



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
Centro de Engenharia Elétrica e Informática
Programa de Pós-Graduação em Engenharia Elétrica

Dissertação de Mestrado

SISTEMA DE DETECÇÃO DE ANOMALIAS ASSOCIADO
A ARMAZENADORES PARA REDUÇÃO DE PICOS DE
CONSUMO DE ENERGIA ELÉTRICA

Ivana Soares Guarany

Campina Grande - PB

Março - 2019



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
Centro de Engenharia Elétrica e Informática
Programa de Pós-Graduação em Engenharia Elétrica

SISTEMA DE DETECÇÃO DE ANOMALIAS ASSOCIADO
A ARMAZENADORES PARA REDUÇÃO DE PICOS DE
CONSUMO DE ENERGIA ELÉTRICA

Ivana Soares Guarany

Dissertação de mestrado submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande como parte dos requisitos necessários para obtenção do grau de Mestre em Engenharia Elétrica.

Área de Concentração: Processamento de Energia

Prof. Dr. Raimundo Carlos Silvério Freire
Orientador

Campina Grande - PB
Março - 2019

G914s Guarany, Ivana Soares.
Sistema de detecção de anomalias associado a armazenadores para redução de picos de consumo de energia elétrica / Ivana Soares Guarany. – Campina Grande, 2019.
136 f. : il. color.

Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2019.
"Orientação: Prof. Dr. Raimundo Carlos Silvério Freire".
Referências.

1. Consumo de energia elétrica. 2. Detecção de anomalias. 3. Algoritmo de seleção negativa. 4. Baterias. I. Freire, Raimundo Carlos Silvério. II. Título.

CDU 621.311(043)

**"SISTEMA DE DETECÇÃO DE ANOMALIAS ASSOCIADO A ARMAZENADORES PARA
REDUÇÃO DE PICOS DE CONSUMO DE ENERGIA ELÉTRICA"**

IVANA SOARES GUARANY

DISSERTAÇÃO APROVADA EM 27/02/2019

Raimundo Carlos S. Freire

RAIMUNDO CARLOS SILVÉRIO FREIRE, Dr., UFCG
Orientador(a)

Benedito Antonio Luciano

BENEDITO ANTONIO LUCIANO, D.Sc., UFCG
Examinador(a)

Edmar Candéia Gurjao

EDMAR CANDEIA GURJAO, D.Sc., UFCG
Examinador(a)

EDSON GUEDES DA COSTA, D.Sc., UFCG
Examinador(a)

CAMPINA GRANDE - PB

*Dedico este trabalho a Janete, Fernando,
Jorlene, Petrus, Nina, Angilberto, Freire,
Edmar. A vocês, família e amigos, pelo
apoio e compreensão de sempre.*

"O conhecimento nos faz responsáveis".
Ernesto Che Guevara

Agradecimentos

Agradeço aos professores Raimundo Carlos Silvério Freire e Edmar Candeia Gurjão, por me orientarem neste projeto com muita paciência, dedicação e me permitirem debater, argumentar e crescer pessoal e profissionalmente. Agradeço também aos professores Edson Guedes e Benedito pelo apoio nos mais diversos momentos da minha caminhada no mestrado em que foram guias, amigos e colaboradores no desenvolvimento deste trabalho. Agradeço fortemente aos amigos companheiros do Laboratório de Instrumentação e Metrologia, minha segunda casa no decorrer desta jornada.

Agradeço em especial a Andressa, pessoa fundamental no desenvolvimento deste trabalho e a Bruno, Érico, Larissa e Verônica companhias diárias que contribuíram com ideias e críticas no decorrer deste mestrado.

Agradeço à cidade de Campina Grande, que me acolheu como sua filha, e me trouxe de volta a alegria de estudar.

Por fim, gostaria de agradecer e prestar o devido reconhecimento à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo provimento da bolsa de estudos, essencial para o desenvolvimento do mestrado e à Coordenação do Programa de Pós-Graduação em Engenharia Elétrica (COPELE) da UFCG incluindo Ângela, Pedro e Leandro que sempre me guiaram na resolução das questões administrativas e burocráticas do programa.

Lista de Figuras

Figura 1.1 – Aplicações e benefícios dos SAE	18
Figura 2.1 – Medidor T. Duncan.	23
Figura 2.2 – Esquema do medidor de energia eletromecânico e suas configurações: ponteiro e ciclométrico.	24
Figura 2.3 – Diagrama de blocos de um medidor eletrônico.	25
Figura 2.4 – Medidor inteligente instalado no Bloco CJ da UFCG.	25
Figura 2.5 – Exemplo de Curva de carga.	26
Figura 2.6 – Camadas do sistema imunológico biológico.	28
Figura 2.7 – União entre receptores e epítopos.	30
Figura 2.8 – Mecanismo de maturação de afinidade entre células tipo B.	31
Figura 2.9 – Mecanismo de maturação de afinidade entre células tipo T.	32
Figura 2.10 – Processo de coestimulação.	33
Figura 2.11 – Fase de geração de detectores segundo o ASN.	34
Figura 2.12 – Fase de monitoramento segundo o ASN.	35
Figura 2.13 – Relação entre espaços de detecção com o parâmetro r . Os vetores próprios são representados por \square , detectores por x , espaços de detecção por \circ	37
Figura 2.14 – Esquema de funcionamento do processo de descarga e carga das baterias	44
Figura 2.15 – Ciclo de Vida de uma bateria chumbo-ácido.	45
Figura 4.1 – Potência ativa fornecida pelo medidor instalado no Bloco CJ na UFCG.	53
Figura 4.2 – Fluxograma do sistema proposto.	54
Figura 4.3 – Exemplo de curva de carga padrão.	55
Figura 4.4 – Fase de geração de detectores para o ASN implementado	57
Figura 4.5 – Fase de monitoramento para o algoritmo implementado	58
Figura 4.6 – Modelo para o sistema de armazenamento	59
Figura 4.7 – Interface para monitoramento das curvas de consumo e carga	60
Figura 5.1 – Modelagem da curva de consumo padrão para o Domingo	63
Figura 5.2 – Modelagem da curva de consumo padrão para a Segunda-Feira	64
Figura 5.3 – Detecção de Falsos Positivos no Domingo	66
Figura 5.4 – Detecção de Falsos Positivos na Segunda-Feira	66
Figura 5.5 – Detecção para espelhamento de curva no Domingo	67
Figura 5.6 – Detecção para espelhamento de curva na Segunda-Feira	68
Figura 5.7 – Detecção durante a madrugada do Domingo	69
Figura 5.8 – Detecção durante a madrugada da Segunda-Feira	70
Figura 5.9 – Detecção de diversas anomalias em um Domingo	71
Figura 5.10 – Detecção de diversas anomalias em uma Segunda-Feira	72

Figura 5.11–Detecção de picos em uma curva de consumo real de Domingo	73
Figura 5.12–Detecção de picos em uma curva de consumo real de Segunda-Feira . . .	74
Figura 5.13–Ciclo de Vida de uma bateria estacionária Freedom [©]	75
Figura 5.14–Parâmetros da bateria chumbo-ácido de 105 Ah	76
Figura 5.15–Parâmetros da bateria chumbo-ácido de 220 Ah	76
Figura 5.16–Estado de carga do SAEB de 105 Ah para picos em todos os dias da semana	77
Figura 5.17–Estado de carga do SAEB de 220 Ah para picos em todos os dias da semana	78
Figura 5.18–Interface utilizando SAEB de 105 Ah	80
Figura 5.19–Interface utilizando SAEB de 220 Ah	80
Figura 5.20–Interface utilizando SAEB de 105 Ah	81
Figura 5.21–Interface utilizando SAEB de 220 Ah	81
Figura 5.22–Interface utilizando SAEB de 105 Ah	83
Figura 5.23–Interface utilizando SAEB de 220 Ah	83
Figura 5.24–Interface utilizando SAEB de 105 Ah	84
Figura 5.25–Interface utilizando SAEB de 220 Ah	84
Figura 5.26–Detecção de outras anomalias com SAEB de 105 Ah	85
Figura 5.27–Interface utilizando SAEB de 105 Ah	86
Figura 5.28–Interface utilizando SAEB de 220 Ah	86
Figura 5.29–Interface utilizando SAEB de 105 Ah	87
Figura 5.30–Interface utilizando SAEB de 220 Ah	87
Figura A.1–Modelagem da curva de consumo padrão para o Terça-Feira	99
Figura A.2–Modelagem da curva de consumo padrão para a Quarta-Feira	100
Figura A.3–Modelagem da curva de consumo padrão para a Quinta-Feira	101
Figura A.4–Modelagem da curva de consumo padrão para a Sexta-Feira	102
Figura A.5–Modelagem da curva de consumo padrão para o Sábado	103
Figura B.1–Detecção de Falsos Positivos na Terça-Feira	104
Figura B.2–Detecção de Falsos Positivos na Quarta-Feira	105
Figura B.3–Detecção de Falsos Positivos na Quinta-Feira	105
Figura B.4–Detecção de Falsos Positivos na Sexta-Feira	106
Figura B.5–Detecção de Falsos Positivos no Sábado	106
Figura B.6–Detecção para espelhamento de curva na Terça-Feira	107
Figura B.7–Detecção para espelhamento de curva na Quarta-Feira	108
Figura B.8–Detecção para espelhamento de curva na Quinta-Feira	108
Figura B.9–Detecção para espelhamento de curva na Sexta-Feira	109
Figura B.10–Detecção para espelhamento de curva no Sábado	109
Figura B.11–Detecção durante a madrugada da Terça-Feira	110
Figura B.12–Detecção durante a madrugada da Quarta-Feira	111

Figura B.13–Detecção durante a madrugada da Quinta-Feira	111
Figura B.14–Detecção durante a madrugada da Sexta-Feira	112
Figura B.15–Detecção durante a madrugada do Sábado	112
Figura B.16–Detecção de diversas anomalias em uma Terça-Feira	113
Figura B.17–Detecção de diversas anomalias em uma Quarta-Feira	114
Figura B.18–Detecção de diversas anomalias em uma Quinta-Feira	114
Figura B.19–Detecção de diversas anomalias em uma Sexta-Feira	115
Figura B.20–Detecção de diversas anomalias em um Sábado	115
Figura B.21–Detecção de picos em uma curva de consumo real de Terça-Feira	116
Figura B.22–Detecção de picos em uma curva de consumo real de Quarta-Feira	117
Figura B.23–Detecção de picos em uma curva de consumo real de Quinta-Feira	117
Figura B.24–Detecção de picos em uma curva de consumo real de Sexta-Feira	118
Figura B.25–Detecção de picos em uma curva de consumo real de Sábado	118
Figura C.1 –Interface utilizando SAEB de 105 Ah	119
Figura C.2 –Interface utilizando SAEB de 220 Ah	120
Figura C.3 –Interface utilizando SAEB de 105 Ah	121
Figura C.4 –Interface utilizando SAEB de 220 Ah	121
Figura C.5 –Interface utilizando SAEB de 105 Ah	122
Figura C.6 –Interface utilizando SAEB de 220 Ah	122
Figura C.7 –Interface utilizando SAEB de 105 Ah	123
Figura C.8 –Interface utilizando SAEB de 220 Ah	123
Figura C.9 –Interface utilizando SAEB de 105 Ah	124
Figura C.10–Interface utilizando SAEB de 220 Ah	124
Figura C.11–Interface utilizando SAEB de 105 Ah	125
Figura C.12–Interface utilizando SAEB de 220 Ah	126
Figura C.13–Interface utilizando SAEB de 105 Ah	127
Figura C.14–Interface utilizando SAEB de 220 Ah	127
Figura C.15–Interface utilizando SAEB de 105 Ah	128
Figura C.16–Interface utilizando SAEB de 220 Ah	128
Figura C.17–Interface utilizando SAEB de 105 Ah	129
Figura C.18–Interface utilizando SAEB de 220 Ah	129
Figura C.19–Interface utilizando SAEB de 105 Ah	130
Figura C.20–Interface utilizando SAEB de 220 Ah	130
Figura C.21–Interface utilizando SAEB de 105 Ah	131
Figura C.22–Interface utilizando SAEB de 220 Ah	132
Figura C.23–Interface utilizando SAEB de 105 Ah	133
Figura C.24–Interface utilizando SAEB de 220 Ah	133
Figura C.25–Interface utilizando SAEB de 105 Ah	134
Figura C.26–Interface utilizando SAEB de 220 Ah	134

Figura C.27–Interface utilizando SAEB de 105 Ah	135
Figura C.28–Interface utilizando SAEB de 220 Ah	135
Figura C.29–Interface utilizando SAEB de 105 Ah	136
Figura C.30–Interface utilizando SAEB de 220 Ah	136

Lista de Tabelas

Tabela 3.1 – Resumo das principais referências.	52
Tabela 5.1 – Parâmetros de entrada do ASN e Cobertura de Falha para espelhamento	68
Tabela 5.2 – Parâmetros de entrada do ASN e Cobertura de Falha para anomalias durante a madrugada	70
Tabela 5.3 – Parâmetros de entrada do ASN e Cobertura de Falha para detecção de diversas anomalias	72
Tabela 5.4 – Parâmetros de entrada do ASN e Cobertura de Falha para detecção de picos de consumo em uma curva real	74
Tabela 5.5 – Comparativo de SAEB	88

Lista de abreviaturas e siglas

ASN	Algoritmo de Seleção Negativa
CD	Conjunto de Detectores
CF	Cobertura de Falhas
GMG	Grupos Motor-Geradores
LSTM	<i>(Long Short Term Memory)</i>
Nd	Número de Detectores
SAA	Sistema de Abastecimento de Água
SAEB	Sistema de Armazenamento de Energia por Baterias
SAE	Sistema de Armazenamento de Energia
SIA	Sistemas Imunológicos Artificiais
SICDF	Sistema Imunológico Computacional para Detecção de Fraude
SOC	<i>State of Charge</i>
UFCG	Universidade Federal de Campina Grande

Resumo

A identificação de comportamentos anômalos no consumo de energia pode indicar defeitos, consumo não previsto e oportunidades para uso de fontes alternativas e armazenadores de energia. A análise do consumo é o primeiro passo para identificar ações que resultem em eficiência, qualidade de energia e redução do consumo de energia elétrica provida pela concessionária. Neste trabalho, é apresentada uma aplicação de sistemas imunológicos artificiais, tendo como foco o algoritmo de seleção negativa, para detecção de anomalias no consumo de energia elétrica. Na aplicação proposta é verificado o consumo anômalo de energia elétrica baseado nas curvas de carga padrão. Os dados de consumo de energia foram fornecidos por um medidor inteligente instalado em um prédio na Universidade Federal de Campina Grande (UFCG). Um modelo de sistema de armazenamento de energia por baterias chumbo-ácido com capacidade variável é simulado e assim, fornecido o comportamento do estado de carga das baterias para correntes demandadas por picos de consumo de energia detectados. Em uma interface, o algoritmo de detecção de anomalias é associado ao modelo de baterias comerciais de capacidades diferentes. Nos resultados obtidos nas simulações, são demonstradas a capacidade do algoritmo em detectar com eficiência diversos tipos de anomalias no consumo, tais como picos, vales, curto-circuito. Sua associação a um sistema de armazenamento de energia por baterias, é capaz de mitigar picos de consumo de energia elétrica avaliando a resposta de cada sistema de baterias quanto a capacidade de reduzir picos, custo de investimento e vida útil para a aplicação proposta.

Palavras-chaves: Detecção de anomalias, Consumo de energia elétrica, Algoritmo de seleção negativa, Baterias.

Abstract

Identification of anomalous behaviors in the electric power supply can indicate defects, unplanned consumption and opportunities for use of alternative sources and energy storage. The analysis of consumption is the first step to identify actions that result in efficiency, quality of energy and reduction of the consumption of electric energy provided by the concessionaire. This work presents an application of artificial immunological systems, focusing on the negative selection algorithm, to detect anomalies in the consumption of electric energy. In this algorithm we verified the anomalous consumption of electric energy based on the standard load curves. The data of energy consumption were provided by a smart meter installed in a building at the Federal University of Campina Grande (UFCG). A model of storage system of energy by lead-acid batteries with different capacities is simulated and thus provided the state of charge behavior of the batteries for currents demanded by detected power consumption peaks. In an interface, the anomaly detection algorithm is associated with the commercial battery model of different capacities. The results obtained in the simulations demonstrate the ability of the algorithm to detect several types of consumption anomalies such as peaks, valleys, short circuits, and high efficiency. Its association to a battery-powered energy storage system can mitigate power consumption peaks by evaluating the response of each battery system as to the ability to reduce spikes, cost of investment and lifetime for the proposed application.

Palavras-chaves: Anomaly detection, Power consumption, Negative selection algorithm, Batteries.

Sumário

1	INTRODUÇÃO	17
1.1	Objetivos	19
1.2	Organização do documento	20
2	FUNDAMENTAÇÃO TEÓRICA	21
2.1	Medidores de Energia Elétrica	21
2.1.1	A evolução dos medidores de energia elétrica	22
2.1.2	Medidores Eletromecânicos	23
2.1.3	Medidores Eletrônicos	24
2.1.4	Curva de Carga	26
2.2	Sistemas Imunológicos Artificiais	27
2.2.1	Visão geral do sistema imunológico biológico	27
2.2.2	Reconhecimento de agentes patogênicos	29
2.2.3	Tolerância ao próprio	31
2.3	Algoritmo de seleção negativa	33
2.3.1	Critérios de casamento parcial	36
2.3.1.1	Critério de casamento r-Hamming	36
2.3.1.2	Critério de casamento para casos com vetores reais	36
2.3.2	Probabilidade de erro de detecção	38
2.3.3	Exemplo de aplicação do algoritmo de seleção negativa	39
2.4	Sistemas de armazenamento de energia	39
2.4.1	Características dos Sistemas de Armazenamento	41
2.4.2	Aspectos de funcionamento das baterias	43
2.4.2.1	Bateria de Chumbo-Ácido	44
3	REVISÃO BIBLIOGRÁFICA	46
4	METODOLOGIA	53
4.1	Geração de curva de carga padrão de consumo de energia elétrica	55
4.2	Aplicação do algoritmo de seleção negativa para a detecção de anomalias no consumo de energia elétrica	56
4.3	Modelo do Sistema de Armazenamento de Energia por Bateria	58
4.4	Sistema supervisor de detecção de anomalias e utilização de baterias para redução de picos de consumo de energia elétrica	60
5	RESULTADOS	62

5.1	Curva de carga padrão	62
5.2	Detecção de anomalias aplicando ASN	65
5.3	Simulação do modelo do sistema de armazenamento	75
5.3.1	Sistema de Armazenamento por Baterias de 105 Ah	77
5.3.2	Sistema de Armazenamento por Baterias de 220 Ah	78
5.4	Interface para detecção de anomalias e utilização de SAEB para redução de picos	79
5.4.1	Início da Simulação	79
5.4.2	Detecção de picos consumo de energia e intervenção do SAEB	82
5.4.3	Detecção de outras anomalias e estado final de carga do SAEB	85
6	CONCLUSÃO	89
6.1	Trabalhos Futuros	90
6.2	Publicações	90
	REFERÊNCIAS	92
	 APÊNDICES	 98
	APÊNDICE A – CURVAS DE CARGA PADRÃO	99
	APÊNDICE B – DETECÇÃO COM ASN	104
B.1	Falsos Positivos	104
B.2	Espelhamento	107
B.3	Madrugada	110
B.4	Diversas Anomalias	113
B.5	Detecção de Picos	116
	APÊNDICE C – INTERFACE	119
C.1	Início	119
C.2	Detecção e Intervenção	125
C.3	Estado final de carga do SAEB	131

1 Introdução

A energia elétrica é um elemento imprescindível para a sustentabilidade de uma sociedade e essencial para a indústria. Porém, o aumento crescente do consumo de energia pode apresentar aspectos negativos, tais como a possibilidade do esgotamento dos recursos utilizados para a produção de energia e o impacto ao meio ambiente.

Uma das maneiras de conter a expansão do consumo de energia elétrica, sem comprometer a qualidade de vida e o crescimento econômico, é o estímulo ao uso eficiente da energia elétrica. Porém o modelo tradicional de redes elétricas não propicia aos consumidores informações suficientes que permitam decisões mais eficientes a respeito desse consumo.

Neste contexto, um gerenciamento energético eficiente deverá permitir que os consumidores possam efetivamente acompanhar o uso da energia de maneira inteligente, uma das opções a utilização de dispositivos de gerenciamento energético que forneçam ao consumidor informações detalhadas sobre o consumo de energia.

Existem dispositivos que permitem acesso às informações de consumo de energia, conhecidos como medidores inteligentes (*smart meters*), que recolhem os dados dos consumidores finais e transmitem estas informações para o coletor de dados que armazena os históricos de consumo.

Os dados do consumo de energia elétrica podem fornecer uma curva de carga que represente o perfil de consumo de energia elétrica do usuário. Este perfil possibilita a análise e intervenções que venham a modificar esta curva de carga de modo a reduzir a demanda por energia elétrica, sem prejudicar o nível de serviço e conforto dos consumidores.

Por outro lado, a detecção e identificação de possíveis anomalias, tais como, picos e vales no perfil de consumo, pode ser uma ferramenta importante para indicar a necessidade de uma intervenção que resulte em eficiência energética e redução no consumo de energia elétrica.

Após o surgimento de redes neurais artificiais e da computação evolucionária, estudos em Sistemas Imunológicos Artificiais (SIA), inspirados no sistema imunológico natural, têm fornecido muitos resultados satisfatórios para a solução de diversos problemas computacionais [1]. Os SIA podem fornecer ferramentas eficientes na detecção prévia de anomalias em um determinado sistema. Os algoritmos oriundos de SIA são inspirados no sistema imunológico humano que possui capacidade de detecção e proteção do organismo contra agentes patogênicos. Uma das mais importantes ferramentas extraídas de SIA é o Algoritmo de Seleção Negativa (ASN) por sua grande possibilidade de aplicação em monitoramentos automáticos de erros [2]. O ASN tem sua inspiração no mecanismo

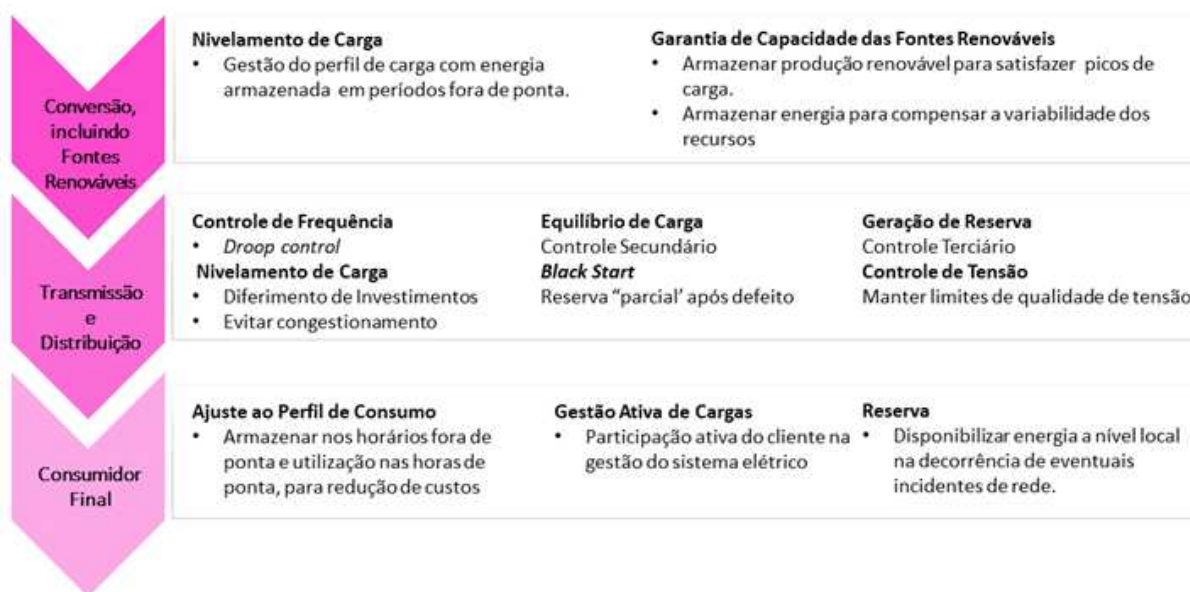
utilizado pelo sistema imunológico humano para maturar as células T, que são assim denominadas por serem células maturadas no Timo (glândula localizada atrás dos pulmões) para reconhecer antígenos não-próprios (corpos estranhos ao organismo) e para evitar que identifiquem as células próprias do corpo como estranhas.

