,00	13,00							
prioridade	0,80	0,73							

Tabela 38 – Frota de VEPs na barra 60

VEP	1	2	3	4	5	6	7	8	9
SOC_0	4,62	6,56	7,97	71,85	84,87	61,53	11,89	65,05	9,93
Δt_{VEP}	18	6	18	23	21	3	9	9	17
prioridade	0,21	0,39	0,55	0,23	0,64	0,48	0,15	0,78	0,10
VEP	10	11	12	13	14	15			
SOC_0	10,57	57,66	29,59	58,84	67,42	52,49			
Δt_{VEP}	15	19	9	6	3	19			
prioridade	0,29	0,24	0,53	0,09	0,41	0,10			

Tabela 39 – Frota de VEPs na barra 64

VEP	1	2	3	4	5	6	7	8	9
SOC_0	10,11	70,60	26,24	54,32	86,80	38,92	62,53	68,23	38,94
Δt_{VEP}	2	8	19	17	4	4	3	1	11
prioridade	0,89	0,70	0,56	0,18	0,21	0,08	0,91	0,71	0,56
VEP	10	11	12	13	14	15	16	17	18
SOC_0	58,99	9,88	84,04	16,87	23,96	71,80	43,88	69,21	35,64
Δt_{VEP}	16	18	13	4	16	4	4	3	4
prioridade	0,31	0,17	0,62	0,99	0,17	0,26	0,40	0,07	0,68
VEP	19	20	21	22	23	24			
SOC_0	24,56	3,35	60,60	38,66	40,66	54,89			
Δt_{VEP}	5	6	8	8	6	7			
prioridade	0,40	0,98	0,40	0,62	0,15	0,38			

Tabela 40 – Frota de VEPs na barra 69

VEP	1	2	3	4	5
SOC_0	14,50	68,23	78,40	31,57	61,70
Δt_{VEP}	8	13	20	15	9
prioridade	0,30	0,45	0,42	0,36	0,56

Tabela 41 – Frota de VEPs na barra 71

VEP	1	2	3	4	5	6	7	8	9
SOC_0	66,83	38,19	38,64	11,24	2,20	26,12	28,58	58,83	86,12
Δt_{VEP}	18	18	18	3	17	12	6	3	20
prioridade	0,52	0,70	0,15	0,95	0,54	0,68	0,04	0,81	0,75
VEP	10	11	12	13					
SOC_0	84,22	41,21	21,64	68,75					
Δt_{VEP}	5	5	16	22					
prioridade	0,12	0,53	0,33	0,55					

Tabela 42 – Frota de VEPs na barra 74

VEP	1	2	3	4	5	6	7	8	9
SOC_0	35,90	37,36	16,27	22,98	1,85	83,13	58,83	83,94	14,72
Δt_{VEP}	13	16	23	11	2	21	16	9	24
prioridade	0,09	0,64	0,18	0,05	0,72	0,35	0,66	0,38	0,63
VEP	10	11	12	13	14	15	16	17	18
SOC_0	82,90	71,52	51,97	39,60	23,19	67,68	20,58	5,78	69,06
Δt_{VEP}	6	16	15	10	4	2	11	5	18
prioridade	0,02	0,91	0,80	0,75	0,81	0,38	0,62	0,58	0,53
VEP	19	20	21	22	23	24	25	26	27
SOC_0	60,41	64,37	57,79	37,71	35,17	73,45	28,57	73,31	71,02
Δt_{VEP}	10	20	18	14	5	23	7	22	6
prioridade	0,28	0,25	0,45	0,23	0,80	0,99	0,03	0,54	0,09
VEP	28								
SOC_0	76,70								
Δt_{VEP}	10								
prioridade	0,80								

Tabela 43 – Frota de VEPs na barra 77

VEP	1	2	3	4	5	6	7	8	9
SOC_0	89,02	6,03	84,55	1,64	61,55	70,54	48,07	79,68	80,91
Δt_{VEP}	9	16	7	8	17	13	10	15	18
prioridade	0,31	0,73	0,78	0,69	0,01	0,84	0,92	0,77	0,04
VEP	10	11	12	13	14	15	16	17	18
SOC_0	56,33	12,41	19,60	16,39	3,76	9,62	55,48	84,57	31,90
Δt_{VEP}	14	14	14	13	3	18	24	9	23
prioridade	0,38	0,70	0,73	0,22	0,27	0,67	0,48	0,62	0,24
VEP	19	20	21	22	23	24			
SOC_0	36,96	88,59	85,10	60,90	88,95	69,01			
Δt_{VEP}	9	21	11	11	6	4			
prioridade	0,18	0,83	0,77	0,93	0,11	0,18			