Em outro contexto, a utilização de sistemas de armazenamento de energia é um componente essencial para um novo paradigma em energia sustentável baseado em energias renováveis, e consiste em acrescentar a um sistema de distribuição ou conversão de energia elétrica outro sistema que tenha a capacidade de armazenar energia para utilização posterior .

Os SAE têm como objetivo assegurar a confiabilidade do sistema elétrico, melhorar a qualidade da energia fornecida e permitir a integração com fontes renováveis e geração distribuída [3].

Existem muitas aplicações para o SAE, na Figura 1.1 é apresentado um diagrama com várias aplicações que os SAE proporcionam e os seus benefícios.

Figura 1.1 – Aplicações e benefícios dos SAE



Fonte: Adaptado de [4].

O consumidor final pode utilizar um Sistema de Armazenamento de Energia por Baterias (SAEB) para correção do fator de potência, reserva operacional de energia, controle de frequência de carga, reserva de emergência, redução de pico de consumo de energia e redução nos custos com energia elétrica fornecida pela concessionária [5].

A aplicação de SAEB para redução de picos de consumo tem sido bem explorada no sentido isolado de dimensionar, otimizar e desenvolver estratégias para os ciclos de carga e descarga da bateria para melhores resultados de viabilidade econômica [6], redução

de custos [7] e alocação de reservas de energia armazenadas para seu uso posterior [8], [9]. Para o planejamento do SAEB as pesquisas comumente utilizam dados de consumo de energia provenientes das faturas emitidas pela concessionária, bancos de dados [10] ou perfil de apenas um dia [11].

Um sistema com detecção de anomalias no consumo de energia elétrica, como picos de consumo, usando dados reais de um medidor eletrônico associado ao uso de SAEB, para atuar nestas anomalias detectadas pode prover muitos benefícios relacionados a eficiência energética, qualidade de energia e em aspectos econômicos para o consumidor.

Para tanto, é apresentado neste trabalho de dissertação a implementação do Algoritmo de Seleção Negativa (ASN), para detecção de anomalias no consumo de energia elétrica, utilizando os dados provenientes de um medidor eletrônico instalado em um prédio da UFCG, e de um modelo de sistema de armazenamento de energia por baterias (SAEB) para suprir a demanda de energia nos períodos de picos detectados. A partir da análise de comportamento destes dois elementos, fundamenta-se o desenvolvimento de uma interface que associa a detecção de anomalias, ao gerenciamento e intervenção dos armazenadores para reduzir picos de consumo de energia. A análise da aplicabilidade do sistema supervisorio é centrada no comportamento do estado de carga (SOC - *State of Charge*) de baterias comerciais, com capacidades de armazenamento distintos perante a anomalia detectada, bem como a avaliação do custo de implantação e vida útil do SAEB, com a função de suavizar os picos de consumo de energia elétrica.

1.1 Objetivos

O objetivo geral deste trabalho foi desenvolver um sistema que pudesse detectar anomalias no consumo de energia elétrica, e intervir nas anomalias referentes a picos de consumo utilizando um sistema de armazenamento de energia por baterias. Este sistema pode ser utilizado para detectar anomalias no consumo de locais que possuam medidores eletrônicos, e que estes medidores disponibilizem os dados de medição automática, além de armazenadores de energia que possam prover a redução de picos no consumo de energia elétrica quando acionados.

Para atingir o objetivo geral deste trabalho, delimitam-se os seguintes objetivos específicos:

- Modelar curvas padrão de consumo de energia elétrica diárias que possam ser referência do perfil de consumo de um prédio localizado na Universidade Federal de Campina Grande;

- Utilizar os conceitos de sistemas imunológicos artificiais e implementar um algoritmo de seleção negativa que detecte anomalias no consumo de energia elétrica;
- Desenvolver o modelo de um sistema de armazenamento de energia por baterias, que forneça o comportamento do estado de carga de baterias comerciais, com capacidade de armazenamento distintas no intuito de suprir as demandas de pico detectadas;
- Desenvolver uma interface associando a detecção de anomalias no consumo de energia elétrica, ao gerenciamento e intervenção do sistema de armazenamento de energia por baterias.

1.2 Organização do documento

O texto desta dissertação divide-se em outros 5 capítulos, além deste, que são apresentados a seguir. No Capítulo 2 é apresentada a fundamentação teórica acerca de medidores de energia elétrica, seus tipos principais e a curva de carga, que pode ser extraída dos dados fornecidos pelos medidores. Outrossim, é apresentada uma visão geral dos sistemas imunológicos artificiais, e algoritmo de seleção negativa abordando a teoria necessária para o desenvolvimento desta pesquisa.

No Capítulo 3 é apresentada uma revisão bibliográfica sobre pesquisas científicas relacionadas ao tema. O foco específico é dado aos trabalhos que mais contribuíram com informações sobre a detecção de anomalias no consumo de energia elétrica, aplicação de algoritmos inspirados no sistema imunológico artificial, algoritmo de seleção negativa e uso de sistemas de armazenamento de energia, para redução de picos no consumo de energia.

Com a fundamentação teórica sobre o tema construída e a identificação dos trabalhos mais relevantes tenha sido cumprida, no Capítulo 4 é introduzida a metodologia usada para a obtenção dos resultados.

Após a aplicação da metodologia proposta, obtiveram-se os resultados, sendo estes apresentados no Capítulo 5. Neste mesmo capítulo, é realizada uma discussão sobre a aplicabilidade e desenvolvimento do sistema proposto.

Por fim, no Capítulo 6, diante dos objetivos propostos e resultados obtidos, são discutidas as conclusões.

São apresentadas também, sugestões de trabalhos para a continuação da pesquisa, assim como as principais referências utilizadas. Trabalhos publicados e aceitos para publicação, relacionados à pesquisa ou à área de concentração, também são apresentados neste capítulo.

2 Fundamentação Teórica

Neste capítulo é fornecido um embasamento teórico para melhor entendimento do trabalho. Para tanto, são apresentados detalhes sobre os medidores de energia elétrica, sua evolução e os dois grupos principais de medidores e conceito sobre uma curva de carga. Foram fundamentados conceitos característicos de SIA, apresentando uma visão geral sobre o sistema imunológico biológico e as características do ASN. Por fim, são apresentados os conceitos de SAE, e os parâmetros de um SAEB a serem considerados para a utilização em uma aplicação, para que sejam compreendidas as etapas de desenvolvimento do sistema de detecção de anomalias associado a armazenadores para a redução de picos de consumo de energia elétrica .

2.1 Medidores de Energia Elétrica

As empresas distribuidoras de energia elétrica necessitam de equipamentos e sistemas de medição para mensurar e faturar sua principal receita. Segundo [12], medição se trata de um processo que é realizado por equipamento que possibilite quantificar e o registrar grandezas elétricas associadas à conversão ou consumo de energia, assim como à potência ativa ou reativa.

A energia fornecida pelas concessionárias distribuidoras a seus clientes é quantificada a partir de um equipamento, o medidor. O medidor de energia elétrica segundo [13] é definido como é um dispositivo ou um equipamento eletromecânico ou eletrônico capaz de medir (mensurar) o consumo de energia elétrica de um estabelecimento. Os equipamentos utilizados para a medição de energia elétrica devem atender padrões técnicos predeterminados por órgãos oficiais de metrologia, em conformidade às normas aplicáveis ao setor.

A muitas décadas, o medidor eletromecânico tem sido o instrumento de medição utilizado pelas distribuidoras do setor elétrico brasileiro, com cerca de 92,61% ,com base nos dados da pesquisa de [14].

Contudo, os medidores eletrônicos têm ganhado representatividade no setor elétrico brasileiro e empresas de todos os tamanhos, institutos de pesquisa, Universidades e mesmo desenvolvedores independentes estão trabalhando na construção e melhoria destes dispositivos. A seguir, são apresentadas uma breve contextualização sobre a história dos medidores, os dois modelos existentes e a curva de carga que pode ser extraída dos dados dos medidores.

2.1.1 A evolução dos medidores de energia elétrica

O instrumento utilizado para medir a quantidade de eletricidade ou energia, necessária ao funcionamento de uma carga, ou um conjunto delas, durante um determinado intervalo de tempo, recebe o nome de medidor de energia elétrica, ou medidor de watt-hora. A unidade comercial de energia elétrica é o kWh.

Sejam $v(t)$ e $i(t)$ respectivamente, os sinais da tensão e da corrente em um dado circuito. A potência instantânea é dada pelo produto entre essas duas grandezas, mostrada na Eq. 2.1:

$$p(t) = v(t) \cdot i(t) \quad (2.1)$$

A potência ativa ou média, é obtida como resultado do teorema do valor médio aplicado a Eq. 2.1. em que t_a é o tempo inicial da amostra e τ é o período escolhido para efetuar a integral.

$$P(\tau) = \frac{1}{\tau} \int_{t_a}^{t_a+\tau} p(t) dt \quad (2.2)$$

Para se obter a energia consumida, faz-se a integral no resultado da Eq. 2.2, P , no tempo, ou:

$$E(t) = \int_{t_0}^t P(y) dy \quad (2.3)$$

As Eqs. 2.1, 2.2 e 2.3 podem simplificar o conceito formal de medição de energia. Porém, a estimativa do consumo pode surgir de parâmetros indiretos. O primeiro aparelho que foi utilizado para taxar o consumo de energia foi desenvolvido em 1872 por Samuel Gardiner operando em corrente contínua. O princípio de funcionamento do medidor de Gardiner era simples. Consistia na utilização de uma carga conhecida, cronometrando o tempo em que o aparelho permanecia ligado. E assim, o consumo era dado multiplicando a potência nominal da carga pelo tempo de funcionamento do aparelho.


O primeiro medidor operando em corrente alternada foi desenvolvido por J. B. Fuller, em 1878. O funcionamento se dava por um sistema de bobinas que oscilavam na mesma frequência da onda da tensão da rede elétrica, e acionavam um conjunto de engrenagens que faziam girar um disco, contando um valor proporcional ao número de ciclos de rede em que o aparelho permaneceu ligado. Para este medidor, o tempo de consumo era a grandeza indireta que indicava o consumo da carga.

Entre o final da década de 1870 e início da de 1880, Thomas Edison foi responsável pelo desenvolvimento de um medidor para corrente contínua com características bastante distintas dos até então inventados, pois já não era necessário saber a potência nominal da carga para que se pudesse obter a medida de energia. A tensão fornecida era assumida como constante e integrando de forma química o valor da corrente instantânea, era possível apontar o consumo individual.

Logo após a invenção de Thomas Edison, em meados da década de 1880, Elihu Thomsom, auxiliado por Thomas Duncan, desenvolveu um medidor em que era possível operar em corrente alternada e em corrente contínua. Neste medidor, o princípio da indução eletromagnética foi utilizado pela primeira vez.

Os medidores de watt-hora eletromecânicos que executam a mesma função, utilizando os mesmos princípios conhecidos nos dias de hoje, foram criados por Thomas Duncan, em 1892. Na Figura 2.1 é mostrado um modelo do medidor de Duncan.

Figura 2.1 – Medidor T. Duncan.



Os medidores atuais estão subdivididos em dois grandes grupos: os eletromecânicos que seguem os mesmos princípios básicos já estudados por Duncan, e os eletrônicos que usam componentes de estado sólido para efetuar a medida de energia.


2.1.2 Medidores Eletromecânicos

Os medidores eletromecânicos foram melhorados fisicamente e quanto a exatidão na medição, mas o seu princípio de funcionamento é o mesmo pensado por Duncan. Seu funcionamento poder ser comparado ao de um motor de indução. Os campos oriundos das bobinas de tensão e de corrente induzem a rotação de um disco móvel, que por sua vez aciona um conjunto de engrenagens responsáveis em registrar o consumo da carga.

Na Figura 2.2 é representado um esquema de um medidor de energia eletromecânico e suas configurações: ponteiro e ciclométrico. As bobinas de corrente juntamente com a de tensão e seus respectivos núcleos, formam o elemento motor, responsável em provocar um

conjugado motor sobre o elemento móvel. Ao girar, o elemento móvel o faz com velocidade angular proporcional à potência ativa que está sendo dissipada pela carga. No entanto, se a carga for desligada, por inércia rotacional esse elemento tende a permanecer girando. O que se faz é adicionar um freio magnético, um ímã permanente que gera no elemento rotor um conjugado proporcional à velocidade de giro de tal elemento, no sentido contrário ao movimento (Lei de Lenz). Anéis de cobre são usados para o ajuste fino do medidor. Para reduzir o atrito mecânico, o disco de alumínio gira em torno de uma suspensão magnética.

Figura 2.2 – Esquema do medidor de energia eletromecânico e suas configurações: ponteiro e ciclométrico.



Fonte: Adaptado de [15].

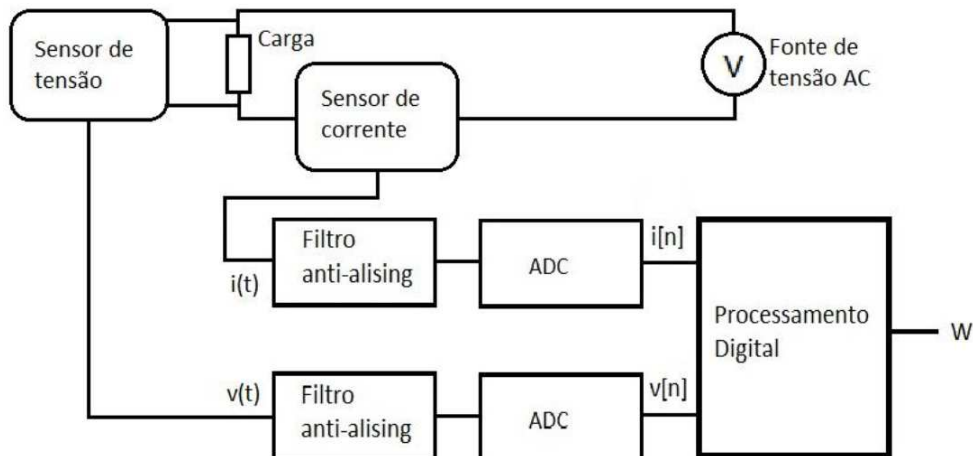
2.1.3 Medidores Eletrônicos

Os medidores eletrônicos se diferem dos eletromecânicos pois não possuem elementos mecânicos, constituídos no mecanismo primário da medição tradicional do consumo de energia elétrica. Os medidores eletrônicos têm como método de medição, os transdutores de corrente e potência, que são alimentados por sinais de entrada.

Esse tipo de medidor apresenta muitas vantagens em relação ao medidor eletromecânico: dimensão reduzida, menor custo, não possui partes móveis, fornece mais informações, etc. De uma forma geral, podem ser descritos pelos blocos apresentados na Figura 2.3. A carga é monitorada por dois sensores, um de corrente que fornece uma corrente $i(t)$ proporcional a corrente que circula pela carga, e um de tensão $v(t)$ que fornece uma tensão proporcional a tensão na carga. Os sinais oriundos desses sensores passam por filtros analógicos *anti-aliasing* e são amostrados pelos circuitos conversores de analógico para digital (ADC - *Analog Digital Converter*). Os sinais amostrados, e passam por um processamento digital de sinais (DSP - *Digital Signal Processing*), de onde é possível obter

a potência ativa. O valor da energia utilizada pela carga é calculado integrando essa potência no tempo.

Figura 2.3 – Diagrama de blocos de um medidor eletrônico.



Fonte: Adaptado de [13].

Na Figura 2.4 é mostrado o medidor desenvolvido no Laboratório de Metrologia de Campina Grande (LabMet), por uma equipe coordenada pelo professor Edmar Candeia Gurjão e instalado pela UFCG para medição individual do consumo de energia elétrica nos blocos existentes na instituição. Este medidor de energia elétrica é capaz de medir parâmetros da rede elétrica ao qual estiver conectado, são eles: potência ativa, potência reativa e fator de potência. Estes dados são enviados para um servidor pela internet que armazena os dados e também é disponibilizado em uma plataforma gráfica na rede chamada Grafana.

Figura 2.4 – Medidor inteligente instalado no Bloco CJ da UFCG.




Fonte: Elaborada pela autora.

2.1.4 Curva de Carga

A curva de carga é definida como a curva em que é apresentada a demanda em função do tempo, $D(t)$, para um dado período T , conforme a Figura 2.5.

Figura 2.5 – Exemplo de Curva de carga.



Fonte: Adaptada de [16].

A curva de carga é composta por patamares, entretanto, é mais comum que ela seja apresentada como uma curva suave, resultando da união dos pontos médios das bases superiores dos retângulos de largura Δt . Para um período T , a ordenada máxima da curva define a demanda máxima, DM . A energia total consumida no período, Δt , é medida pela área entre a curva e o eixo dos tempos, ou seja, pela Eq. 2.4:

$$\varepsilon_T = \int_0^T D(t) \cdot dt \quad (2.4)$$

A compreensão dos parâmetros da curva de carga ainda permite uma análise mais detalhada para o melhor enquadramento tarifário do consumidor, e também permite visualizar uma possível aplicação de ações de eficiência energética, por meio do gerenciamento da demanda, colaborando assim para a redução de tarifas e consumo.

Os consumidores de energia possuem diferentes características de consumo, de acordo com a natureza de sua carga: residencial, comercial, industrial, rural, iluminação pública e serviço público, da sua conexão: trifásica, bifásica ou monofásica e da tensão de alimentação: alta, média ou baixa tensão. Portanto, suas curvas de carga apresentam um comportamento diferenciado de consumo ao decorrer do dia. A tipologia da curva de carga pode ser analisada individualmente para cada segmento consumidor de energia, que tenha participação expressiva no consumo.

Para utilizar os dados de um medidor de energia elétrica com o intuito de identificar possíveis anormalidades no consumo de energia, se faz necessário compreender melhor sobre sistemas imunológicos artificiais e a sua teoria para a aplicação proposta.

2.2 Sistemas Imunológicos Artificiais

2.2.1 Visão geral do sistema imunológico biológico

O sistema imunológico biológico se refere a todas as estruturas utilizadas para proteção do organismo contra agentes patogênicos, sejam eles, bactérias, vírus ou moléculas estranhas. As células do organismo são nominadas próprias e os agentes patogênicos nominados de não-próprios. Uma das principais funções desse sistema é que se possa reconhecer as células do corpo e classificar as mesmas como próprias ou não-próprias [17], [18]. Muitas propriedades do sistema imunológico biológico são de grande relevância nos estudos de pesquisadores das áreas da Medicina e de outras áreas da tecnologia como a Ciência da Computação e a Engenharia. Algumas das propriedades existentes nos sistemas imunológicos são elencadas a seguir:

- a. **Unicidade:** em que se trata do fato do sistema biológico de cada ser vivo ser único;
- b. **Detecção distribuída:** os detectores usados no sistema imunológico são diminutos e eficazes, são elevadamente distribuídos e não estão sujeitos a um controle unificado;
- c. **Detecção de anomalias:** o sistema imunológico pode detectar e responder a agentes patogênicos que nunca antes haviam sido avistadas;
- d. **Aprendizado e memória:** o sistema imunológico pode assimilar as estruturas dos agentes patogênicos e “memoriar” essas estruturas para futuras reações sejam mais velozes na presença destes agentes.

As propriedades descritas anteriormente tornam o sistema imunológico escalável, robusto e com flexibilidade [2]. Dois tipos principais de mecanismos de defesa são encontrados no organismo: o inato (nasce com o ser vivo) e o adquirido (ou adaptativo). Quando o organismo é penetrado por um agente patogênico, o sistema inato é acionado primeiramente e, na maioria das vezes, essa resposta protege por si mesma o organismo. Em caso de falha deste sistema, o adaptativo entra em ação. Como se trata de uma intervenção específica, a resposta é mais eficiente.

A detecção distribuída é usada pelo sistema imunológico no intuito de solucionar o problema da distinção entre o próprio e o não-próprio. Efetivamente, a performance do


sistema imunológico é dependente de sua habilidade em detectar elementos não-próprios danosos [2].

Detectar elementos não-próprios danosos é um problema complexo, posto que:

1. A quantidade de indicadores não-próprios, ou seja, o número de proteínas (estimado em 10^{16}) que um receptor de uma célula de defesa humana pode reconhecer é muito maior do que o número de proteínas diferentes produzidas pelo corpo humano viabilizadas para utilização pelo sistema imunológico a fim de construir receptores (estimado em 10^6 proteínas);
2. O ambiente é excessivamente distribuído, assim, não existe um controle unificado das funções de monitoramento e detecção de agentes patogênicos;
3. É imprescindível que o organismo continue funcionando.

A resolução deste problema se dá pelo desenvolvimento por parte do sistema imunológico, de uma arquitetura com diversas camadas de defesa, conforme mostrado na Figura 2.6.

Figura 2.6 – Camadas do sistema imunológico biológico.



Fonte: [19].

A composição desta arquitetura se dá por diversas camadas de defesa, como a pele (primeira barreira contra agentes externos), barreiras bioquímicas (temperatura interna, Ph, etc.) e a resposta imune inata e a resposta imune adaptativa (ou adquirida). A resposta adquirida refere-se à proteção desenvolvida por um organismo biológico (por meio de processos específicos de aperfeiçoamento de suas células de defesa) contra determinados tipos de microorganismos ou substâncias estranhas.

As células mais importantes do sistema adaptativo são conhecidas como linfócitos, ou também, glóbulos brancos, e são de dois tipos: T e B. Em se tratando de distinguir padrões no sistema imunológico, o atributo mais considerável dessas células é que as duas possuem moléculas receptoras em sua superfície que estão aptas a reconhecer antígenos. As células do tipo B têm sua produção na medula óssea e sua responsabilidade é pela imunidade humoral e assim combater organismos extracelulares [2].

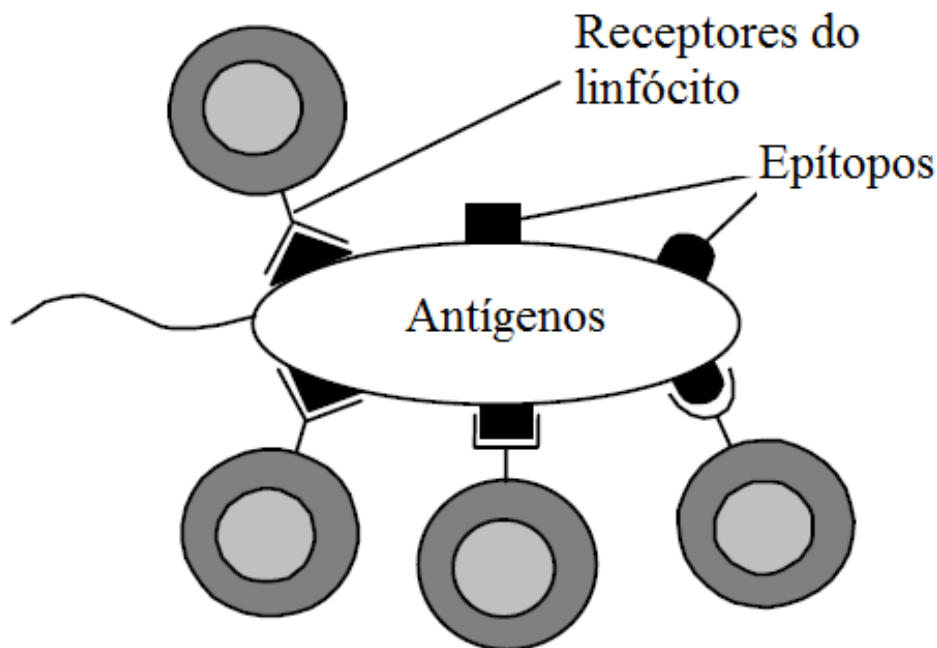
Células do tipo T têm seu processo de maturação ocorrendo no Timo (uma glândula localizada por detrás dos pulmões) ainda no período fetal e na infância. A imunidade celular e o processo de discriminação próprio e não-próprio são competências destas células. Durante a constituição das células T, os receptores (epítomos) são produzidos por meio de um processo pseudo-aleatório de rearranjo genético. Conseqüentemente, estes receptores são monitorados no Timo, a este processo de monitoramento dá-se o nome de seleção negativa, em que células T que reagem às proteínas do corpo são destruídas [20]. Assim sendo, apenas as células não conectadas às proteínas do organismo são liberadas para deixar o Timo. Estas células, são nominadas como células maduras, e passam a circular no organismo realizando as funções imunológicas e protegem o organismo contra antígenos.

2.2.2 Reconhecimento de agentes patogênicos

Os linfócitos ou glóbulos brancos, têm o papel de detectar ou reconhecer agentes patogênicos no sistema imunológico adquirido.

O método de reconhecimento dos antígenos por parte dos linfócitos se dá pela união entre eles. Os agentes patogênicos (ou antígenos) são localizados por meio de uma ligação molecular estabelecida entre os agentes patogênicos e os receptores presentes nas superfícies do linfócito, segundo mostrado na Figura 2.7. Por conta de sua grande dimensão e a complexidade da maior parte dos agentes patogênicos, somente um componente, nominados epítomos, se une (reage) aos receptores do linfócito. Um receptor particularmente, não será capaz de reagir a todos os agentes patogênicos: quanto mais estruturas do epítomo e do receptor forem complementares, maior a probabilidade de união.

Figura 2.7 – União entre receptores e epítomos.



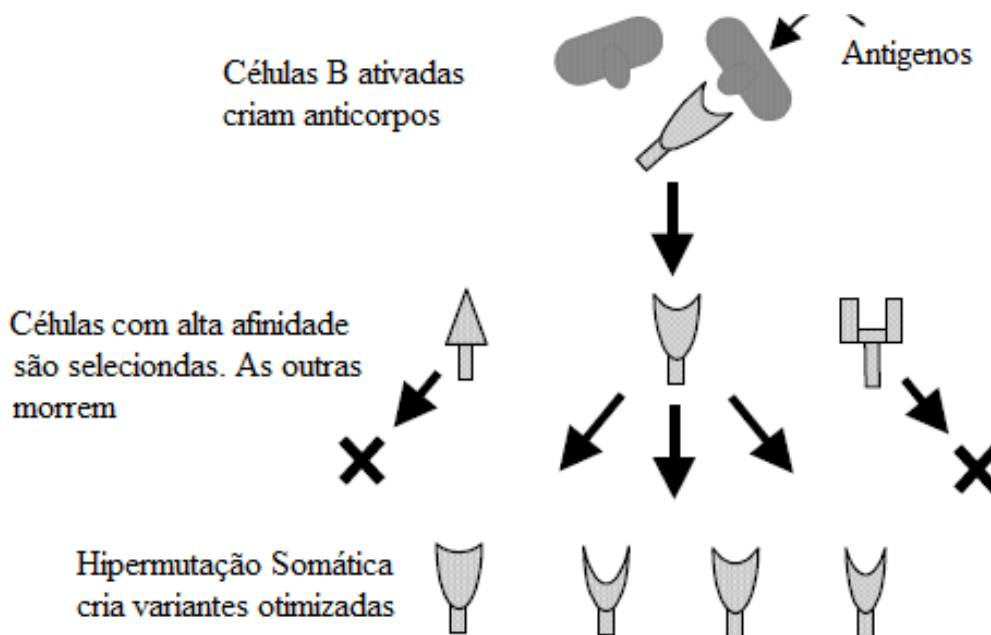
Fonte: [19].

Desse modo, em virtude da grande quantidade e variedade de agentes infecciosos, não é possível ao corpo produzir uma célula T que reaja (case) totalmente com todos os epítomos de cada componente invasor. Para atender à essa impossibilidade, o corpo deve permitir que a reação com apenas alguns dos epítomos do elemento invasor seja suficiente para a sua detecção, a esta ação nomina-se **casamento parcial**. Diante disso, uma única célula tipo T deverá ser capaz de reconhecer diversos desses agentes. Implicando em que uma única célula seja capaz de detectar um subconjunto de epítomos, sendo isto muito vantajoso, já que uma pequena quantidade de linfócitos reconhece uma grande variedade de antígenos [2].

Para satisfazer apropriadamente a todos os padrões não-próprios, é necessário que exista uma grande variedade de receptores, com limiares de afinidades relativamente baixos. O que permite ao sistema imunológico detectar praticamente qualquer tipo de agente patogênico vivo. Contudo esta detecção pode dilatar o tempo, devido a demora, os agentes patogênicos podem se reproduzir e causar malefícios.

Assim sendo, o sistema imunológico carece de um método para identificar e suprimir agentes patogênicos o mais rápido possível. Os linfócitos comuns não são suficientemente lépidos para detectar agentes patogênicos, nem muito eficientes para detê-los. Dessa forma, o sistema imunológico possui mecanismos que permitem que os linfócitos assimilem as estruturas de proteínas estranhas específicas. Ou seja, realizado através de um processo nominado **maturação de afinidade**, apresentado na Figura 2.8.

Figura 2.8 – Mecanismo de maturação de afinidade entre células tipo B.



Fonte: [19].

A maturação de afinidade se utiliza de um subconjunto de linfócitos chamados de células B, assim denominados devido a sua maturação ocorrer na medula óssea (*bone marrow*). Quando uma célula B é acionada, por meio da união com agentes patogênicos, ela primeiramente expõe uma forma solúvel de seus receptores, os anticorpos, que é capaz de se unir aos agentes patogênicos (por meio dos epítopos) com a função de deixá-los inativos ou para identificá-los para células do sistema imunológico inato. Conseqüentemente, as células B são clonadas, mas suas cópias produzidas não são idênticas, pois a clonagem está sujeita a mutações com uma taxa muito alta, denominada de **hipermutação somática**. Estas novas células B também poderão se ligar aos agentes patogênicos. Se elas tiverem uma alta afinidade com os agentes externos, elas serão, por sua vez, ativadas e clonadas.

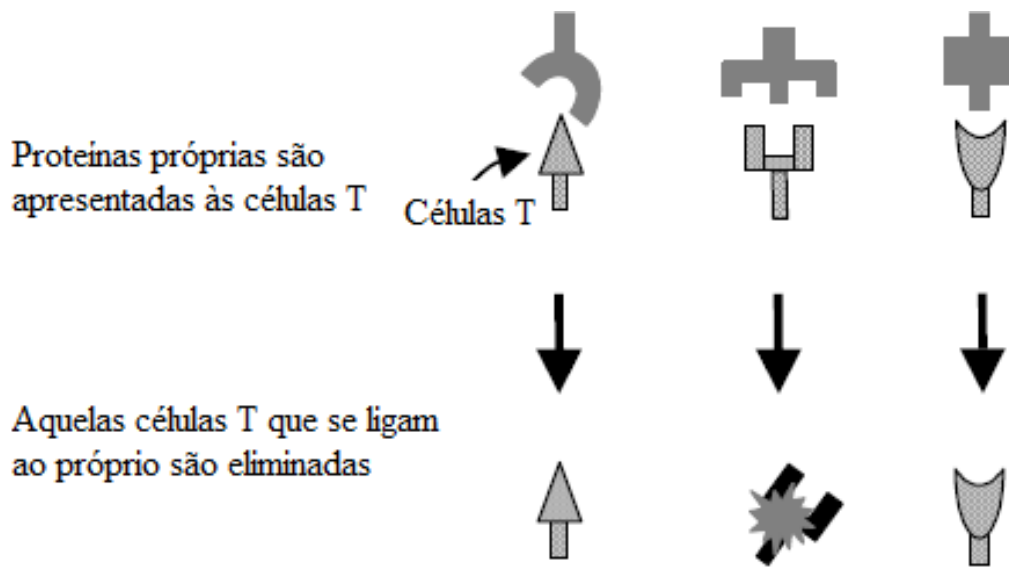
Dessa maneira, à medida que a população de células B passa pelo processo de maturação de afinidade, ela evolui. As células B com maior afinidade aos agentes patogênicos, isto é, células B mais eficientes, serão produzidas para detectar e capturar estes agentes.

2.2.3 Tolerância ao próprio

Os receptores que são produzidos aleatoriamente e sujeitos à mudanças aleatórias por meio de hipermutação poderiam se unir com facilidade a padrões próprios e iniciando respostas autoimunes. Contudo, isto eventualmente acontece, pois em sua maioria, o sistema imunológico é tolerante ao próprio, isto é, ele “não ataca” o que faz parte dele.

Esta tolerância é executada por outra classe de linfócitos chamados de células *T helper*, já que sua maturação ocorre no timo e auxiliam as células B. Devido a maioria das proteínas do organismo circular pelo timo, as células *T* que estão amadurecendo nesta glândula são expostas a estas proteínas. No caso de uma célula *T* se unir (reagir) a alguma dessas proteínas, ela será retirada em um processo denominado eliminação clonal(do inglês *clonal deletion*), conforme mostrado na Figura 2.9. As células *T* que sobreviverem ao processo de maturação serão tolerantes a maior parte das proteínas do organismo. Esta tolerância é unificada, portanto células *T* imaturas são toleradas em um único local.

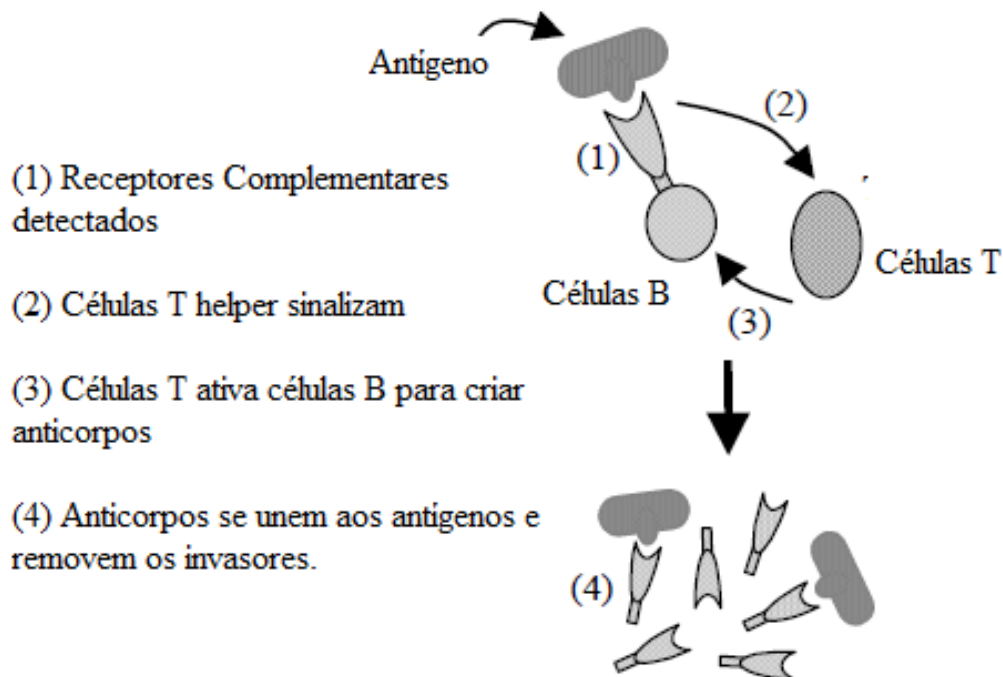
Figura 2.9 – Mecanismo de maturação de afinidade entre células tipo T.



Fonte: [19].

Garantir a tolerância de células B é um problema mais complexo, pois a maturação dessas células é distribuída [2]. Assim, se faz necessário um sistema de controle compartilhado para garantir a tolerância ao próprio. As células *T helper* são responsáveis pelo controle se utilizando mecanismo conhecido como coestimulação. Para ser acionada, uma célula B precisa receber coestimulação por dois sinais: o primeiro sinal acontece quando o número de agentes patogênicos que reagem (por meio dos epítomos) aos receptores ultrapassar um determinado limiar e o segundo sinal é fornecido pelas células *T helper*. Elas fornecerão este sinal apenas se reconhecerem o agente patogênico que a célula B capturou. Este processo de coestimulação conforme mostrado na Figura 2.10.

Figura 2.10 – Processo de coestimulação.



Fonte: [19].

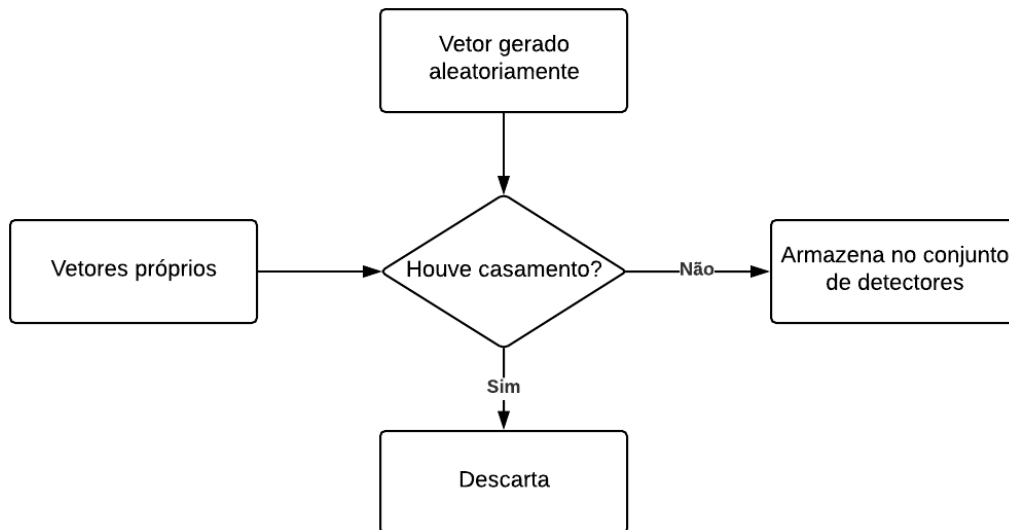
2.3 Algoritmo de seleção negativa

O Algoritmo de Seleção Negativa (ASN) é inspirado no mecanismo utilizado pelo sistema imunológico para treinar as células *T* (seleção negativa) e este processo é considerado um dos maiores mecanismos pertencentes ao complexo sistema imunológico. Tais células são treinadas para reconhecer antígenos (não-próprio) e para evitar que reconheçam as próprias células do corpo (próprio) [21]. A ideia é estabelecer um conjunto de detectores, inicialmente criando candidatos de forma aleatória e, então, descartando os que reconhecem dados pertencentes ao próprio. Baseado na proposta de [22] o algoritmo possui três etapas principais:

1. **Definição do conjunto de dados próprios:** determinar como próprio uma coleção de cadeias/vetores de tamanho restrito, que precise de resguardo ou monitoramento;
2. **Fase de Geração de Detectores:** gerar vetores aleatórios e analisar a semelhança entre cada um deles e os vetores próprios. Caso a semelhança (correspondente a um critério de comparação entre dois elementos de uma mesma cadeia) seja igual (ou superior) a um determinado limiar, isto quer dizer que houve um reconhecimento (detecção) do conjunto próprio, e que, portanto, a cadeia/vetores deve ser rejeitada; caso contrário deve-se armazenar em um conjunto de detectores. De modo geral, os candidatos a detectores são gerados aleatoriamente e testados individualmente para

verificar se casam com algum vetor pertencente ao próprio. Esta etapa é mostrada na Figura 2.11;

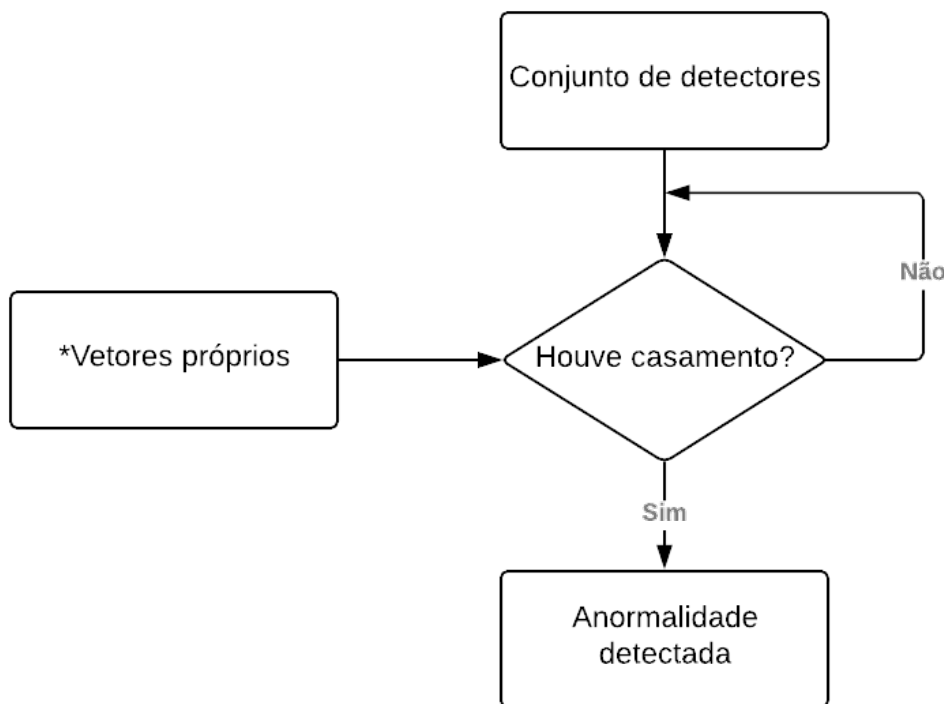
Figura 2.11 – Fase de geração de detectores segundo o ASN.



Fonte: Elaborada pela autora.

3. **Fase de Monitoramento:** monitorar prováveis alterações no conjunto de vetores próprios que se deseja proteger (em que podem sobrevir erros) utilizando os detectores gerados anteriormente. No caso de semelhanças entre um detector do conjunto de detectores e uma das cadeias/vetores próprios serem maiores (ou iguais) a um limiar previamente estabelecido, é possível afirmar que uma anomalia ocorreu, tendo em conta que os detectores nunca devem reconhecer cadeias do conjunto próprio. Esta etapa é mostrada na Figura 2.12.

Figura 2.12 – Fase de monitoramento segundo o ASN.



Nota: Aqui "***Vetores próprios**" podem ser suscetíveis a mudanças.

Fonte: Elaborada pela autora.

A similaridade, conceito apontado anteriormente, consiste na comparação entre dois elementos de uma mesma cadeia, com base em critérios de comparação parcial, definida por um parâmetro de comparação. Esta similaridade é inspirada no casamento parcial decorrente da reação de alguns epítomos de um elemento invasor com a superfície de uma célula do tipo T .

Uma das principais aplicações do ASN tem sido na área de detecção de anomalias, em que os detectores são gerados para que possam detectar alterações nos padrões dos dados [23]. O elemento mais importante do algoritmo de seleção negativa é a escolha do princípio de detecção, determinado assim, a similaridade entre dois padrões de modo a classificar as amostras em próprio/não-próprio (normal/anormal). Estimar a quantidade de detectores é necessária para assegurar determinada confiabilidade na detecção da anomalia. Se um limiar de detecção elevado for utilizado, os detectores gerados serão sensíveis a qualquer alteração nos dados, e, logo, uma quantidade maior de detectores será necessário para que o grau de confiabilidade desejado seja atingido. Em contrapartida, se o limiar for muito baixo, pode não ser possível gerar um conjunto de detectores de tamanho admissível

a partir do conjunto próprio disponível. O que sugere que o valor do limiar pode ser utilizado para que se possa ajustar a sensibilidade da detecção e diminuir o risco de falso-positivos [2].

2.3.1 Critérios de casamento parcial

No Algoritmo de Seleção Negativa é obrigatório que se defina um critério de casamento parcial para executar as fases de geração de detectores e de monitoramento. Um casamento completo (perfeito) acarreta na afirmação de que cada elemento de um vetor casa exatamente com o do detector, ou seja, cada detector identificará apenas um único vetor[17]. O emprego de um casamento parcial objetiva fazer com que cada detector tenha sua capacidade de detecção aumentada. Para exercer um casamento parcial entre dados em um sistema de monitoramento será utilizado o critério **r-Hamming**, que é bastante comum para este tipo de aplicação. Este critério é controlado por meio do parâmetro r (parâmetro de casamento).

2.3.1.1 Critério de casamento r-Hamming

Este critério é baseado na distância de Hamming e consiste em verificar se dois vetores de comprimentos iguais e pertencentes ao mesmo princípio são idênticos em pelo menos r posições correspondentes, mas não necessariamente de forma contínua. Por exemplo, suponha que sejam utilizados dois vetores binários A e B conforme mostrado na Eq. 2.5. Estes vetores casam para qualquer $r \leq 9$, utilizando o critério de casamento r-Hamming.

$$\begin{aligned} A &= [1100101010111010] \\ B &= [0010101001101011] \end{aligned} \tag{2.5}$$

2.3.1.2 Critério de casamento para casos com vetores reais

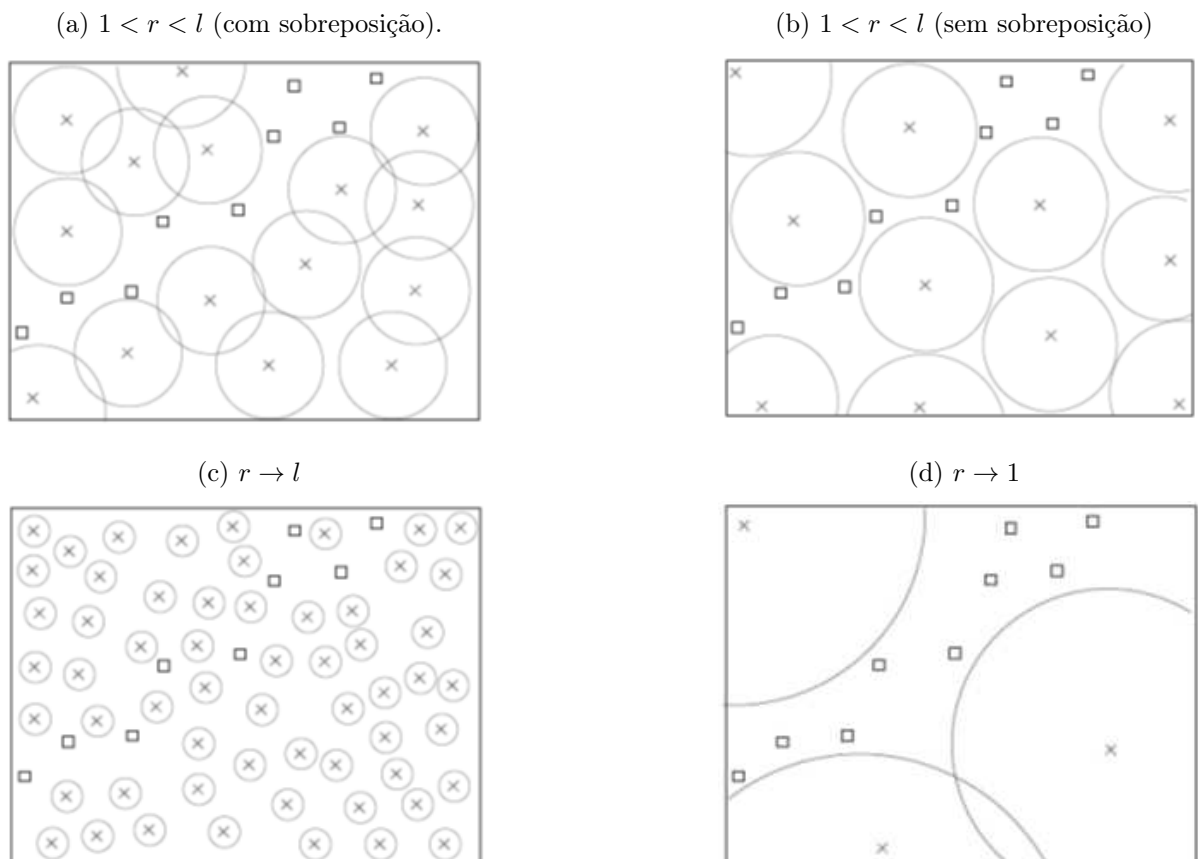
Para realizar a comparação entre dois vetores cujos elementos são formados por números reais são encontradas diversas técnicas [24]. Nesta pesquisa, para esta finalidade, utilizou-se uma variável auxiliar denominada desvio (ϵ). Assim, as posições correspondentes do vetor erro casam se a diferença, em módulo, entre esses dois vetores for menor ou igual ao desvio (erro absoluto) pré-estabelecido. Por exemplo, supondo que sejam apresentados dois vetores reais X e Y de comprimentos iguais, pertencentes ao mesmo princípio e que o desvio escolhido para promover a comparação entre eles seja $\epsilon = 0,2$. Estes vetores podem ser observados na Eq. 2.6. Dessa forma, o vetor Z é formado pelo casamento, neste caso

utilizando o critério r-Hamming, em que 1 é o bit representativo caso a diferença entre o valor de cada elemento do vetor X com cada elemento de Y for menor (ou igual) ao o desvio ϵ e 0 caso contrário.

$$\begin{aligned} X &= [1, 20, 0, 50, 1, 80, 0, 95, 2, 00, 3, 10, 0, 60, 1, 30, 0, 64, 2, 54] \\ Y &= [1, 40, 1, 00, 2, 30, 0, 76, 2, 10, 1, 54, 1, 00, 1, 19, 0, 78, 1, 32] \\ Z &= [1, 0, 0, 1, 1, 0, 0, 1, 1, 0] \end{aligned} \tag{2.6}$$

Na Figura 2.13a é apresentada, em um espaço bidimensional, a ideia básica sobre espaços de detecção e sua relação com o parâmetro r . Nesta figura, os quadrados pequenos representam os vetores próprios, os símbolos x representam os detectores e os espaços de detecção são representados por círculos. É possível verificar que sobreposições de espaços de detecção podem ocorrer. O que significa que mais de um detector é capaz de detectar um mesmo vetor não-próprio, logo, existem detectores repetitivos para cobrir o espaço não-próprio. O caso ideal, em relação ao número de detectores, é mostrado na Figura 2.13b em que não existe sobreposição de espaços de detecção.