Tabela 44 – Frota de VEPs na barra 80

VEP	1	2	3	4	5	6	7	8	9
SOC_0	8,92	44,08	17,39	80,63	8,92	3,97	50,16	69,52	28,07
Δt_{VEP}	15	9	23	4	18	16	20	10	18
prioridade	0,28	0,23	0,71	0,62	0,59	0,66	0,05	0,35	0,45
VEP	10	11	12	13	14	15	16	17	18
SOC_0	16,11	30,51	18,91	45,91	81,57	56,60	9,14	35,18	4,92
Δt_{VEP}	20	8	14	24	14	9	15	9	18
prioridade	0,24	0,72	0,86	0,28	0,73	0,14	0,84	0,14	0,59
VEP	19	20	21	22	23	24	25	26	27
SOC_0	45,12	38,85	89,78	73,04	43,71	80,50	12,38	35,10	83,46
Δt_{VEP}	11	12	17	23	9	20	18	23	2
prioridade	0,37	0,81	0,50	0,49	0,88	0,35	0,45	0,96	0,04
VEP	28	29							
SOC_0	82,57	64,22							
Δt_{VEP}	9	16							
prioridade	0,97	0,19							

Tabela 45 – Frota de VEPs na barra 85

VEP	1	2	3	4	5	6	7	8	9
SOC_0	60,04	52,78	60,76	32,49	55,83	73,00	1,73	7,55	87,73
Δt_{VEP}	3	22	10	2	9	18	19	14	17
prioridade	0,80	0,29	0,54	0,98	0,72	0,84	0,43	0,47	0,56
VEP	10	11	12	13	14	15	16	17	18
SOC_0	58,62	20,81	36,31	10,98	24,16	23,21	29,85	13,70	31,32
Δt_{VEP}	22	2	8	2	5	18	18	21	14
prioridade	0,27	0,75	0,50	0,65	0,31	0,14	0,48	0,36	0,79
VEP	19	20							
SOC_0	10,95	79,57							
Δt_{VEP}	3	22							
prioridade	0,78	0,67							

Tabela 46 – Frota de VEPs na barra 88

VEP	1	2
SOC_0	12,02	1,94
Δt_{VEP}	14	8
prioridade	0,94	0,98

Tabela 47 – Frota de VEPs na barra 92

VEP	1	2	3	4	5	6	7	8	9
SOC_0	25,80	72,07	80,65	53,78	79,56	84,94	49,42	65,55	51,91
Δt_{VEP}	16	22	20	12	18	11	23	24	21
prioridade	0,66	0,12	0,41	0,28	0,72	0,28	0,90	0,83	0,39
VEP	10	11	12	13	14	15	16	17	18
SOC_0	2,33	40,19	58,17	46,91	33,51	84,34	74,66	76,42	33,53
Δt_{VEP}	10	11	7	19	21	22	14	15	4
prioridade	0,50	0,69	0,83	0,61	0,57	0,33	0,46	0,71	0,88
VEP	19	20	21	22	23	24	25	26	
SOC_0	53,39	78,53	84,02	60,16	18,61	58,85	6,48	36,61	
Δt_{VEP}	22	11	6	22	19	21	8	16	
prioridade	0,72	0,02	0,67	0,44	0,44	0,12	0,81	0,32	

Tabela 48 – Frota de VEPs na barra 99

VEP	1	2	3	4	5	6	7	8	9
SOC_0	22,16	30,84	33,81	49,19	50,57	35,62	35,83	46,38	59,18
Δt_{VEP}	14,00	13	9	11	12	3	21	2	11
prioridade	0,70	0,72	0,35	0,52	0,56	0,16	0,56	0,69	0,43
VEP	10	11	12	13	14	15	16	17	18
SOC_0	85,58	65,01	36,01	74,87	12,09	5,44	7,58	14,75	29,18
Δt_{VEP}	20	10	15	20	21	22	5	7	22
prioridade	0,84	0,73	0,36	0,45	0,39	0,78	0,73	0,43	0,69
VEP	19	20	21	22	23	24	25	26	27
SOC_0	27,16	1,05	48,59	8,58	13,19	56,80	77,34	87,68	51,38
Δt_{VEP}	15	13	15	20	13	6	11	11	23
prioridade	0,95	0,78	0,71	0,11	0,39	0,59	0,46	0,05	0,23
VEP	28								
SOC_0	89,72								
Δt_{VEP}	15								
prioridade	0,83								