Figura 2.13 – Relação entre espaços de detecção com o parâmetro r . Os vetores próprios são representados por \square , detectores por x , espaços de detecção por \circ



Fonte: [17].

Da ocorrência de casos extremos: em que o raio de cobertura r tende ao comprimento do vetor l $r \rightarrow l$ e quando o raio de cobertura tende a 1 ($r \rightarrow 1$). Estes casos são observados nas Figuras 2.13c e 2.13d, respectivamente. No primeiro caso, o espaço de detecção de cada detector é bem reduzido o que resulta em um grande número de detectores para identificar vetores não-próprios. Também, neste caso, a tendência do casamento, entre os vetores, pode deixar de ser parcial (que aumenta a cobertura de detecção de falhas) para ser completo (em que um detector é capaz de estar associado apenas a um vetor de falha). No segundo caso, cada detector possui um grande espaço de detecção, apesar disso, a geração de tais detectores é computacionalmente complexa [17].

2.3.2 Probabilidade de erro de detecção

Dada a existência de um conjunto de detectores d em que se deseja saber qual a probabilidade desses detectores não identificarem um elemento não-próprio ao sistema, isto é, qual a probabilidade de erro na detecção de uma mudança ocorrida em algum elemento próprio ao sistema não ser relatada, segundo a fase de monitoramento do ASN proposto por [22].

Com o intuito de sanar essa dúvida, é necessário identificar a probabilidade de que dois vetores aleatórios casem conforme um dado critério de casamento.

Para o critério de casamento **r-Hamming**, (quaisquer condições) considerando p o vetor de dados próprios e l o comprimento deste vetor. A probabilidade P_H de que dois vetores aleatórios casem em pelo menos r posições por este critério [17] é dada na Eq. 2.7:

$$P_H = \frac{1}{p^l} \left[\sum_{i=r}^l \binom{l}{i} (p-1)^{l-i} \right] \quad (2.7)$$

Geralmente, a probabilidade P_M que d detectores falhem em detectar **um** vetor não-próprio, ou seja, a probabilidade de erro de detecção P_e será dada na Eq. 2.8:

$$P_e = (1 - P_M)^d \quad (2.8)$$

Assim, quanto maior for a quantidade de detectores, menor será a probabilidade de erro de detecção P_e . Além disso, quanto maior a probabilidade de casamento P_M , menor será a probabilidade de erro de detecção P_e .

2.3.3 Exemplo de aplicação do algoritmo de seleção negativa

Admitindo como vetores próprios, dados a serem monitorados, tomando os seguintes vetores de 4 bits cada: $P = [0010, 1000, 1101, 0000, 0100, 0010, 1001, 0011]$. A fase de geração de detectores será responsável em gerar vetores aleatórios (conjunto D) e, então, verificar se os vetores em D casam com algum vetor em P . Caso algum vetor em D casar com qualquer vetor próprio em P , então este vetor é descartado. Aqueles que não forem descartados tornam-se membros do conjunto de vetores detectores, formando o conjunto de detectores (CD).

Por exemplo, supondo $D = [0111, 1000, 0101, 1001]$ (formado por quatro vetores aleatórios). Assim, CD possuirá dois vetores, 0111 e 0101, pois os demais vetores (1000 e 1001) serão descartados já que cada um deles casa com um vetor em P . Na verdade, o processo consiste em gerar vetores aleatórios continuamente até que o conjunto CD contenha um número adequado de detectores.

Considerando, agora, que em P possam ocorrer erros, a fase de monitoramento de erro irá verificar, continuamente, se detectores em CD casam com algum vetor em P . Por exemplo, supondo que um bit do último vetor próprio (0011) mude, produzindo o vetor 0111. Assim, em algum ponto da fase de monitoramento, será verificado que o vetor não-próprio 0111 casa com algum dos detectores (nesse caso o detector 0111), e um erro em P será relatado, ou seja, o algoritmo detectou uma anomalia.

2.4 Sistemas de armazenamento de energia

O significado de *Armazenar* se refere a guardar ou recolher, conter em depósito, acumular-se, fazer provisões. Desde a descoberta da eletricidade, métodos efetivos têm sido procurados para armazenar energia elétrica com eficiência. A indústria do armazenamento está evoluindo notavelmente, para se adequar aos requisitos e avanços da tecnologia. O sistema de armazenamento de energia (SAE) consiste em acrescentar a um sistema de conversão ou distribuição um outro com capacidade de armazenar energia para a usar, posteriormente, de forma mais proveitosa e possui uma grande variedade de abordagens tecnológicas para gerir o fornecimento de energia e criar uma infraestrutura energética mais resistente.

As principais tecnologias para armazenamento de energia tem como base, a conversão de energia elétrica em energia mecânica, térmica ou química e vice-versa. A energia elétrica pode ser armazenada, também em sua própria forma, sem necessidade de conversão, por meio de campo elétrico e do campo magnético, é o caso da tecnologia de supercapacitores e dos sistemas supercondutores, respectivamente.

As tecnologias apresentam características específicas em relação a capacidade de armazenamento e tempo de atuação, estas especificações se baseiam nas escolhas do tipo de armazenamento em função da aplicação a qual se destina. Dentre as principais aplicações identificadas do sistema de armazenamento de energia para consumidores, destacam-se:

1. **Redução de pico ou ponta de carga:** armazenar a energia em períodos de maior disponibilidade para utilizar em períodos de maior restrição. Um exemplo desta aplicação, é a redução da demanda contratada para consumidores com picos de consumo.
2. **Arbitragem:** armazenar a energia em períodos de menor custo para utilizar em períodos de maior custo. Comumente, este uso está associado a redução de pico. Neste caso, a redução da demanda contratada no horário de ponta é um exemplo, quando a energia tem custo elevado, ou até a substituição de Grupos Motor-Geradores (GMGs) para clientes que substituem a contratação de demanda na ponta por geração própria. A utilização em *shopping centers* é o melhor exemplo desta aplicação;
3. **Deslocamento de consumo:** armazenar energia em períodos de maior produção (oferta) para utilizar em períodos de maior demanda (consumo). Esta alternativa é particularmente aplicada a sistemas isolados. Por exemplo: a energia é produzida durante os horários de incidência solar para consumo durante a noite;
4. **Confiabilidade:** armazenamento da energia em períodos com disponibilidade, para uso em períodos de indisponibilidade – por exemplo, os *no – breaks* utilizados em centros de processamento de dados, centrais de segurança etc. Existem aplicações deste tipo em que os sistemas de armazenamento são uma exigência, ou, um requisito legal, como em hospitais e centros cirúrgicos.
5. **Suprimento a picos de demanda de potência:** aplicação para sistemas de tração elétrica ou em indústrias com cargas de grande inércia, as partidas da carga exigem altos picos de potência. Baterias podem suprir estes picos de curta duração, reduzindo o dimensionamento do sistema de suprimento.
6. **Suavização de oscilações de potência:** esta aplicação se dá quando uma fonte de energia é incapaz de fornecer uma saída constante de potência. Por exemplo, uma usina solar, sujeita a momentos de maior ou menor insolação, ou um gerador eólico, sujeito a momentos de maior ou menor intensidade de vento.
7. **Suprimento contínuo de energia em sistemas isolados:** os sistemas isolados são aqueles não conectados ao Sistema Interligado Nacional (SIN) e normalmente localizados em áreas remotas. Para estas aplicações, o uso de SAE é imprescindível para assegurar a continuidade do fornecimento, devido a intermitência das principais fontes de energia (solar, eólica ou mesmo geração diesel - GMG).

8. **Qualidade adicional para processos industriais sensíveis:** aplicação para determinados processos industriais com elevado nível de automação bastante sensíveis a oscilações e afundamentos de tensão, resultantes de distúrbios naturais do sistema elétrico. Por exemplo, um curto circuito seguido por um “religamento automático”, uma prática muito comum na operação de sistemas de distribuição de energia, e pode resultar em afundamento de tensão de curta duração (de frações de segundos até alguns poucos segundos), que podem levar à perda de várias horas de produção em processo sensíveis, além de perdas volumosas de produtos.

2.4.1 Características dos Sistemas de Armazenamento

Determinadas particularidades podem ser essenciais para que se possa definir o tipo de armazenamento mais adequado a uma determinada aplicação. Algumas especificações de tecnologia devem ser consideradas na decisão por um sistema de armazenamento adequado:

1. **Capacidade de Armazenamento de Energia:** é uma característica essencial a ser observada, quando a aplicação requer que o sistema de armazenamento propicie o gerenciamento de potência em um intervalo de tempo contínuo. Esta característica expressa a quantidade de energia que o sistema é capaz de armazenar, sendo expressa em Wh ou em múltiplos dessa unidade de medida;
2. **Potência Máxima:** é a potência máxima instantânea que o sistema pode captar ou injetar no sistema de conexão, expressa em W ou nos múltiplos dessa unidade;
3. **Constante de Tempo:** é a razão entre a Capacidade de Armazenamento de Energia e a Potência Máxima, usualmente expressa em horas ou frações de hora. A compreensão dessa especificação pode se dar como a quantidade de tempo máxima que a bateria pode captar ou injetar potência na rede de forma contínua;
4. **Tempo de Resposta:** é o tempo necessário para que, após o acionamento, o sistema responda com a absorção ou injeção de potência na rede correlacionada;
5. **Densidade de Energia e Densidade de Potência:** é definida pela capacidade de armazenamento por unidade de massa ou volume, a densidade de energia medida em Wh/kg ou Wh/L e a densidade de potência medida em W/kg ou W/L. Esses parâmetros refletem a dimensão que o equipamento deve possuir para armazenar determinada quantidade de energia ou potência;
6. **Eficiência:** a energia armazenada nem sempre é aproveitada totalmente, já que em qualquer processo não ideal, ocorrem perdas. Nos sistemas de armazenamento, as perdas estão associadas aos processos de conversão de energia e notadamente nas

baterias, as perdas estão ligadas ao processo de auto-descargas, quando a bateria sofre descargas parciais a vazio. A eficiência é expressa por um percentual de aproveitamento em relação à capacidade máxima do armazenamento;

7. **Tempo de Vida Útil:** os sistemas de armazenamento possuem uma estimativa de vida útil, com base na durabilidade e desgaste dos seus elementos. Devido a deterioração do equipamento, está mais suscetível a falhas, menor eficiência (fruto do aumento das perdas) ou mesmo perder capacidade de armazenamento. Essa característica pode ser definida em anos ou em ciclos de carga e descarga completos, que podem ser relacionados com a curva de *stress* e fadiga do material.

Especificações para sistemas de armazenamento fundamentados na utilização de baterias serão detalhadas a seguir. Determinados critérios de operação, que possuem relação com a estas especificações, são apontados para melhor proveito da capacidade de armazenamento e garantia de maior durabilidade do equipamento:

1. **Profundidade das Descargas (DOD):** é definida como a porcentagem da capacidade de armazenamento consumida em um processo de descarga. Para algumas baterias, como as de chumbo-ácido, o tempo de vida útil é influenciado diretamente pela estratégia de operação, de maneira que ao se permitirem descargas profundas (maiores que 80%), ocorre maior desgaste e a redução no tempo de vida útil do equipamento;
2. **Estado de Carga (SOC):** é a especificação que estabelece o nível de carregamento do sistema como um percentual da capacidade total de armazenamento. Um sistema que possua Estado de Carga igual a 100% está plenamente carregado, enquanto um sistema com Estado de Carga igual a zero está completamente descarregado;
3. **Estado de Carga Mínimo (SOC_{min}):** é necessário que se mantenha um carregamento mínimo para evitar o desgaste do equipamento. Devido ao efeito de *cut-off*, referente ao nível mínimo de carga que deve ser mantido na bateria para que seja possível a ocorrência de novas reações eletroquímicas. Abaixo desse carregamento mínimo, as reações eletroquímicas ficam impossibilitadas, assim, por mais que a bateria não esteja completamente descarregada, não há possibilidade de fornecer energia ao sistema. Comumente, se indica a operação da bateria com um SOC_{min} igual ou superior a 20% [25];
4. **Estado de Saúde (SOH):** esta especificação representa a capacidade de armazenamento do sistema como uma porcentagem da capacidade nominal de armazenamento. A importância deste parâmetro se dá após um longo tempo de uso do equipamento, momento ao qual se inicia a perda de capacidade de armazenamento, em consequência

de sua deterioração. É sugerida a troca do equipamento por um novo, quando um estado de saúde inferior a 80% é atingido[25].

Baterias são equipamentos compactos, e que não dependem fortemente das características do local em que serão instaladas, isto as torna mais flexíveis e ajustáveis. Por conta da flexibilidade característica dessa tecnologia, adicionada a sua capacidade de armazenar alta potência por horas, muitas pesquisas e experimentos focam nestes dispositivos, gerando, após últimos anos, o seu aperfeiçoamento, e a tornou ainda mais competitiva para aplicações integradas a rede elétrica.

2.4.2 Aspectos de funcionamento das baterias


O método utilizando baterias para fins de armazenamento ocorre por meio de reações eletroquímicas de oxirredução, que fornecem uma corrente elétrica, estabelecida pela transferência de elétrons do elemento que oxida (perde elétrons) para o elemento que reduz (recebe os elétrons), por intermédio de um meio condutor.

As baterias são constituídas por células eletroquímicas conectadas em série ou paralelo, onde ocorrem as reações. Uma célula eletroquímica é formada por dois condutores, chamados de eletrodos, separados pelo meio de transferência denominado eletrólito. No processo de descarga da bateria, quando a energia química é transformada em energia elétrica, uma reação de ionização acontece no interior da célula, de maneira que um dos eletrodos, chamado cátodo, recebe elétrons advindos do eletrodo oxidado, denominado ânodo. O fluxo de elétrons do ânodo para o cátodo pelo eletrólito forma uma diferença de potencial entre os eletrodos, que podem conectar-se um circuito externo por onde fluirá uma corrente elétrica gerada pela diferença de potencial dos pontos de contato.

No decorrer do processo de carga da bateria, uma corrente elétrica é aplicada sobre os eletrodos, provocando a reação inversa.

Nas Figuras 2.14a e a Figura 2.14b são apresentados os esquemas de funcionamento do processo de descarga e carga das baterias, respectivamente. É possível observar que o sentido do fluxo de corrente nos terminais da bateria nos dois processos é diferente.

Figura 2.14 – Esquema de funcionamento do processo de descarga e carga das baterias



Fonte: [25].

2.4.2.1 Bateria de Chumbo-Ácido


A bateria de chumbo-ácido vem sendo utilizada há muitos anos, especialmente na indústria automotiva, conseqüentemente, a sua tecnologia está consolidada no mercado. Neste tipo de bateria o ânodo é composto de chumbo metálico (P_b) o cátodo de dióxido de chumbo (P_bO_2) e o eletrólito composto por ácido sulfúrico (H_2SO_4)

A vantagem mais relevante a ser citada para esse tipo de bateria é o custo de instalação, que é inferior ao das outras baterias e outras alternativas de armazenamento, devido ao seu alto grau de maturidade tecnológica. Em contrapartida, as principais desvantagens associadas ao seu uso são dificuldade de se determinar e manter com exatidão seu estado de carga. Já a durabilidade dessa bateria depende muito da maneira como ela é descarregada e da temperatura em que ela é operada. Outra desvantagem em relação às outras tecnologias é a sua baixa densidade de energia por massa, 28 a 35 Wh/kg. A vida média de uma bateria de chumbo-ácido, sem a ocorrência de descargas profundas, dificilmente excede a 4 anos. Um ciclo completo de carga e descarga de uma bateria é definido quando a mesma se encontra a 100% da sua capacidade, utiliza uma determinada profundidade de descarga e torna a recarregar novamente até aos 100%.

Quanto menor for a profundidade da descarga maior é o número de ciclos da bateria, logo maior é a sua durabilidade. Se a profundidade de descarga de uma bateria for de 40%, esta dura duas vezes mais do que uma profundidade de descarga de 80%. Daí que

o recomendado seja uma profundidade de descarga na ordem dos 50% (o que não invalida que por vezes a descarga vá até aos 100%), pois é o valor que proporciona um melhor fator custo/armazenamento, o que confere a este tipo de baterias uma longevidade entre os 500 e os 800 ciclos. Na Figura 2.15 é mostrado um gráfico relacionando a quantidade de ciclos por profundidade de descarga de uma bateria.

Figura 2.15 – Ciclo de Vida de uma bateria chumbo-ácido.



Fonte: [26].

Neste capítulo de fundamentação teórica, foram apresentados fundamentos técnicos necessários para o entendimento deste trabalho de dissertação.

O embasamento teórico sobre medidores e curva de carga foram cruciais para o entendimento da motivação do trabalho. As análises do algoritmo de seleção negativa, assim como a utilização dos sistemas de armazenamento de energia por baterias contribuíram para a compreensão dos principais objetivos desta pesquisa.

No próximo capítulo, apresenta-se uma revisão bibliográfica desenvolvida sobre os principais trabalhos e contribuições relacionados ao tema abordado.

3 Revisão Bibliográfica

Neste capítulo, tendo como base o tema deste trabalho e as teorias estudadas nos capítulos anteriores, foi realizado um levantamento de trabalhos científicos publicados em anais de conferências e em revistas sobre detecção de anomalias no consumo de energia elétrica, utilização de sistema imunológico artificial para detecção de anomalias e uso de sistemas de armazenamento de energia com baterias para redução de picos de consumo de energia elétrica, a fim de analisar métodos que contribuam para o desenvolvimento deste trabalho. A seguir, alguns trabalhos relevantes no assunto são descritos brevemente.

A detecção de *outliers* ou anomalias em dados tem sido estudada na comunidade de estatísticas desde o século XIX.

Edgeworth [1887] [27] levantou a hipótese de três modelos de anomalias e ilustrou cada um usando método de Monte Carlo. Deduzindo matematicamente todos os modelos e fazendo comparativos nominais entre eles. Este trabalho é considerado seminal no sentido dos estudos sobre anomalias utilizando dados estatísticos, mas sua pesquisa se apresenta de maneira simplificada, tendo assim diversos estudos complementares efetuados posteriormente para atestar o funcionamento das hipóteses levantadas e ramificações das ideias apresentadas pelo autor.

No trabalho de Chandola et al. [2009] [28] foi elaborada uma pesquisa com diferentes maneiras pelas quais o problema da detecção de anomalias foi formulado na literatura e forneceu uma visão geral sobre várias técnicas. Para cada categoria de técnicas de detecção de anomalias, identificou uma suposição única em relação à noção de dados normais e anômalos. Uma das vantagens deste trabalho é a demonstração das várias aplicabilidades de detecção de anomalias direcionadas a muitos campos de atuação para que se possa encontrar alterações, já o fato de ser um trabalho muito amplo, não apresenta resultados detalhados e soluções específicas, tendo assim a necessidade de um estudo aprofundado, difundido em outras pesquisas posteriores, de cada campo de atuação para melhores resultados.

Jakkula and Cook [2010] [29] em suas pesquisas, apresentaram um comparativo entre a abordagem estatística e de agrupamento para detecção de anomalias no consumo de energia em uma residência em que usam dados reais e com falhas sintéticas e aplicam os dois métodos e após a comparação dos resultados têm-se o agrupamento com melhores resultados de detecção. O fato de construir algoritmo de detecção que usa técnicas estatísticas para identificar anomalias, em conjuntos de dados de energia coletados de ambientes inteligentes, significa um avanço na utilização de dados de consumo de energia elétrica para detectar alterações, porém estes dados são antigos e o objetivo da pesquisa é apenas verificar quais dos dois métodos escolhidos apresenta melhor qualidade de detecção,

enquanto que a partir destas detecções poderiam ser tomadas ações para modificar o consumo do local estudado.

No trabalho de Zhang et al. [2011] [30] foi proposto um método para identificar com precisão consumos anômalos para instalações residenciais em período de férias, assumindo a ausência do morador neste período não deveria haver consumo de energia e assim se define a curva de consumo padrão e a anômala pelo consumo dos equipamentos da residência e fazem um comparativo entre três métodos: detecção de anomalias baseado em regressão, entropia e agrupamento e os resultados são apresentados indicam o modelo que possui proporção maior de falsas detecções. Vale ressaltar que a pesquisa se limitou apenas para um período específico de acontecimento no local analisado, o que restringe a detecção de anomalias e suas possíveis soluções, mas com base nos resultados apresentados é possível adaptar o consumo de energia elétrica à utilização dos equipamentos existentes e o comparativo dos métodos de detecção utilizados indicou qual a melhor técnica a se aplicar a este caso específico.

A detecção de anomalias no consumo de energia elétrica foi proposta por Windmann et al. [2013] [31] utilizando filtro de Kalman baseado no perfil de consumo dos processos de produção de uma pequena fábrica. Primeiramente, o algoritmo aprendia o funcionamento padrão dos processos industriais e gerava uma curva de consumo de energia padrão e posteriormente associava o consumo padrão dos processos ao consumo real efetuando assim a detecção das alterações no consumo de energia. Esta pesquisa apresenta resultados consistentes acerca da detecção de anomalias para um determinado perfil de consumo aplicando filtros de Kalman, contudo a detecção se relaciona apenas ao funcionamento de determinados equipamentos, o que poderia ser expandido para todo o perfil de consumo apresentado na fábrica e assim identificar diversos tipos de anomalias, que estivessem relacionados a outros equipamentos.

O uso de redes neurais artificiais foi demonstrado por Ford et al. [2014] [32] para detecção de fraude no consumo de energia de uma residência que possui medidor inteligente, foram caracterizados dois tipos de fraudes e desenvolvido um algoritmo para simular estas fraudes associadas a uma média de consumo real, e assim feito um comparativo do consumo normal ao consumo com fraudes foi apresentada a detecção por meio de gráfico de barras. Uma das vantagens desta pesquisa se deve ao fato da utilização de inteligência artificial para detecção de anomalias no consumo de energia elétrica associadas a fraudes, no entanto a restrição em simular apenas dois tipos de fraude limita os resultados, que são apresentados em formato de gráfico de barras e não permitem uma análise detalhada das detecções, apresentando resultados quantitativos e não qualitativos.