Tabela 49 – Frota de VEPs na barra 100

VEP	1	2	3	4	5	6	7	8	9
SOC_0	1,41	77,73	7,03	60,21	45,02	19,62	51,45	11,00	60,41
Δt_{VEP}	3	13	4	14	1	19	21	22	24
prioridade	0,44	0,94	0,66	0,45	0,84	0,53	0,55	0,68	0,37
VEP	10	11	12	13	14	15	16	17	18
SOC_0	53,96	5,04	5,07	13,73	1,77	39,17	74,90	55,57	46,81
Δt_{VEP}	13	7	3	13	14	19	3	16	13
prioridade	0,24	0,58	0,87	0,41	0,11	0,44	0,30	0,40	0,83
VEP	19	20	21						
SOC_0	77,75	8,79	81,72						
Δt_{VEP}	5	23	15						
prioridade	0,40	0,39	0,36						

Tabela 50 – Frota de VEPs na barra 102

VEP	1	2	3	4	5	6	7	8	9
SOC_0	12,62	23,41	7,81	38,65	23,16	26,78	38,24	10,73	44,56
Δt_{VEP}	22	23	6	12	10	13	7	3	11
prioridade	0,37	0,89	0,86	0,40	0,32	0,61	0,91	0,91	0,59
VEP	10	11	12	13	14	15	16	17	18
SOC_0	63,58	21,92	70,66	6,67	35,45	0,31	19,86	0,12	17,03
Δt_{VEP}	5	2	23	11	23	19	1	17	17
prioridade	0,33	0,85	0,44	0,90	0,03	0,53	0,72	0,18	0,34
VEP	19	20	21	22	23				
SOC_0	12,82	24,13	15,74	12,48	53,90				
Δt_{VEP}	16	14	6	19	6				
prioridade	0,19	0,32	0,40	0,55	0,05				

Tabela 51 – Frota de VEPs na barra 106

VEP	1	2	3	4	5	6	7	8	9
SOC_0	49,75	24,73	21,74	21,88	13,87	86,08	84,21	73,68	65,54
Δt_{VEP}	18	16	4	13	9	3	4	6	16
prioridade	0,45	0,58	0,69	0,72	0,65	0,73	0,37	0,58	0,12
VEP	10	11	12	13	14	15	16	17	18
SOC_0	15,82	32,43	16,99	0,11	28,48	62,97	56,27	48,88	39,51
Δt_{VEP}	11	17	7	1	13	7	23	22	10
prioridade	0,06	0,98	0,28	0,60	0,96	0,19	0,19	0,34	0,93
VEP	19	20	21	22	23				
SOC_0	25,87	45,15	68,54	68,62	51,85				
Δt_{VEP}	2	16	20	23	2				
prioridade	0,39	0,27	0,15	0,40	0,37				

Tabela 52 – Frota de VEPs na barra 109

VEP	1	2	3	4	5	6	7	8	9
SOC_0	11,80	39,15	8,2362	55,32	0,9881	51,59	71,08	21,18	40,32
Δt_{VEP}	16	6	20	23	20	13	7	18	6
prioridade	0,17	0,09	0,26	0,86	0,91	0,70	0,73	0,23	0,58
VEP	10	11	12						
SOC_0	51,24	5,53	44,67						
Δt_{VEP}	23	15	15						
prioridade	0,81	0,40	0,99						

Tabela 53 – Frota de VEPs na barra 111

VEP	1	2	3	4	5	6	7	8	9
SOC_0	8,10	28,88	46,03	5,45	65,31	50,09	47,64	74,70	77,29
Δt_{VEP}	8	21	22	16	7	3	20	14	23
prioridade	0,13	0,67	0,57	0,17	0,15	0,48	0,91	0,55	0,03
VEP	10	11	12	13	14	15	16	17	18
SOC_0	71,01	28,61	40,70	67,70	9,89	9,88	24,29	47,22	87,54
Δt_{VEP}	2	14	8	20	5	11	10	20	17
prioridade	0,05	0,81	0,45	0,38	0,79	0,36	0,53	0,71	0,87
VEP	19	20							
SOC_0	63,94	28,07							
Δt_{VEP}	6	8							
prioridade	0,33	0,65							

Tabela 54 – Frota de VEPs na barra 114

VEP	1	2	3	4	5	6
SOC_0	87,74	6,84	52,83	37,25	27,82	23,75
Δt_{VEP}	18	24	5	19	6	24
prioridade	0,80	0,42	0,73	0,50	0,81	0,36