No trabalho de Coma-Puig et al. [2016] [33] foi apresentada uma técnica supervisionada, que se utilizava de informações de medidores, para detectar anomalias nos medidores e comportamento fraudulento do cliente como a adulteração do medidor.

Detecta leituras anômalas de medidores com base em modelos construídos usando técnicas de aprendizado de máquina usando dados de histórico fazendo um comparativo com 8 tipos de algoritmos de construção de classificadores de consumo real com diferentes configurações. Este trabalho apresenta resultados relevantes de detecção de anomalias por efetuar comparações com diversas técnicas apontando a mais eficiente. A melhoria neste trabalho seria apenas no sentido de prover aplicabilidade às detecções, e influenciar diretamente na resolução das fraudes.

Um gerenciamento remoto do consumo de energia de uma escola que identifica eventos anômalos com base nos dados de um medidor foi proposto por e Hao Wang [2017] [34]. Nesse trabalho comparados cinco modelos para detectar anomalias nos dados de consumo de eletricidade da escola e utilizam um modelo híbrido que combina regressão polinomial e distribuição gaussiana e por fim desenvolvem um sistema de detecção e visualização de dados no consumo de energia da escola que representa a escala de consumo em baixa, média ou alta utilizando um mapa de calor. O diferencial deste trabalho se deve ao fato de possuir uma interface que informa ao usuário sobre a criticidade das anomalias detectadas, e como complemento a esta pesquisa, seria interessante integrar o sistema de detecção a um outro que pudesse informar e atuar mediante as alterações identificadas.

A definição de um método de detecção de anomalias foi proposto por Fenza et al. [2019] [35] que é capaz de enfrentar o conceito de desvio, por exemplo, mudanças na estrutura familiar e propõem uma metodologia que adota o método LSTM (*Long Short Term Memory*) para traçar e prever o comportamento dos consumidores baseando-se em seus consumos passados e o monitoramento contínuo dos erros de previsão de consumo permite distinguir entre possíveis anomalias como fraudes e furtos de energia elétrica e mudanças (desvios) no comportamento normal que correspondem a diferentes motivos de erro. Esta é uma pesquisa bastante recente, que utiliza conceitos relativamente novos para predição de comportamentos de consumo de energia, identificando automaticamente fraudes e anomalias em geral e as diferenciando de alterações sazonais de consumo.

Trabalhos que aplicam sistemas imunológicos artificiais na solução de problemas de detecção em sistemas computacionais iniciaram com Forrest et al. [1994] [22] que descreveram um método para detecção de mudanças distinguindo o que era próprio e não-próprio ao sistema de um computador baseado em a geração de células T no sistema imunológico. A análise matemática revelou custos computacionais do sistema e experimentos usando strings binárias aleatórias, experimentos em instruções SPARC geradas pela compilação de programas C e, no ambiente DOS experimentos em COM infectados com vírus de computador reais ilustraram sua viabilidade como um método de detecção de vírus de computador. Este trabalho é considerado de elevada importância no que tange a utilização de SIA para detectar anomalias, tendo em vista que sistemas computacionais e a relação de proteção dos mesmos ainda eram recentes a época do

desenvolvimento do trabalho, sua contribuição para identificar o que era estranho aos sistemas foi muito relevante para pesquisas posteriores.

Diferentes mecanismos imunológicos foram ilustrados por Dasgupta and Forrest [1999] [36] e sua relação com o processamento de informações. Fornecendo uma visão geral de sistemas imunológicos artificiais e as técnicas foram usadas com sucesso no reconhecimento de padrões, detecção e diagnóstico de falhas, segurança de computadores e uma variedade de outras aplicações. A relevância desse trabalho se dá pela exposição de diversas aplicações para o SIA, mas também o fato de ser um trabalho muito abrangente, faltam detalhes específicos sobre cada aplicação.

Tratando-se especificamente de pesquisas que utilizam algoritmo de seleção negativa para detecção de anomalias, no trabalho de Gonzalez et al. [2002] [37] foi apresentada uma abordagem inspirada no sistema imunológico que permitia a aplicação de algoritmos de classificação convencional como uma rede neural multicamada, treinada usando algoritmo retro propagação e um algoritmo evolutivo para gerar o classificador de regras fuzzy para realizar a detecção de anomalias.

Na pesquisa de Kim et al. [2003] [38] foi proposto um novo sistema imunológico artificial, chamado SICDF (Sistema Imunológico Computacional para Detecção de Fraude), e adota tanto a seleção negativa quanto a seleção positiva para gerar células imunes artificiais. O fato deste sistema ser capaz de detectar fraudes no comércio varejista, apontadas como fraude contra o próprio negócio e fraude contra seus clientes através de seus sistemas apresentou soluções interessantes para sanar estas anomalias.

Um algoritmo de seleção negativa foi apresentado no trabalho de Wei et al. [2004] [39] e se baseava no mecanismo de células T exibido no processo de seleção negativa. O algoritmo é composto por três procedimentos, definição dos dados próprios, geração de detectores, monitoramento de mudança de dados próprios e é adotado um o vetor no conjunto dos reais para representar o espaço do problema e está mais próximo do espaço original do problema que analisou a aplicação do algoritmo de seleção negativa na detecção de anomalias utilizando a série de dados "*Fisher iris data set*" como dados experimentais. Os dados da íris são amplamente utilizados conjunto de testes de referência na comunidade de agrupamento e aprendizado de máquina.

No trabalho de Gao et al. [2006] [40] foi proposto um algoritmo de seleção negativa baseado em otimização clonal, em que os detectores são otimizados pelo clonal para obter a melhor desempenho na detecção de anomalias. As aplicações de do algoritmo foram para a detecção de falhas no motor em que se aplica um problema de detecção de falhas de rolamentos e o desempenho na detecção de falhas de rolamentos simples, duplos e triplos são obtidas em simulações computacionais.

Um novo modelo de proteção de redes inteligentes de energia elétrica é apresentado

por A. and Ehlers [2012] [41]. Usando conceitos inspirados em sistemas imunológicos artificiais para detecção de anomalias, e este modelo visa proteger desde a conversão até o consumidor final mapeando todos os pontos do sistema energético, representados como partes do corpo humano e assim aplicando teorias do sistema imunológico artificial para proteger a rede elétrica e este controle seria feito pelo sistema SCADA.

Na pesquisa de Lima et al. [2013] [21] é proposto um sistema de detecção de anomalias baseado no sistema imunológico artificial aplicado ao Sistema de Abastecimento de Água (SAA). No funcionamento normal, o nível de pressão no SAA é controlado por um sistema de controle fuzzy. Existe a probabilidade de ocorrerem falhas nesses dispositivos causando distúrbios anormais. Um Algoritmo de Seleção Negativa (ASN), é a base do sistema de detecção de anomalias proposto. A ASN verifica condições anormais do sistema com base nas condições normais do sistema.

No trabalho de Levin et al. [2017] [42] é apresentado um sistema de detecção de anomalias em dados de saúde baseado no sistema imunológico humano. O algoritmo de seleção negativa efetua a detecção de anomalia distribuída eficaz e escalável para a prevenção de surtos de doença em larga escala. O ASN detecta anomalias nos dados grandes e complexos conjuntos de dados de monitoramento de saúde modernos com baixas taxas de falso positivo.

No trabalho de Marciniak et al. [2018] [43] são apresentados três algoritmos originais usados para auxiliar o controle do processo de combustão em uma câmara. Geração de receptores, detecção de anomalia e correção das variáveis do processo são usados para manter a água desejada temperatura na saída de uma câmara. Os algoritmos baseados no método de seleção negativa foram implementados.

A utilização de sistemas de armazenamento de energia por baterias (SAEB) para redução de picos de consumo de energia elétrica já havia despertado o interesse de pesquisadores.

Possibilidades de utilizar baterias para redução de pico pelo lado do consumidor baseado nos dados do medidor foi a pesquisa apresentada por Even et al. [1993] [44]. A eficiência econômica foi discutida em função da fórmula de tarifação e da duração do tempo do pico a ser reduzido. Foram apresentados modelos de dimensionamento da bateria e avaliação das tecnologias existentes e sua associação a elementos que controlavam os ciclos de carga e descarga.

Uma metodologia foi desenvolvida por Oudalov et al. [2007] [45] para o dimensionamento e operação estratégica ideal de um SAEB para fornecer carga durante um pico. A metodologia de dimensionamento foi usada para maximizar o benefício econômico de um cliente, reduzindo o pagamento da demanda de energia com um SAEB de capacidade mínima, ou seja, um sistema com o menor custo. A estratégia de operação ótima da SAEB

era baseada em programação dinâmica e tendia a minimizar o custo de energia enquanto satisfazia as restrições físicas da bateria.

No trabalho de Leadbetter and Swan [2012] [7] foram apresentados resultados de modelagem, simulação e dimensionamento de sistemas de armazenamento de energia de bateria para o reduzir pico de eletricidade residencial. Utilizaram perfis de eletricidade com medição de 5 minutos em um modelo de armazenamento de energia com o objetivo de reduzir a demanda de pico de eletricidade vista pela rede elétrica. O modelo foi simulado e os resultados fornecidos tratavam do desempenho de uma variedade de tamanhos de baterias e inversores específicos para uma variedade de residências. E foi estimado também o tempo de vida útil dos sistemas de armazenamento.

Uma estratégia para reduzir pico de demanda e mitigar o desequilíbrio de tensão das redes elétricas usando um SAEB foi apresentada por Chua et al. [2013] [46] com vistas para redução de custos na conta de energia e prolongar a vida útil das máquinas trifásicas. A estratégia proposta para controlar o SAEB foi desenvolvida usando o *software* de programação gráfica LabVIEW[®] e os testes realizados em uma universidade.

Na pesquisa de Uddin et al. [2018] [47] foi analisado o efeito das seguintes estratégias para redução de pico de energia elétrica: Integração de sistemas de armazenamento de energia, integração de veículos elétricos à rede, gerenciamento do lado da demanda e em cada um dos três casos, os possíveis benefícios trazidos pela redução de pico para o fornecedor e para o consumidor.

No trabalho de Vedullapalli et al. 2018 [48] foi desenvolvido um algoritmo para controlador de bateria usando modelo de controle preditivo para aplicações de redução de pico. O algoritmo usava um previsor de duas partes uma parte determinística usando média móvel exponencialmente ponderadas para tendências de longo prazo e um modelo de regressão de segunda ordem considera as variações de curto prazo. O algoritmo foi validado em um sistema de armazenamento de energia de 50 kW, 165 kWh instalado após do medidor de energia elétrica em um prédio acadêmico.

Nas buscas realizadas em artigos e revistas relativos ao tema deste trabalho, percebeu-se que a maioria dos trabalhos utilizam técnicas bastante consolidadas, a exemplo de implementações regressões polinomiais, redes neurais artificiais e diversas modelagens matemáticas para a detecção de anomalias. Além disso, foram encontradas poucas publicações sobre sistemas imunológicos artificiais aplicados na detecção de anomalias ou *outliers* no consumo de energia elétrica bem como sua associação em um sistema para redução de picos de consumo de energia elétrica utilizando sistemas de armazenamento de energia por baterias.

Na Tabela 3.1 é apresentado um resumo das principais contribuições avaliadas neste trabalho, com o intuito de sintetizar as informações exploradas neste capítulo.

Tabela 3.1 – Resumo das principais referências.


Autor(es)	Tema/Metodologia	Informações Adquiridas
Edgeworth (1887)	Detecção de <i>Outliers</i> /Método Monte Carlo	Comparativo de técnicas estatísticas para detecção de anomalias
Chandola (2009)	Detecção de Anomalias/Comparativo de técnicas matemáticas de detecção	Definição de dados normais e anômalos classificados por técnica
V. Ford, A. Siraj e W. Eberle (2014)	Detecção de Fraude no consumo de energia elétrica/Redes Neurais	Uso de dados de medidor para simulação das anomalias e uso de algoritmos para detecção da fraude
W. Cui e H.Wang (2017)	Detecção de alterações no consumo de energia/técnica matemática híbrida	Detecção e Visualização de anomalias em uma interface de mapa de calor
S. Forrest, <i>et al.</i> (1994)	Detecção de vírus em sistemas computacionais/Sistema Imunológico Artificial	Detecção de dados próprios e não-próprios de um sistema
Dasgupta, D. (1999)	Técnicas de detecção e aplicações/Sistema Imunológico Artificial	Identificação de caos de uso para aplicação de Sistema Imunológico Artificial
Yao-Guang Wei, <i>et al.</i> (2004)	Detecção de anomalias em séries temporais/ASN	Aplicação de ASN para detecção de anomalias em séries de dados consolidadas
R. P. G. Lima <i>et al.</i> (2013)	Detecção de Anomalias em sistemas de abastecimento de água/ASN	Aplicação de ASN para detecção de anomalias com interface de monitoramento
A. Even <i>et al.</i> (1993)	Redução de Picos de consumo de energia/Modelos de Dimensionamento de SAEB	Resultados da eficiência econômica associada ao uso de SAEB
A. Oudalov <i>et al.</i> (2007)	Dimensionamento e operação otimizadas de baterias/programação dinâmica para SAEB	Identificação dos principais parâmetros para baterias para atender redução de pico
K.H. Chua <i>et al.</i> (2013)	Simulações de Redução de Pico e Equilíbrio de tensão/Interface Gráfica de SAEB	Gerenciamento do SAEB por interface em Labview
D. T. Vedullapalli <i>et al.</i> (2018)	Redução de Pico e Controle das baterias/Redes Neurais e SAEB	Aplicação de algoritmo que detecta picos de consumo e controla a bateria para intervir
Este Trabalho	Detecção de Anomalias no consumo de energia elétrica, Armazenadores de energia e Interface para Detecção e Redução de Picos/ASN, SAEB	Aplicação de ASN para detectar anomalias, modelo de SAEB para suprir picos de consumo de energia com interface para monitoramento das detecções e intervenção do SAEB.

4 Metodologia

Com o intuito de contribuir para o estado-da-arte de detecção de anomalias no consumo de energia elétrica utilizando sistemas imunológicos artificiais em adição ao estado-da-arte da utilização de sistemas de armazenamento de energia para redução de picos, propõe-se um sistema composto por um Algoritmo de Seleção Negativa (ASN) associado a um sistema de armazenamento de energia por baterias (SAEB) para a redução de picos de consumo de energia elétrica.

A metodologia proposta se dá pela coleta de dados de potência ativa em função do tempo de um medidor instalado em um prédio da UFCG denominado Bloco CJ (coordenadas geográficas 7,212135,Sul;35,908530,Oeste) que envia dados a cada minuto. Os dados da potência ativa são utilizados para análise neste trabalho, devido ao seu impacto na fatura de energia, bem como a conversão direta da potência ativa em capacidade da bateria, além de que os outros dados fornecidos pelo medidor como potência reativa e fator de potência são mais facilmente corrigidos com a instalação de um banco de capacitores, por exemplo. Na Figura 4.1 é mostrada a medição da potência ativa pelo medidor e a interface Grafana na qual os dados são exibidos.

Figura 4.1 – Potência ativa fornecida pelo medidor instalado no Bloco CJ na UFCG.

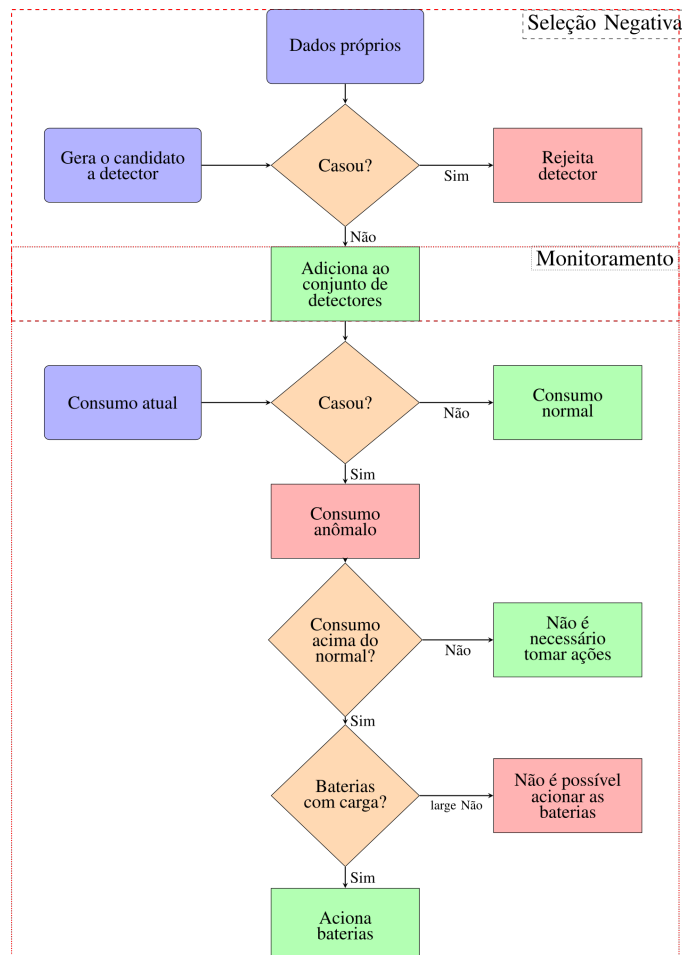


Fonte: Elaborada pela autora

O pré-processamento dos dados é realizado para a geração de curva padrão de consumo para cada dia da semana, e foram utilizados no ASN juntamente com curvas de consumo diários e fizeram parte dos processos de geração de detectores e monitoramento do

algoritmo. O algoritmo ASN foi implantando em linguagem Python e após o processo de detecção aplicado a vários tipos de anomalias para validação da técnica, a detecção dos picos de consumo foi escolhida como anomalia a ser mitigada pelo sistema de armazenamento de energia por baterias (SAEB). O SAEB foi adotado considerando a bateria chumbo-ácido devido ao alto grau de maturidade tecnológica, alta eficiência e menor custo inicial de armazenamento de todas as baterias existentes no mercado [49]. O SAEB foi implementado em MATLAB[®]/Simulink para fornecer carga baseado na corrente demandada pelas curvas de potência consumo real e apresenta o comportamento do estado de carga da bateria (SOC) perante a carga demandada. A interface entre o algoritmo de seleção negativa que detecta as anomalias e o SAEB é o MATLAB[®] App Designer que é um ambiente para criar aplicativos com interfaces gráficas de usuário no MATLAB[®]. Na Figura 4.2 é apresentado o fluxograma do sistema proposto.

Figura 4.2 – Fluxograma do sistema proposto.



Fonte: Elaborada pela autora

Com esta metodologia, melhor descrita nas próximas subseções, espera-se obter um sistema que associe a detecção de anomalias ao uso de SAEB para redução de picos de consumo de energia elétrica.

4.1 Geração de curva de carga padrão de consumo de energia elétrica


A curva de carga padrão de consumo de energia elétrica tem por objetivo determinar perfil de consumo de energia elétrica e permite uma análise detalhada para o melhor enquadramento tarifário do consumidor, bem como visualizar uma possível aplicação de ações de eficiência energética, por meio do gerenciamento da demanda, colaborando assim para a redução de tarifas e consumo.

Existem diversas maneiras de modelar uma curva de carga padrão, o modelo utilizado neste trabalho baseou-se fundamentalmente em [50].

Os dados da curva de consumo padrão de consumo utilizados neste trabalho possuem uma relação unívoca entre o eixo horizontal (correspondente ao tempo) e ao eixo vertical (correspondente à potencia ativa em kW) e são de cinco semanas referentes ao período de 01 à 31 de Julho de 2018 e foram processados previamente utilizando um algoritmo em Python que agrupa as medições a cada 15 minutos, tendo em vista que o medidor instalado faz a medição a cada 1 minuto e que convencionalmente utiliza-se o período de 15 minutos para se gerar uma curva de carga [51]. E o uso de dados a cada 1 minuto demandaria grande esforço computacional.

Após o agrupamento é feito o cálculo da média, mediana e desvio padrão das semanas selecionadas resultando em uma curva de carga média para cada dia da semana. A curva média será utilizada no trabalho. Na figura 4.3 é apresentado um modelo de curva de carga semelhante a que será utilizada no trabalho.

Figura 4.3 – Exemplo de curva de carga padrão.



Fonte: Adaptada de [52]

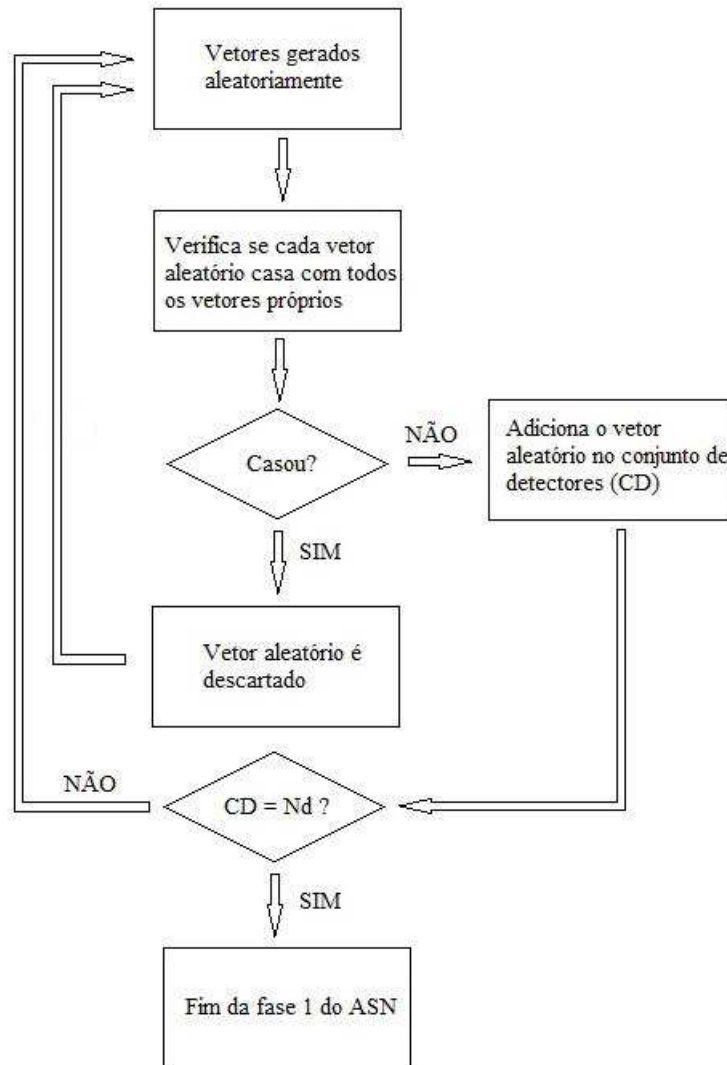
As curvas de carga real utilizadas foram referentes ao período de 09 a 15 de Setembro de 2018. Foram pré-processadas a fim de convertê-las em medições a cada 15 minutos, para posterior correlação á curva de carga padrão no algoritmo de seleção negativa e para uso na interface.

4.2 Aplicação do algoritmo de seleção negativa para a detecção de anomalias no consumo de energia elétrica

A elaboração algoritmo de seleção negativa baseado na proposta de [22] em que consideraram os seguintes passos:

- **Definição dos conjuntos de dados próprios:** considerando a geração de curvas de carga padrão para cada dia da semana que resultou assim em 7 curvas, cada uma com amostras de 96 pontos (medição a cada 15 minutos) de valores de potência em kW. Estas curvas formarão o conjunto de dados próprios. Utilizando a técnica de janelamento (divisão uniforme da característica analisada em intervalos regulares), a curva de carga padrão foi dividida em $n = 48$ *self-vectors* (vetores-próprios) e cada vetor possui um comprimento $l = 2$ (escolhido para facilitar a geração dos detectores, pois à medida que aumenta o valor de l há maior dificuldade computacional em formar cada vetor próprio), isto é, a cada 2 valores consecutivos de potência forma-se um vetor-próprio;
- **Fase de geração dos detectores:** foram gerados 150 detectores. A quantidade de detectores foi fixa em todas as simulações para o critério r-Hamming bem como o parâmetro de casamento r . Entretanto, o desvio (ϵ) e o número de partes em que a curva foi dividida N_Slice foram ajustados, em cada caso, para obter os valores de maiores percentuais de cobertura de falhas, que correspondem aos valores ótimos. Estes valores serão as entradas do ASN. Os parâmetros ótimos foram alcançados de forma empírica, mediante vários testes, até serem determinados os valores em que ocorreram as maiores porcentagens de detecção de anormalidades dentre todos os parâmetros testados. Cada vetor, gerado de maneira aleatória, é testado com todos os vetores próprios a fim de verificar se houve casamento. Isto é realizado até que a quantidade de vetores contidos no conjunto de detectores CD seja igual quantidade de detectores (Nd) previamente escolhidos. Este procedimento é baseado no fluxograma mostrado na Figura 4.4.

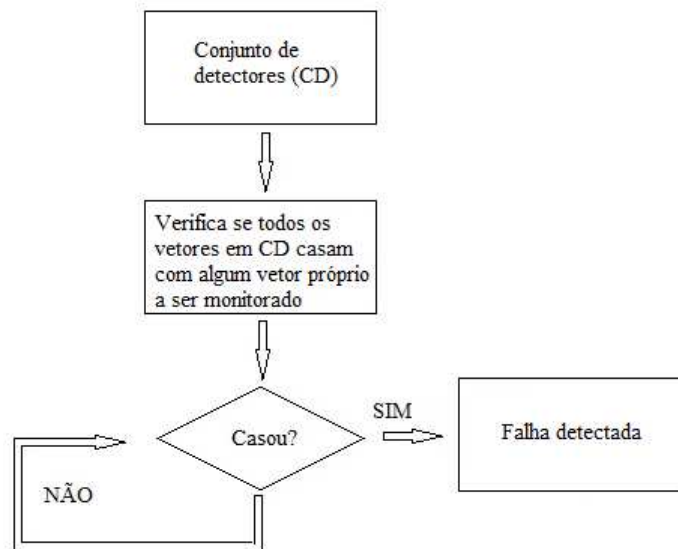
Figura 4.4 – Fase de geração de detectores para o ASN implementado



Fonte: Adaptada de [21]

- Fase de Monitoramento:** considerando a curva de carga real para cada dia da semana, essa característica foi monitorada utilizando os detectores previamente gerados na fase anterior. Todos os detectores gerados verificam, continuamente, se existe alguma modificação em cada vetor a ser monitorado e que possa estar passível de erros. Este procedimento é baseado no fluxograma mostrado na Figura 4.5

Figura 4.5 – Fase de monitoramento para o algoritmo implementado



Fonte: Adaptada de [21]

E com o objetivo de verificar a eficiência do ASN, foram realizadas algumas simulações utilizando o critério **r-Hamming** por se obter melhores resultados conforme o trabalho de [21] em situações distintas: detecção de falso positivo, detecção de anomalias em caso de espelhamento de curva, detecção de anomalias durante a madrugada, detecção de diversas anomalias em uma curva, detecção de anomalias em uma curva real visando picos de consumo. Para estas simulações serão mostrados os parâmetros utilizados como entrada do ASN e sua porcentagem de cobertura de falhas.

4.3 Modelo do Sistema de Armazenamento de Energia por Bateria

O modelo de armazenamento de energia por baterias foi adaptado para se obter as curvas referentes ao estado de carga da bateria conforme os parâmetros especificados pelos fabricantes. O modelo é baseado no trabalho de [53] com adaptações referentes ao tipo de bateria utilizada e aos elementos associados a carga e descarga da bateria.

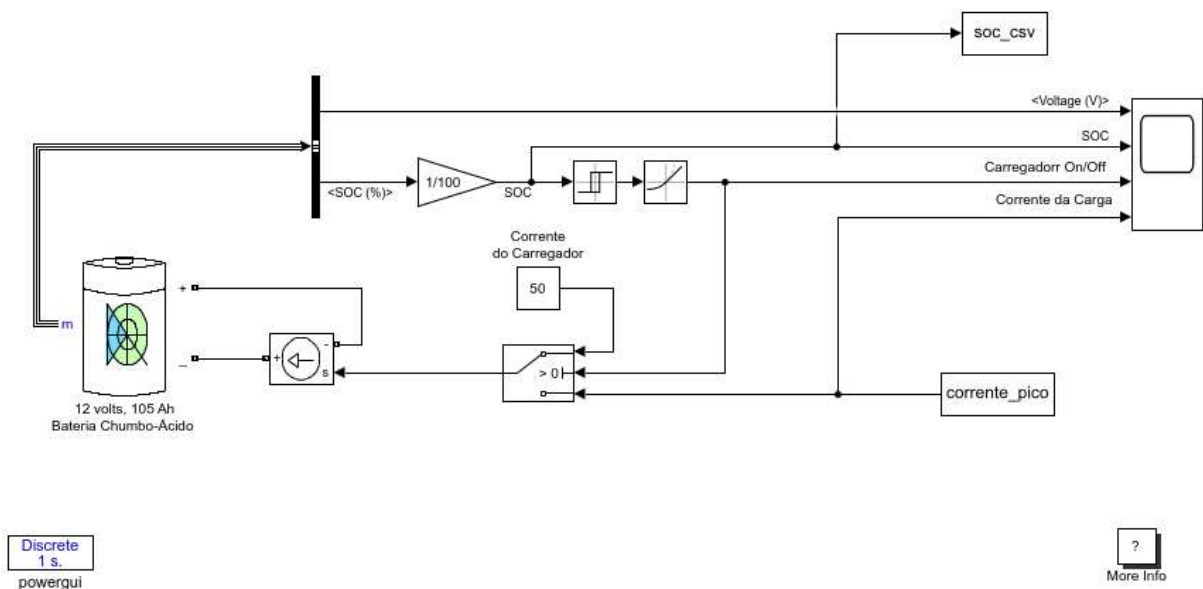
O sistema de armazenamento de energia por bateria foi implementado em MATLAB® e Simulink®, e fornece o comportamento do estado de carga da bateria (SOC) mediante a demanda para cada perfil de corrente selecionado. O sistema é composto por:

- **Corrente de pico:** é o parâmetro de entrada que são os perfis de consumo real da corrente extraídos da potência ativa medida durante a detecção de anomalias de picos de consumo para cada dia da semana, considerando a tensão constante em 220 V utilizando a Eq. 2.1. Este perfil é calculado utilizando um algoritmo em MATLAB®.

- Bateria Chumbo-Ácido:** é o elemento responsável por fornecer energia ao perfil de corrente requerido conforme especificações parametrizáveis tais como tensão nominal, capacidade da bateria (Ah), estado de carga inicial(%). Estes parâmetros são selecionados de acordo com o manual do produto ou para a simulação de uma bateria ideal. O estado inicial de carga da SOC foi estimado em 80% e o estado final da SOC para que ela pare de fornecer carga foi de 40%. Estes valores são convencionalmente aplicados pois minimizam os ciclos profundos de carga/descarga e assim prolongam a vida útil da bateria [54].
- Carregador para a bateria:** elemento que fornece carga para a bateria quando a SOC está no limite inferior permitido e é fixado em 5A.
- Chave seletora:** é um comutador com duas entradas, uma saída e um controle. A entrada de controle está conectada a SOC. Quando o SOC atingir 80% a bateria está carregada e apta a ser usada. O comutador conecta a bateria ao perfil de corrente selecionado. Quando o SOC atingir 40%, o comutador desconecta a bateria da carga e a conecta ao carregador efetivamente carregando a bateria para o próximo ciclo.
- Osciloscópio:** é o dispositivo que exibe o a tensão da bateria, o estado de carga o perfil de corrente e o estado do carregador. O estado de carga também é armazenado em formato .csv para utilização na interface que será posteriormente descrita.

Na Figura 4.6 é apresentado o modelo utilizado.

Figura 4.6 – Modelo para o sistema de armazenamento



Fonte: Elaborada pela autora


4.4 Sistema supervisorio de detecção de anomalias e utilização de baterias para redução de picos de consumo de energia elétrica

Com o objetivo de associar a detecção de anomalias no consumo de energia elétrica utilizando ASN à utilização de um sistema de armazenamento de energia por baterias para redução de picos de consumo, foi utilizada uma interface que permite acompanhar a curva de consumo real do prédio CJ e a curva do estado de carga da bateria indicando sua utilização e atuação perante as anomalias detectadas. A interface de programação utilizada para este objetivo foi implementada no MATLAB® App Designer.

O MATLAB® App Designer é um ambiente usado para construir aplicativos no MATLAB®. Ele simplifica o processo de leiaute dos componentes visuais de uma interface de usuário. Ele inclui um conjunto de componentes de interface de usuário padrão, bem como um conjunto de medidores, botões, interruptores e lâmpadas. O MATLAB® App Designer integra as duas principais tarefas de criação de aplicativos: o leiaute dos componentes visuais e o comportamento do aplicativo de programação.

A interface para monitoramento das curvas de consumo de energia elétrica e do estado de carga da bateria para atuação durante os picos de consumo é mostrada na Figura 4.7

Figura 4.7 – Interface para monitoramento das curvas de consumo e carga



Fonte: Elaborada pela autora

A seguir é mostrada uma descrição geral da estrutura que constitui a interface implementada no MATLAB® App Designer. Seus principais componentes são:

- A. **Botões de seleção dos dias da semana:** são botões mediante os quais são carregados os dados referentes ao dia da semana selecionado, como a curva padrão e a curva real de consumo de energia elétrica e os detectores. Estes dados estão no formato .csv foram processados no início do trabalho e durante a fase de detecção de anomalias do ASN e carregados na interface de programação do MATLAB[®] App designer. Quando um dia for selecionado o conjunto de dados referente a ele indicará a ocorrência das anomalias referentes a picos de consumo para possível intervenção da bateria.
- B. **Botões de intervenção do sistema:** os botões são responsáveis por iniciar o processo de monitoramento do consumo e detecção de anomalias, pausar quando da necessidade de avaliar a intervenção ou paralisar o processo.
- C. **Janela de visualização do consumo:** consiste na janela que mostrará o comportamento da curva de carga real, a curva de carga padrão e as curvas com e sem a intervenção do SAEB.
- D. **Janela de visualização da SOC:** consiste na janela que mostrará o estado inicial de carga da bateria bem como suas alterações mediante a carga demandada pelo consumo real após a detecção dos picos de consumo de energia elétrica.
- E. **LEDs indicadores de consumo e SOC:** são indicadores luminosos que serão acionados para indicar anomalia no consumo de energia ou para indicar os estados intermediários de carga do SAEB.
- F. **Botão seletor de capacidade das baterias:** consiste no botão em que é possível selecionar a capacidade do SAEB, em 105 Ah ou 220 Ah.

Neste capítulo foi apresentada a metodologia utilizada na pesquisa. Os resultados deste trabalho de dissertação são apresentados e analisados no capítulo seguinte.


5 Resultados

As análises dos resultados são apresentadas e discutidas a seguir de forma sequencial. De início, elabora-se as curvas de carga padrão de consumo de energia elétrica com base nos dados obtidos do medidor. Logo em seguida, são apresentados os resultados referentes à aplicação do Algoritmo de Seleção Negativa para detecção de anomalias no consumo de energia elétrica. Posteriormente, tem-se os resultados referentes ao modelo do sistema de armazenamento por baterias perante a demanda dos picos de consumo de energia elétrica para dois modelos de baterias comerciais. Em seguida, são discutidos os resultados obtidos da interface de detecção de anomalias associado ao SAEB referente à avaliação das especificações e considerações sobre a vida útil das baterias para atender as anomalias detectadas.

5.1 Curva de carga padrão


Conforme a literatura, para que se possa aplicar a detecção de anomalias utilizando ASN é necessário um conjunto de dados padrão. No caso aplicado ao consumo de energia elétrica, o conjunto de dados padrão é referente a média de cinco semanas no período de 01 a 31 de julho de 2018 da medição da potência ativa do Bloco CJ que fica localizado na UFCG, e é um ambiente com diversas salas que são utilizadas para as mais variadas atividades como aulas, laboratórios de pesquisa, sala de professores. Nas Figuras 5.1 e 5.2 são mostrados os valores da média, mediana e desvio padrão para um dia do fim de semana e para um dia útil, as curvas de carga padrão para os demais dias da semana são apresentados no Apêndice A1.

Figura 5.1 – Modelagem da curva de consumo padrão para o Domingo



Fonte: Elaborada pela autora

Figura 5.2 – Modelagem da curva de consumo padrão para a Segunda-Feira



Fonte: Elaborada pela autora

A partir das Figuras 5.1 e 5.2 é possível observar o comportamento no consumo de energia elétrica e os intervalos de tempo em que há maior consumo, sendo estes os horários de 8 h da manhã até as 17 h com queda no consumo durante o intervalo entre 12 h e 14 h em média, este consumo se deve a presença de alunos e professores na instituição. E nos finais de semana é possível identificar que o consumo durante a noite e madrugada é diferente do consumo durante o dia, por conta da iluminação externa que é ligada às 17 h e desligada às 05 h da manhã. O comportamento no consumo é parecido na maioria dos dias úteis, mas com características como média, duração e variância específicas para cada dia. Os principais equipamentos instalados no Bloco CJ são ar-condicionados, computadores, lâmpadas. A existência ou não de um comportamento parecido nos mesmos dias da semana está associado principalmente ao uso de ar-condicionado nos horários e dias em que há funcionamento no prédio com a presença de alunos e professores nas salas e laboratórios. Os resultados do desvio padrão para cada dia da semana fornecem resultados que permitem concluir que esta medida de dispersão representa o desvio de cada um dos valores de potência ativa medidos em relação à média e sendo estes valores muito próximos de 0 a média dos valores é bastante uniforme. Deve-se salientar que as curvas de carga padrão

sofrem influencias relacionadas ao período de funcionamento da instituição, e sazonalidade sendo assim interessante que seja recalculada periodicamente para uma melhor modelagem da curva de carga padrão para posterior aplicação no algoritmo de detecção.


5.2 Detecção de anomalias aplicando ASN

Com o objetivo de verificar a eficiência do ASN, foram realizadas as simulações descritas a seguir: detecção de falso positivo, detecção de anomalias em caso de espelhamento de curva, detecção de anomalias durante a madrugada, detecção de diversas anomalias em uma curva, detecção de anomalias em uma curva real visando picos de consumo.

Todas utilizaram o critério **r-Hamming** e os parâmetros de entrada do ASN são apresentados para cada tipo de simulação, exceto para falsos positivos que não apresentaram variações mesmo com muitas variações nos parâmetros. A porcentagem de cobertura de falha (CF) é apresentada junto aos parâmetros e indica, neste caso, a quantidade de falhas detectadas pelo ASN, correspondentes aos detectores ativados atuantes em resposta a estas falhas. Neste caso, as falhas são comportamentos que se diferem da curva de carga padrão a cada medição de 15 minutos.


1. **Detecção de falsos positivos:** o ASN não deve detectar situações em que a curva de carga padrão seja considerada como curva de carga real. Segundo a teoria, o algoritmo não deve detectar elementos próprios do sistema. Para esta simulação a curva de carga padrão (dados próprios) de cada dia da semana foi inserida como curva de carga real (dados não-próprios). O resultado dessa simulação para um dia do fim de semana e para um dia da semana é mostrado nas Figuras 5.3 e 5.4, o resultado para os demais dias são mostrados no Apêndice B1. Para quaisquer valores dos parâmetros de entrada tais como o desvio e parâmetro de casamento, não houve a atuação de nenhum detector. As curvas de carga padrão e a real estão sobrepostas representando assim a mesma curva para a entrada dos dados não-próprios e a para os dados próprios. Os detectores em vermelho permanecem no eixo horizontal concluindo assim que nenhum detector ativado nestas simulações, isto é, o ASN não detectou como anormalidade a curva considerada padrão de carga, o resultado esperado para a simulação e assim a eficiência do ASN neste caso foi de 100%.

Figura 5.3 – Detecção de Falsos Positivos no Domingo



Fonte: Elaborada pela autora


Figura 5.4 – Detecção de Falsos Positivos na Segunda-Feira



Fonte: Elaborada pela autora


2. **Deteccção de anomalias em caso de espelhamento da curva:** o ASN deverá detectar as anomalias em uma curva padrão espelhada, que embora possua os mesmos valores da curva padrão, os dados iniciais da curva espelhada, são os dados finais da curva de carga padrão e a simulação é para verificar a resposta do algoritmo a esta curva. Para que esta deteção pudesse acontecer foi inserido um novo parâmetro no algoritmo para que essa deteção pudesse ser efetuada. Este parâmetro chamado N_Slice é responsável por dividir a curva em partes, este é um parâmetro de entrada do algoritmo para que os detectores sejam gerados a cada parte da curva e não seja assumido que o espelhamento ou uma curva muito parecida com a curva de carga padrão seja associada aos dados próprios do sistema. Nas Figuras 5.5 e 5.6 são apresentados os resultados de deteção de anomalias para o espelhamento da curva padrão em um dia útil e em um dia de fim de semana. Os resultados para os demais dias da semana são mostrados no Apêndice B2. Os parâmetros de desvio (ϵ), casamento (r), comprimento do vetor (l), número de detectores (Nd), número de divisões da curva (N_slice) e cobertura de falha (CF%) serão apresentados na Tabela 5.1 e são considerados parâmetros ótimos (obtidos após vários testes).

Figura 5.5 – Deteccção para espelhamento de curva no Domingo



Fonte: Elaborada pela autora

Figura 5.6 – Detecção para espelhamento de curva na Segunda-Feira




Fonte: Elaborada pela autora

Tabela 5.1 – Parâmetros de entrada do ASN e Cobertura de Falha para espelhamento

Parâmetro	r	Desvio (ϵ)	(l)	Nd	N_Slice	CF(%)
Domingo	1	1,8	2	150	8	100%
Segunda-Feira	1	2,1	2	150	8	91,6%
Terça-Feira	1	1,8	2	150	12	79,16%
Quarta-feira	1	1,8	2	150	8	85,41%
Quinta-feira	1	1,8	2	150	12	86,45%
Sexta-feira	1	1,8	2	150	12	78,12%
Sábado	1	1,8	2	150	8	77,08%


3. **Detecção de anomalias durante a madrugada:** O ASN deverá detectar apenas anomalias inseridas na curva de carga padrão referentes a picos de consumo ou redução de consumo no período das 22 h às 05 h, não devendo detectar os intervalos considerados como próprios do consumo de energia. Estas anomalias simulam o uso de equipamentos, iluminação ou ar condicionados em horários incomuns, ou curto-circuito na rede do prédio. Nas Figuras 5.7 e 5.8 são apresentados os resultados de detecção de anomalias durante a madrugada para um dia útil e um dia do fim de semana, os resultados referentes aos demais dias da semana são mostrados no Apêndice B3. Os parâmetros de desvio (ϵ), casamento (r), comprimento do vetor (l), número de detectores (Nd), número de divisões da curva (N_Slice) e cobertura de falha (CF%) serão apresentados na Tabela 5.2 e são considerados parâmetros ótimos (obtidos após vários testes).

Figura 5.7 – Detecção durante a madrugada do Domingo



Fonte: Elaborada pela autora

Figura 5.8 – Detecção durante a madrugada da Segunda-Feira




Fonte: Elaborada pela autora

Tabela 5.2 – Parâmetros de entrada do ASN e Cobertura de Falha para anomalias durante a madrugada

Parâmetro	r	Desvio (ϵ)	(l)	Nd	N_Slice	CF(%)
Domingo	1	1,8	2	150	6	100%
Segunda-Feira	1	2,1	2	150	6	100%
Terça-Feira	1	1,8	2	150	6	100%
Quarta-feira	1	1,8	2	150	6	100%
Quinta-feira	1	1,8	2	150	6	100%
Sexta-feira	1	1,8	2	150	6	100%
Sábado	1	1,8	2	150	6	100%

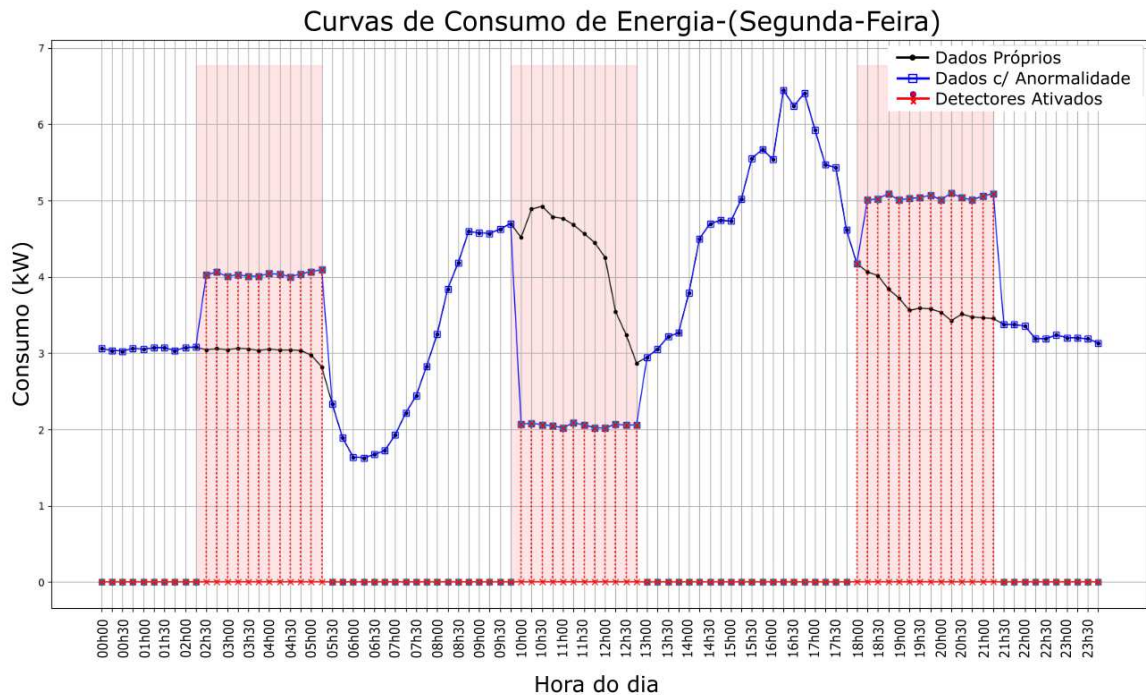
4. **Detecção de diversas anomalias em uma curva:** O ASN deverá detectar apenas os intervalos que contêm anomalias inseridas na curva de carga padrão, não devendo detectar os intervalos considerados próprios do consumo padrão de energia. Dessa forma, foram inseridas anomalias de picos e vales na curva de carga padrão afim de que apenas estes intervalos fossem detectados pelo ASN. Estas anomalias são baseadas nos comportamentos mais comuns de consumo de energia elétrica e no contexto da universidade são consumos incomuns relacionados ao horário em que foram inseridos. Nas Figuras 5.9 e 5.10 são apresentados os resultados de detecção de diversas anomalias, para um dia útil e para um dia do fim de semana. Os resultados para os demais dias da semana são mostrados no Apêndice B4. Os parâmetros de desvio (ϵ), casamento (r), comprimento do vetor (l), número de detectores (Nd), número de divisões da curva (N_Slice) e cobertura de falha (CF%) serão apresentados na Tabela 5.3 e são considerados parâmetros ótimos (obtidos após vários testes).

Figura 5.9 – Detecção de diversas anomalias em um Domingo



Fonte: Elaborada pela autora

Figura 5.10 – Detecção de diversas anomalias em uma Segunda-Feira



Fonte: Elaborada pela autora

Tabela 5.3 – Parâmetros de entrada do ASN e Cobertura de Falha para detecção de diversas anomalias


Parâmetro	r	Desvio (ϵ)	(l)	Nd	N_Slice	CF(%)
Domingo	1	1,8	2	150	6	100%
Segunda-Feira	1	2,1	2	150	6	100%
Terça-Feira	1	1,8	2	150	6	100%
Quarta-feira	1	1,8	2	150	6	100%
Quinta-feira	1	1,8	2	150	6	100%
Sexta-feira	1	1,8	2	150	6	100%
Sábado	1	1,8	2	150	6	100%

5. Detecção de anomalias em uma curva real de consumo-Detecção de Picos:

Nesta simulação foram utilizadas curvas de cargas reais referentes ao período de 09 a 15 de setembro de 2018 e o ASN deveria detectar os consumos que divergissem da curva de carga padrão no tocante a picos de consumo. Para tanto o parâmetro de desvio foi ajustado até de obtivessem detecções apenas para os picos, já que os testes para detecção de vales já haviam sido validados e o objetivo do trabalho é a redução nos picos de consumo utilizando SAEB. Assim sendo, valores da curva de carga real que estejam em um limiar próximo dos valores da curva padrão não serão detectados, bem como os vales. Devido a geração aleatória dos detectores poderão ocorrer falhas na detecção em pontos de pico isolados. Os parâmetros de desvio


(ϵ), casamento (r), comprimento do vetor (l), número de detectores (Nd), número de divisões da curva (N_Slice) e cobertura de falha (CF%) serão apresentados na Tabela 5.4 e são considerados parâmetros ótimos (obtidos após vários testes). A cobertura de falha foi considerada apenas para os pontos que representam picos de consumo ou consumo superior a curva padrão. Pontos da curva que sejam muito semelhantes a curva padrão não serão considerados devido ao valor do desvio não conseguir detectar alterações muito pequenas na curva. Nas Figuras 5.11 e 5.12 são apresentados os resultados de detecção de picos de consumo em uma curva real, para um dia útil e para um dia do fim de semana. Os resultados referentes aos demais dias da semana, são apresentados no Apêndice B5.

Figura 5.11 – Detecção de picos em uma curva de consumo real de Domingo



Fonte: Elaborada pela autora

Figura 5.12 – Detecção de picos em uma curva de consumo real de Segunda-Feira



Fonte: Elaborada pela autora


Tabela 5.4 – Parâmetros de entrada do ASN e Cobertura de Falha para detecção de picos de consumo em uma curva real

Parâmetro	r	Desvio (ϵ)	(l)	Nd	N_Slice	CF(%)
Domingo	1	2,5	2	150	12	82,22%
Segunda-Feira	1	4,5	2	150	8	91,17%
Terça-Feira	1	4,0	2	150	12	81,81%
Quarta-feira	1	6,0	2	150	8	82,85%
Quinta-feira	1	5,0	2	150	8	75,86%
Sexta-feira	1	5,7	2	150	8	90,90%
Sábado	1	2,5	2	150	12	95,83%

5.3 Simulação do modelo do sistema de armazenamento

Um modelo de SAEB foi implementado para definir a capacidade das baterias a serem utilizadas para a redução de picos de consumo de energia, baseando-se nas anomalias detectadas pelo ASN. Foram escolhidas duas especificações comerciais de baterias com capacidade de 105 Ah e 220 Ah em um sistema composto por 10 baterias ligadas em série, e a partir da simulação verificado o comportamento do SOC para as correntes de pico em cada dia da semana. O SOC foi o parâmetro definido para ser monitorado pois permite avaliar a vida útil conforme sua profundidade de descarga e a necessidade de ciclos para suprir os picos detectados. Estas baterias possuem vida útil de 4 anos a 1 ciclo/dia para uma profundidade de descarga de 20% conforme mostrado na Figura 5.13:

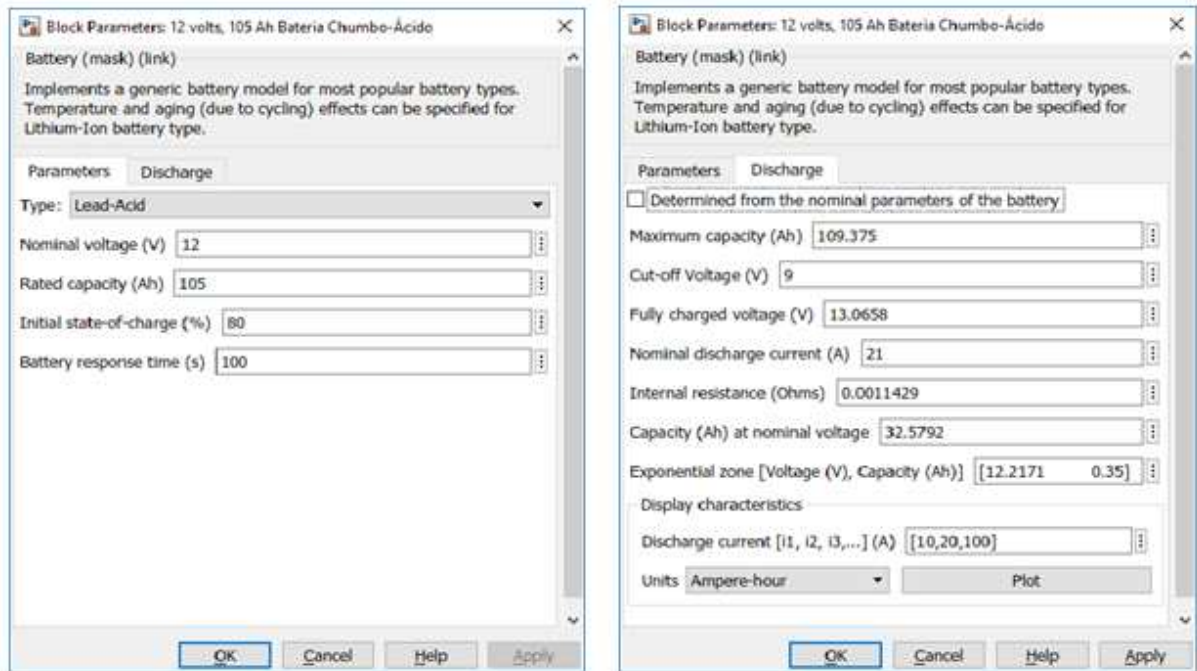
Figura 5.13 – Ciclo de Vida de uma bateria estacionária Freedom[©]



Fonte: [26]

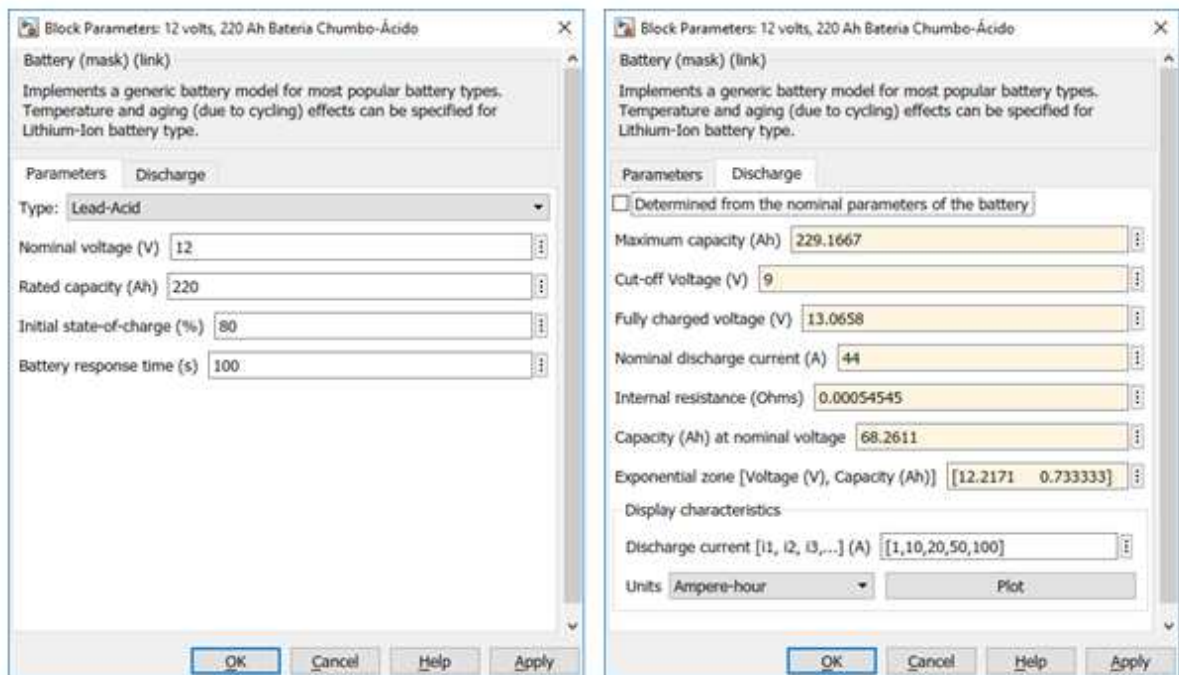
A profundidade de descarga máxima definida para as simulações foi de 40%. O estado inicial da carga foi estimado em 80% no início de cada simulação, considerando as baterias carregadas. Os controladores impedem que o estado de carga varie para limites superiores a 80% e inferiores a 40%, o que significa dizer que a bateria não sofrerá carga e descarga profunda aumentando assim sua vida útil. Os parâmetros para cada bateria são apresentados nas Figuras 5.14 e 5.15.

Figura 5.14 – Parâmetros da bateria chumbo-ácido de 105 Ah



Fonte: Elaborada pela autora

Figura 5.15 – Parâmetros da bateria chumbo-ácido de 220 Ah




Fonte: Elaborada pela autora

5.3.1 Sistema de Armazenamento por Baterias de 105 Ah

O SAEB com capacidade de 105 Ah supriram os picos de carga apenas com sua energia armazenada sem necessidade de efetuar mais de um ciclo de carga no fim de semana tendo uma profundidade de descarga de 35% e 15% para o sábado e domingo, respectivamente. Para os dias úteis (segunda à sexta) haveria necessidade de realizar um novo ciclo de carga para suprir os picos detectados pois a carga da bateria é consumida até a SOC_{min} . Na Figura 5.16 são apresentados os estados de carga das baterias de 105 Ah quanto ao suprimento dos picos de demanda a cada dia da semana.

Figura 5.16 – Estado de carga do SAEB de 105 Ah para picos em todos os dias da semana




Fonte: Elaborado pela autora

5.3.2 Sistema de Armazenamento por Baterias de 220 Ah

O SAEB com capacidade de 220 Ah supriram os picos de carga apenas com sua energia armazenada sem necessidade de efetuar mais de um ciclo de carga para todos os dias da semana, assim sendo, não haveria necessidade de realizar um novo ciclo de carga para suprir os picos detectados. Pois para os fins de semana a profundidade de descarga de 12% e 8%, para o sábado e domingo, respectivamente. Nos dias da semana a profundidade de descarga é por volta de 20% a 35% da carga armazenada. Na Figura 5.17 são apresentados os estados de carga das baterias de 220 Ah quanto ao suprimento dos picos de demanda a cada dia da semana.

Figura 5.17 – Estado de carga do SAEB de 220 Ah para picos em todos os dias da semana



Fonte: Elaborado pela autora

5.4 Interface para detecção de anomalias e utilização de SAEB para redução de picos


Para verificar a atuação do ASN para detecção de anomalias no consumo de energia elétrica juntamente com a utilização de baterias para redução de picos de consumo foram realizadas simulações para o comportamento das baterias de 105 Ah e 220 Ah para cada dia da semana. Desta forma os testes visam identificar a eficiência da detecção de anomalias e a indicação da intervenção das baterias para mitigar os picos bem como o comportamento de sua capacidade perante os o aumento na demanda do prédio e avaliação da quantidade ciclos necessários e o reflexo em sua vida útil. Nas Figuras 5.18 e 5.21 são mostrados os resultados da associação de detecção de anomalias pelo ASN e intervenção das baterias de 105 Ah e 220 Ah para cada dia da semana.

5.4.1 Início da Simulação

No início da simulação é possível monitorar o comportamento do consumo real perante a curva de carga padrão, bem como o estado inicial de carga da bateria para possíveis intervenções. As simulações para os demais dias da semana são mostradas no Apêndice C1.

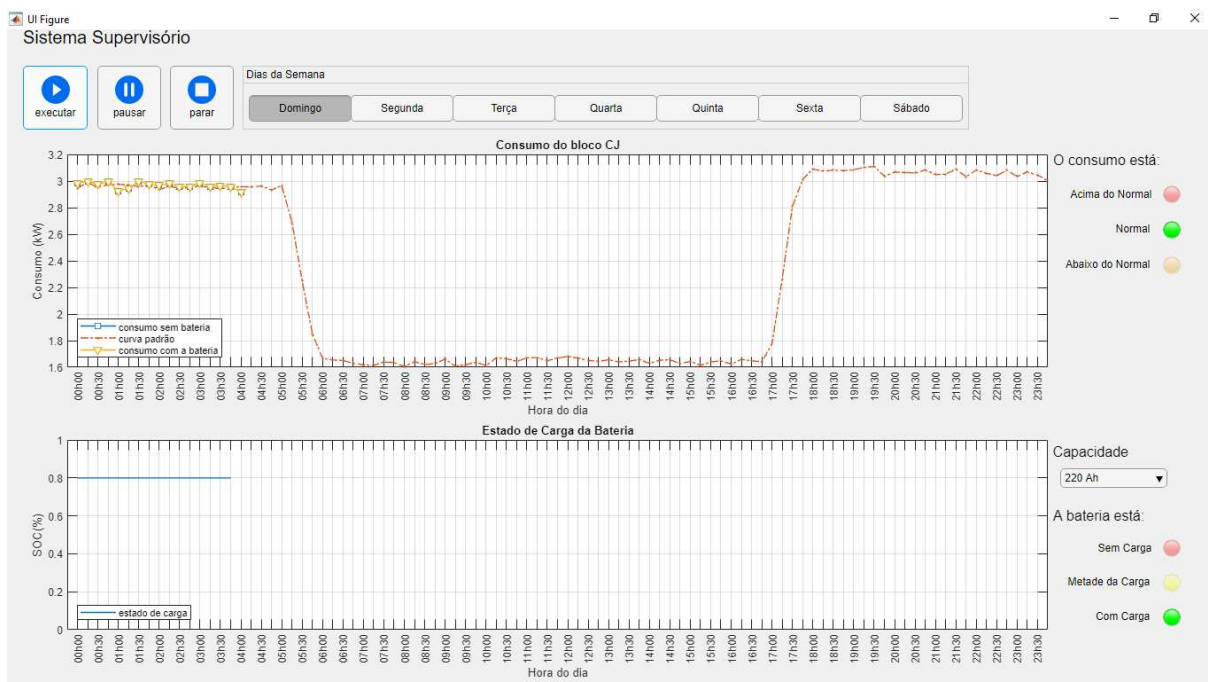
a) Domingo

Figura 5.18 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora


Figura 5.19 – Interface utilizando SAEB de 220 Ah



Fonte: Elaborado pela autora

b) Segunda-feira

Figura 5.20 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura 5.21 – Interface utilizando SAEB de 220 Ah




Fonte: Elaborado pela autora

5.4.2 Detecção de picos consumo de energia e intervenção do SAEB

A partir do ponto em que o ASN detecta uma anomalia no consumo, a bateria inicia o processo de fornecer energia para eliminar a anomalia e assim permanece até que o ASN não mais indique divergência entre o consumo real e o padrão ou quando a SAEB não possua mais carga disponível. O SAEB de 220 Ah é capaz de fornecer carga para as anomalias detectadas em todos os dias da semana, enquanto que o SAEB de 105 Ah não consegue fornecer energia necessária para reduzir os picos de consumo nos dias úteis (segunda á sexta), sendo necessário mais de um ciclo de carga do SAEB para atender os picos de demanda e com isto influenciar diretamente no tempo de vida útil das baterias. As baterias escolhidas possuem vida útil de 4 anos com 1 ciclo/dia. O fato de utilizar o SAEB de 105 Ah realizando mais de um ciclo de carga por dia, poderá reduzir sua vida útil. Os resultados para os demais dias da semana são mostrados no Apêndice C2.


a) Domingo

Figura 5.22 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura 5.23 – Interface utilizando SAEB de 220 Ah



Fonte: Elaborado pela autora

b) Segunda-feira

Figura 5.24 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura 5.25 – Interface utilizando SAEB de 220 Ah



Fonte: Elaborado pela autora

5.4.3 Detecção de outras anomalias e estado final de carga do SAEB

O ASN também é capaz de detectar consumo abaixo da curva de carga padrão, porém as baterias não atuam para estas anomalias devido o foco ser apenas nas reduções de pico. Um exemplo de detecção de consumos inferiores ao padrão é mostrado na Figura 5.26.

Figura 5.26 – Detecção de outras anomalias com SAEB de 105 Ah



Fonte: Elaborado pela autora

No horário de 17 h até as 17h 30 min é possível observar uma redução no consumo real comparado a curva de carga padrão, a lâmpada do consumo informa “consumo abaixo do normal”, porém a lâmpada que informa sobre a carga do SAEB de baterias 105 Ah informa “bateria sem carga” pois o mesmo está liberado para fornecer energia apenas para picos de consumo. O estado final de carga dos SAEBs de 105 Ah e 220 Ah, para um dia útil e um dia do fim de semana serão mostrados nas Figuras 5.27 e 5.30 e na Tabela 5.5 é apresentado um comparativo entre as duas baterias quanto a sua capacidade, custo, quantidades de ciclos por dia para suprir os picos de demanda e vida útil. Os resultados para os demais dias da semana são mostrados no Apêndice C3.

a) Domingo

Figura 5.27 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura 5.28 – Interface utilizando SAEB de 220 Ah



Fonte: Elaborado pela autora

b) Segunda-feira

Figura 5.29 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura 5.30 – Interface utilizando SAEB de 220 Ah



Fonte: Elaborado pela autora

Tabela 5.5 – Comparativo de SAEB

Comparativo de Baterias Chumbo-Ácido		
Capacidade (Ah)	105	220
Custo de Implantação	R\$ 5.700,00	R\$ 9.500,00
Ciclos/Dia para aplicação	2	1
Vida Útil	≤ 2 anos	≥ 4 anos

Diante dos resultados apresentados pela Tabela 5.5 é possível afirmar que o investimento em um sistema de armazenamento de energia por bateria de 220 Ah possui maior custo-benefício, devido a seu tempo de vida útil ser mais elevado diante de sua maior capacidade de prover energia para as anomalias detectadas. O uso de um sistema de armazenamento de energia por bateria de 105 Ah é passível para esta aplicação, mediante estudos para o controle de intervenção para picos, definindo a intervenção apenas em períodos que representem maiores custos para o consumidor, tais como os horários de ponta determinados pela concessionária para que a utilização do SAEB de 105 Ah possa representar redução efetiva de custos.

6 Conclusão

Neste trabalho, foi implementado um sistema com a aplicação de algoritmo de seleção negativa para detecção de anomalias no consumo de energia elétrica, associada à utilização de um sistema de armazenamento de energia por baterias. As curvas de carga referentes consumo de energia elétrica foram obtidas de um medidor eletrônico instalado em no Bloco CJ na UFCG, o ASN foi desenvolvido para detecção de anomalias no consumo de energia elétrica, tendo como base curvas de carga padrão resultantes de uma média de consumo obtidas de medições anteriores retiradas do banco de dados que armazena as informações do medidor, e o SAEB dimensionado e utilizado para reduzir os picos de consumo detectados como anomalias pelo ASN.

Com a obtenção das curvas de carga padrão do Bloco CJ foi possível caracterizar o perfil de consumo do prédio, e iniciar o desenvolvimento do ASN para detecção de anomalias no consumo de energia elétrica. De acordo com a revisão bibliográfica realizada, compreendeu-se a importância da detecção de anomalias no consumo de energia elétrica, a aplicação de técnicas de detecção pelo ASN, a utilização de SAEB para mitigar picos de consumo de energia para redução de consumo de energia da concessionária e custos com energia elétrica.

A definição da capacidade das baterias foi possível a partir da simulação de um modelo de baterias, que apresentava o estado de carga de dois tipos de baterias frente aos picos de consumo anômalos detectado pelo ASN, verificou-se ser possível a utilização de baterias para redução de pico, e o comportamento do estado de carga perante a demanda exigida é que define seu ciclo de carga/descarga. Finalmente, foi observado a eficiência da detecção de anomalias por ASN, associada a um sistema de armazenamento de energia por baterias para a redução de picos de consumo. O ASN foi capaz de detectar consumos inferiores e superiores á curva de carga padrão, para cada dia da semana e o SAEB forneceu energia apresentando comportamentos diferentes de acordo com a capacidade das baterias, o que refletirá diretamente em sua vida útil pois a necessidade de mais ciclos de carga/descarga reduzem o tempo de vida das baterias.

Portanto, o presente trabalho avaliou e comprovou como eficaz, a aplicabilidade da detecção de anomalias no consumo de energia elétrica associada ao uso de baterias para a redução de picos de consumo de energia elétrica. Conclui-se que, com a aplicação de ASN para detecção de anomalias, o modelo de SAEB pode colaborar no planejamento de ações de eficiência energética, redução de consumo advindo da concessionária e possíveis reduções de custos com energia.

Adicionalmente, foi possível observar que o desenvolvimento da técnica de detecção de anomalias e utilização de baterias se apresentam como uma solução viável de imple-

mentação real. Para tanto, uma interface de detecção de anomalias por ASN, associada ao monitoramento e atuação do SAEB na redução de picos de consumo de energia elétrica foi estabelecida e avaliada, mediante simulações para cada dia da semana e para cada uma das duas capacidades definidas para as baterias.

6.1 Trabalhos Futuros

A detecção de anomalias no consumo de energia elétrica por ASN associada a utilização de SAEB foi estabelecida como viável para redução de picos de consumo de energia elétrica. Um sistema de detecção de anomalias com armazenamento de energia por baterias pode intervir em diversas falhas no consumo de energia advindo da concessionária e com um tempo de resposta bastante reduzido. Neste sentido, trabalhos futuros podem ser desenvolvidos, sendo estes elencados a seguir:

- Desenvolvimento de algoritmo para estimação automática de curvas de carga padrão, por critérios estatísticos baseadas na sazonalidade, calendário acadêmico, e histórico de consumo;
- Avaliação do ASN para otimização na escolha dos parâmetros e implementação de rotina automática para os testes de detecção de anomalias em pontos isolados;
- Implementação de detecção de anomalias em tempo real, considerando os dados do medidor para as três fases separadamente, com catalogação dos equipamentos instalados em cada fase para incorporar ao algoritmo o alarme de equipamentos ou iluminação que tornem o consumo anômalo;
- Dimensionamento e gerenciamento ótimos para o sistema de armazenamento de energia por baterias, visando sua intervenção em função do custo-benefício com estudo prévio de tarifas para o prédio;
- Desenvolvimento de interface para detecção de anomalias, baseada na predição de consumo e gerenciamento de SAEB em tempo real com alarmes de anomalia e estado da bateria.

6.2 Publicações

Durante o desenvolvimento do trabalho, a autora publicou artigos em congressos nacionais e internacionais. Além disso, até a data marcada para a defesa desta dissertação de mestrado, um artigo se encontra apenas com submissão/aceite. São estes listados a seguir:

Artigos Publicados:

- Guarany, I. S.; Freire, R. C. S.; Silva, A.; Gurjão, E.C.. *Detecção de outliers no consumo de energia elétrica.. XXVI Simpósio Brasileiro de Telecomunicações e Processamento de Sinais - SBrT*, Campina Grande, 2018, p.p 433-437.
- G. A. Pereira, B. A. Luciano, G. C. Agra, B. A. de Souza e I. S. Guarany, *Some considerations about development research and development projects on energy efficiency in the Brazilian electrical systems*, 2018 Simposio Brasileiro de Sistemas Eletricos (SBSE), Niteroi, 2018, pp. 1-6. doi: 10.1109/SBSE.2018.8395931;
- G. C. Agra, R. C. Silvério Freire, I. S. Guarany e E. C. Gurjão, *Proposal of supervision and control of alternative sources transfer*, 2018 Simpósio Brasileiro de Sistemas Elétricos (SBSE), Niteroi, 2018, pp. 1-5. doi: 10.1109/SBSE.2018.8395544;
- Morais, S.M.A.; Guarany,I.S; Freire R.C.S; Serres, A.J.R.; Silva Júnior, P.F.; Silva, P.H.DA F.. *Aperture-Coupled Koch Fractal on-Chip Antennas for 60 GHz ISM Band.*, In: IEEE Latin American Microwave Conference (LAMC), 2018, Arequipa, Peru.

Artigos aceitos/submetidos para publicação

- Silva, A. ; Guarany, I. S. ; Freire, R. C. S. ; Gurjão, E.C. . *Method for Anomaly Prediction in Power Consumption using Long Short-Term Memory and Negative Selection.*, In: IEEE International Symposium on Circuits and Systems (ISCAS), 2019, Sapporo, Hokkaido, Japão.

REFERÊNCIAS

- [1] Y. F. Li, G. H. Chang, C. J. Zhang, and S. H. Liang. Modified real-value negative selection algorithm and its application on fault diagnosis. In *2011 IEEE 2nd International Conference on Software Engineering and Service Science*, pages 216–219, July 2011. Citado na página 17.
- [2] Jorge Luís Machado do Amaral. *Sistemas Imunológicos Artificiais Aplicados à Detecção de Falhas*. PhD thesis, Tese de doutorado, Pontifícia Universidade Católica do Rio de Janeiro, Rio . . . , 2006. Citado 7 vezes nas páginas 17, 27, 28, 29, 30, 32 e 36.
- [3] Marcello Mezaroba. Sistemas de armazenamento de energia. *Apresentação do Núcleo de Processamento de Energia Elétrica. Universidade do Estado de Santa Catarina, Joinville*, 2012. Citado na página 18.
- [4] Ana Catarina Vaia Assis. Sistema de armazenamento de energia como solução reparadora de perturbações na qualidade de energia elétrica. 2014. Citado na página 18.
- [5] Douglas K. Maly and Khang-Shen Kwan. Optimal battery energy storage system (bess) charge scheduling with dynamic programming. *IEE Proceedings-Science, Measurement and Technology*, 142(6):453–458, 1995. Citado na página 18.
- [6] Zechun Hu, Shu Zhang, Fang Zhang, and Haiyan Lu. Scuc with battery energy storage system for peak-load shaving and reserve support. In *Power and Energy Society General Meeting (PES), 2013 IEEE*, pages 1–5. IEEE, 2013. Citado na página 18.
- [7] Jason Leadbetter and Lukas Swan. Battery storage system for residential electricity peak demand shaving. *Energy and buildings*, 55:685–692, 2012. Citado 2 vezes nas páginas 19 e 51.
- [8] Lukas Sigrüst, Enrique Lobato, and Luis Rouco. Energy storage systems providing primary reserve and peak shaving in small isolated power systems: An economic assessment. *International Journal of Electrical Power & Energy Systems*, 53:675–683, 2013. Citado na página 19.
- [9] Soyoung Park and Wan-Ki Park. Ces peak demand shaving with energy storage system. In *Information and Communication Technology Convergence (ICTC), 2017 International Conference on*, pages 1124–1126. IEEE, 2017. Citado na página 19.

- [10] Bwo-Ren Ke, Te-Tien Ku, Yu-Lung Ke, Chen-Yuan Chuang, and Hong-Zhang Chen. Sizing the battery energy storage system on a university campus with prediction of load and photovoltaic generation. *IEEE Transactions on Industry Applications*, 52(2):1136–1147, 2016. Citado na página 19.
- [11] Rama K. Bonthu, Ha Pham, Ricardo P. Aguilera, and Quang P. Ha. Minimization of building energy cost by optimally managing pv and battery energy storage systems. In *Electrical Machines and Systems (ICEMS), 2017 20th International Conference on*, pages 1–6. IEEE, 2017. Citado na página 19.
- [12] Luís Henrique Pinto Santiago. Resolução normativa nº 414/2010: Aspectos e mudanças sobre a regulamentação do fornecimento de energia elétrica. 2011. Citado na página 21.
- [13] Carolina Teixeira Nicolau, Reinaldo C. Souza, and Maurício N. Frota. *Medição de energia elétrica: impactos da mudança tecnológica no setor jurídico de uma concessionária distribuidora de energia elétrica*. PhD thesis, Dissertação de Mestrado-Departamento Pós-MQI, Pontifícia Universidade . . . , 2013. Citado 2 vezes nas páginas 21 e 25.
- [14] Pedro Guilherme Costa Ferreira. *Prof. Dr. João Carlos de Oliveira Aires*. PhD thesis, PUC-Rio, 2013. Citado na página 21.
- [15] Guilherme Zen Moritz. Projeto de um analisador autônomo de requisitos de qualidade de energia baseado em software. 2018. Citado na página 24.
- [16] Ademaro Alberto Machado Bittencourt Cotrim. *Instalações elétricas*. McGraw-Hill do Brasil, 2003. Citado na página 26.
- [17] Cleonilson P. Souza. Uma arquitetura autotestável para circuitos digitais baseada no algoritmo de berlekamp-massey e em sistemas imunológicos artificiais. *Tese de Doutorado, UFCG*, 2005. Citado 4 vezes nas páginas 27, 36, 37 e 38.
- [18] Qi Jin and Ma Ming. A method to construct self set for ids based on negative selection algorithm. In *Mechatronic Science, Electric Engineering and Computer (MEC), 2011 International Conference on*, pages 1051–1053. IEEE, 2011. Citado na página 27.
- [19] Leandro Nunes de Castro. Engenharia imunológica: desenvolvimento e aplicação de ferramentas computacionais inspiradas em sistemas imunológicos artificiais. *Universidade Estadual de Campinas, Campinas-SP*, 2001. Citado 5 vezes nas páginas 28, 30, 31, 32 e 33.
- [20] Ismaila Idris and Ali Selamat. Negative selection algorithm in artificial immune system for spam detection. In *Software Engineering (MySEC), 2011 5th Malaysian Conference in*, pages 379–382. IEEE, 2011. Citado na página 29.

- [21] Robson Pacífico Guimarães Lima, Bruno Willian de Souza Arruda, and de Cleonilson P. Souza. Experimental platform for faults detection in fuzzy controllers based on artificial immune systems. In *Instrumentation and Measurement Technology Conference (I2MTC), 2013 IEEE International*, pages 593–596. IEEE, 2013. Citado 4 vezes nas páginas 33, 50, 57 e 58.
- [22] Stephanie Forrest, Alan S. Perelson, Lawrence Allen, and Rajesh Cherukuri. Self-nonsel self discrimination in a computer. In *Research in Security and Privacy, 1994. Proceedings., 1994 IEEE Computer Society Symposium on*, pages 202–212. Ieee, 1994. Citado 4 vezes nas páginas 33, 38, 48 e 56.
- [23] Jian hua Guo and Hai dong Yang. A negative selection algorithm integrated with immune network theory. In *Natural Computation (ICNC), 2012 Eighth International Conference on*, pages 859–863. IEEE, 2012. Citado na página 35.
- [24] Fabio Gonzalez, Dipankar Dasgupta, and Luis Fernando Niño. A randomized real-valued negative selection algorithm. In *International Conference on Artificial Immune Systems*, pages 261–272. Springer, 2003. Citado na página 36.
- [25] Elisabeth Lemaire-Potteau, Florence Mattera, Arnaud Delaille, and Philippe Malbranche. Assessment of storage ageing in different types of pv systems: technical and economical aspects. In *23rd European Photovoltaic Solar Energy Conference (Valencia, Spain, 2008)*, pages 2765–2769, 2008. Citado 3 vezes nas páginas 42, 43 e 44.
- [26] Johnson Controls. Manual técnico bateria estacionária freedom®. *Sorocaba, Manual Tecnico Julho*, 25, 2008. Citado 2 vezes nas páginas 45 e 75.
- [27] Francis Y. Edgeworth. On observations relating to several quantities. *Hermathena*, 6 (13):279–285, 1887. Citado na página 46.
- [28] Varun Chandola, Arindam Banerjee, and Vipin Kumar. Anomaly detection: A survey. *ACM computing surveys (CSUR)*, 41(3):15, 2009. Citado na página 46.
- [29] Vikramaditya Jakkula and Diane Cook. Outlier detection in smart environment structured power datasets. In *Intelligent Environments (IE), 2010 Sixth International Conference on*, pages 29–33. IEEE, 2010. Citado na página 46.
- [30] Yi Zhang, W. Chen, and J. Black. Anomaly detection in premise energy consumption data. In *2011 IEEE Power and Energy Society General Meeting*, pages 1–8, July 2011. doi: 10.1109/PES.2011.6039858. Citado na página 47.
- [31] Stefan Windmann, Shuo Jiao, Oliver Niggemann, and Holger Borchering. A stochastic method for the detection of anomalous energy consumption in hybrid industrial

- systems. In *Industrial Informatics (INDIN), 2013 11th IEEE International Conference on*, pages 194–199. IEEE, 2013. Citado na página 47.
- [32] Vitaly Ford, Ambareen Siraj, and William Eberle. Smart grid energy fraud detection using artificial neural networks. In *Computational Intelligence Applications in Smart Grid (CIASG), 2014 IEEE Symposium on*, pages 1–6. IEEE, 2014. Citado na página 47.
- [33] Bernat Coma-Puig, Josep Carmona, Ricard Gavalda, Santiago Alcoverro, and Victor Martin. Fraud detection in energy consumption: a supervised approach. In *Data Science and Advanced Analytics (DSAA), 2016 IEEE International Conference on*, pages 120–129. IEEE, 2016. Citado na página 47.
- [34] Wenqiang Cui e Hao Wang. Anomaly detection and visualization of school electricity consumption data. In *Big Data Analysis (ICBDA), 2017 IEEE 2nd International Conference on*, pages 606–611. IEEE, 2017. Citado na página 48.
- [35] Giuseppe Fenza, Mariacristina Gallo, and Vincenzo Loia. Drift-aware methodology for anomaly detection in smart grid. *IEEE Access*, 2019. Citado na página 48.
- [36] Dipankar Dasgupta and Stephanie Forrest. Artificial immune systems in industrial applications. In *Intelligent Processing and Manufacturing of Materials, 1999. IPMM'99. Proceedings of the Second International Conference on*, volume 1, pages 257–267. IEEE, 1999. Citado na página 49.
- [37] Fabio Gonzalez, Dipankar Dasgupta, and Robert Kozma. Combining negative selection and classification techniques for anomaly detection. In *Evolutionary Computation, 2002. CEC'02. Proceedings of the 2002 Congress on*, volume 1, pages 705–710. IEEE, 2002. Citado na página 49.
- [38] Jungwon Kim, Arlene Ong, and Richard E. Overill. Design of an artificial immune system as a novel anomaly detector for combating financial fraud in the retail sector. In *Evolutionary Computation, 2003. CEC'03. The 2003 Congress on*, volume 1, pages 405–412. IEEE, 2003. Citado na página 49.
- [39] Yao-Guang Wei, De-Ling Zheng, and Ying Wang. Research of a negative selection algorithm and its application in anomaly detection. In *Machine Learning and Cybernetics, 2004. Proceedings of 2004 International Conference on*, volume 5, pages 2910–2913. IEEE, 2004. Citado na página 49.
- [40] Xiao Zhi Gao, Seppo J. Ovaska, Xiaolei Wang, and M-Y. Chow. Clonal optimization of negative selection algorithm with applications in motor fault detection. In *Systems, Man and Cybernetics, 2006. SMC'06. IEEE International Conference on*, volume 6, pages 5118–5123. IEEE, 2006. Citado na página 49.

- [41] Sheu Mavee M. A. and Elizabeth M. Ehlers. A multi-agent immunologically-inspired model for critical information infrastructure protection—an immunologically-inspired conceptual model for security on the power grid. In *Trust, Security and Privacy in Computing and Communications (TrustCom), 2012 IEEE 11th International Conference on*, pages 1089–1096. IEEE, 2012. Citado na página 50.
- [42] Drew Levin, Melanie Moses, Tatiana Flanagan, Stephanie Forrest, and Patrick Finley. Negative selection based anomaly detector for multimodal health data. In *Computational Intelligence (SSCI), 2017 IEEE Symposium Series on*, pages 1–7. IEEE, 2017. Citado na página 50.
- [43] Jacek Marciniak, Krzysztof Wawryn, and Patryk Widulinski. An artificial immune negative selection algorithm to control water temperature in the outlet of the chamber. In *2018 International Conference on Signals and Electronic Systems (ICSES)*, pages 236–241. IEEE, 2018. Citado na página 50.
- [44] Andr Even, Jan Neyens, and A. Demousselle. Peak shaving with batteries. In *Electricity Distribution, 1993. CIRED. 12th International Conference on*, volume 5, pages 5–17. IET, 1993. Citado na página 50.
- [45] Alexandre Oudalov, Rachid Cherkaoui, and Antoine Beguin. Sizing and optimal operation of battery energy storage system for peak shaving application. In *Power Tech, 2007 IEEE Lausanne*, pages 621–625. IEEE, 2007. Citado na página 50.
- [46] Kein Huat Chua, Yun Seng Lim, and Stella Morris. Battery energy storage system for peak shaving and voltage unbalance mitigation. *International Journal of Smart Grid and Clean Energy*, 2(3):357–363, 2013. Citado na página 51.
- [47] Moslem Uddin, Mohd Fakhizan Romlie, Mohd Faris Abdullah, Syahirah Abd Halim, and Tan Chia Kwang. A review on peak load shaving strategies. *Renewable and Sustainable Energy Reviews*, 82:3323–3332, 2018. Citado na página 51.
- [48] D. T. Vedullapalli, R. Hadidi, B. Schroeder, and R. Baumgartner. Adaptive scheduling of the battery for peak shaving using model predictive control. In *2018 IEEE Electronic Power Grid (eGrid)*, pages 1–5. IEEE, 2018. Citado na página 51.
- [49] Alexdandre Oudalov, Daniel Chartouni, Christian Ohler, and G. Linhofer. Value analysis of battery energy storage applications in power systems. In *Power Systems Conference and Exposition, 2006. PSCE'06. 2006 IEEE PES*, pages 2206–2211. IEEE, 2006. Citado na página 54.
- [50] A. Andersson, A. Jansson, and J. Klevas. Model for load simulations by means of load pattern curves. In *Electricity Distribution, 1989. CIRED 1989. 10th International Conference on*, pages 545–549. IET, 1989. Citado na página 55.


- [51] André Nunes de Souza, Pedro da Costa Junior, Renato de Oliveira, Maria Goretti Zago, João Paulo Papa, and Danilo Sinkiti Gastaldello. Algoritmos para estimar curvas de cargas a partir de padrões de hábitos de consumo. 2010. Citado na página 55.
- [52] Aislan Antonio Francisquini. Estimação de curvas de carga em pontos de consumo e em transformadores de distribuição. 2006. Citado na página 55.
- [53] Olivier Tremblay and Louis-A Dessaint. Experimental validation of a battery dynamic model for ev applications. *World Electric Vehicle Journal*, 3(2):289–298, 2009. Citado na página 58.
- [54] Khoa Le Dinh and Yasuhiro Hayashi. Coordinated bess control for improving voltage stability of a pv-supplied microgrid. In *Power Engineering Conference (UPEC), 2013 48th International Universities'*, pages 1–6. IEEE, 2013. Citado na página 59.

APÊNDICES

APÊNDICE A – Curvas de carga padrão


Curvas de carga padrão para os demais dias da semana com valores de média, mediana, e desvio padrão.

Figura A.1 – Modelagem da curva de consumo padrão para o Terça-Feira




Fonte: Elaborada pela autora

Figura A.2 – Modelagem da curva de consumo padrão para a Quarta-Feira



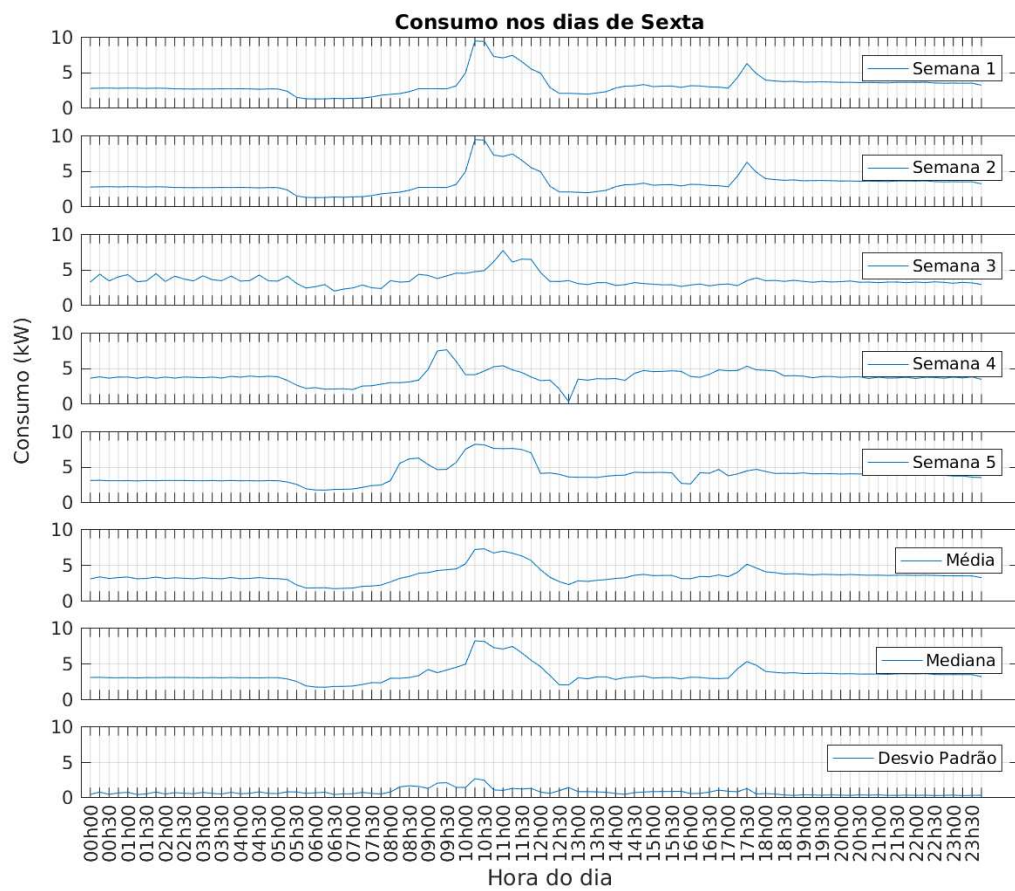
Fonte: Elaborada pela autora

Figura A.3 – Modelagem da curva de consumo padrão para a Quinta-Feira




Fonte: Elaborada pela autora

Figura A.4 – Modelagem da curva de consumo padrão para a Sexta-Feira



Fonte: Elaborada pela autora

Figura A.5 – Modelagem da curva de consumo padrão para o Sábado




Fonte: Elaborada pela autora

APÊNDICE B – Detecção com ASN

B.1 Falsos Positivos


Resultados para a detecção de falsos positivos nos demais dias da semana.

Figura B.1 – Detecção de Falsos Positivos na Terça-Feira




Fonte: Elaborada pela autora

Figura B.2 – Detecção de Falsos Positivos na Quarta-Feira




Fonte: Elaborada pela autora

Figura B.3 – Detecção de Falsos Positivos na Quinta-Feira



Fonte: Elaborada pela autora


Figura B.4 – Detecção de Falsos Positivos na Sexta-Feira



Fonte: Elaborada pela autora

Figura B.5 – Detecção de Falsos Positivos no Sábado

[Detecção de Falsos Positivos no Sábado]




Fonte: Elaborada pela autora

B.2 Espelhamento


Resultados para a detecção de anomalias no caso de espelhamento da curva de carga nos demais dias da semana.

Figura B.6 – Detecção para espelhamento de curva na Terça-Feira




Fonte: Elaborada pela autora

Figura B.7 – Detecção para espelhamento de curva na Quarta-Feira




Fonte: Elaborada pela autora

Figura B.8 – Detecção para espelhamento de curva na Quinta-Feira




Fonte: Elaborada pela autora

Figura B.9 – Detecção para espelhamento de curva na Sexta-Feira



Fonte: Elaborada pela autora

Figura B.10 – Detecção para espelhamento de curva no Sábado




Fonte: Elaborada pela autora

B.3 Madrugada


Resultados para a detecção de anomalias durante a madrugada nos demais dias da semana.

Figura B.11 – Detecção durante a madrugada da Terça-Feira




Fonte: Elaborada pela autora

Figura B.12 – Detecção durante a madrugada da Quarta-Feira




Fonte: Elaborada pela autora

Figura B.13 – Detecção durante a madrugada da Quinta-Feira




Fonte: Elaborada pela autora

Figura B.14 – Detecção durante a madrugada da Sexta-Feira



Fonte: Elaborada pela autora

Figura B.15 – Detecção durante a madrugada do Sábado




Fonte: Elaborada pela autora

B.4 Diversas Anomalias


Resultados para a detecção de diversas anomalias nos demais dias da semana.

Figura B.16 – Detecção de diversas anomalias em uma Terça-Feira




Fonte: Elaborada pela autora

Figura B.17 – Detecção de diversas anomalias em uma Quarta-Feira




Fonte: Elaborada pela autora

Figura B.18 – Detecção de diversas anomalias em uma Quinta-Feira




Fonte: Elaborada pela autora

Figura B.19 – Detecção de diversas anomalias em uma Sexta-Feira



Fonte: Elaborada pela autora

Figura B.20 – Detecção de diversas anomalias em um Sábado




Fonte: Elaborada pela autora

B.5 Detecção de Picos


Resultados para a detecção de picos de consumo em uma curva de carga real nos demais dias da semana.

Figura B.21 – Detecção de picos em uma curva de consumo real de Terça-Feira




Fonte: Elaborada pela autora

Figura B.22 – Detecção de picos em uma curva de consumo real de Quarta-Feira




Fonte: Elaborada pela autora

Figura B.23 – Detecção de picos em uma curva de consumo real de Quinta-Feira




Fonte: Elaborada pela autora

Figura B.24 – Detecção de picos em uma curva de consumo real de Sexta-Feira



Fonte: Elaborada pela autora

Figura B.25 – Detecção de picos em uma curva de consumo real de Sábado



Fonte: Elaborada pela autora

APÊNDICE C – Interface

C.1 Início

Resultados do início do monitoramento na interface para os demais dias da semana.


a) Terça-feira

Figura C.1 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura C.2 – Interface utilizando SAEB de 220 Ah




Fonte: Elaborado pela autora

APÊNDICE C. INTERFACE


b) Quarta-feira

Figura C.3 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura C.4 – Interface utilizando SAEB de 220 Ah




Fonte: Elaborado pela autora

APÊNDICE C. INTERFACE

c) Quinta-feira

Figura C.5 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura C.6 – Interface utilizando SAEB de 220 Ah




Fonte: Elaborado pela autora

APÊNDICE C. INTERFACE


d) Sexta-feira

Figura C.7 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura C.8 – Interface utilizando SAEB de 220 Ah




Fonte: Elaborado pela autora

APÊNDICE C. INTERFACE


e) Sábado

Figura C.9 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura C.10 – Interface utilizando SAEB de 220 Ah



Fonte: Elaborado pela autora

C.2 Detecção e Intervenção

Resultados do sistema associando a detecção de picos de consumo de energia elétrica e intervenção do SAEB para os demais dias da semana.

a) Terça-feira

Figura C.11 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura C.12 – Interface utilizando SAEB de 220 Ah



Fonte: Elaborado pela autora

APÊNDICE C. INTERFACE

b) Quarta-feira

Figura C.13 – Interface utilizando SAEB de 105 Ah




Figura C.14 – Interface utilizando SAEB de 220 Ah



APÊNDICE C. INTERFACE

c) Quinta-feira

Figura C.15 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura C.16 – Interface utilizando SAEB de 220 Ah



Fonte: Elaborado pela autora

APÊNDICE C. INTERFACE

d) Sexta-feira

Figura C.17 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura C.18 – Interface utilizando SAEB de 220 Ah



Fonte: Elaborado pela autora

e) Sábado

Figura C.19 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura C.20 – Interface utilizando SAEB de 220 Ah




Fonte: Elaborado pela autora

C.3 Estado final de carga do SAEB

Resultados do fim do monitoramento da curva de carga e estado final de carga do SAEB para os demais dias da semana.

a) Terça-feira

Figura C.21 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura C.22 – Interface utilizando SAEB de 220 Ah



Fonte: Elaborado pela autora

APÊNDICE C. INTERFACE


b) Quarta-feira

Figura C.23 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura C.24 – Interface utilizando SAEB de 220 Ah



Fonte: Elaborado pela autora

APÊNDICE C. INTERFACE

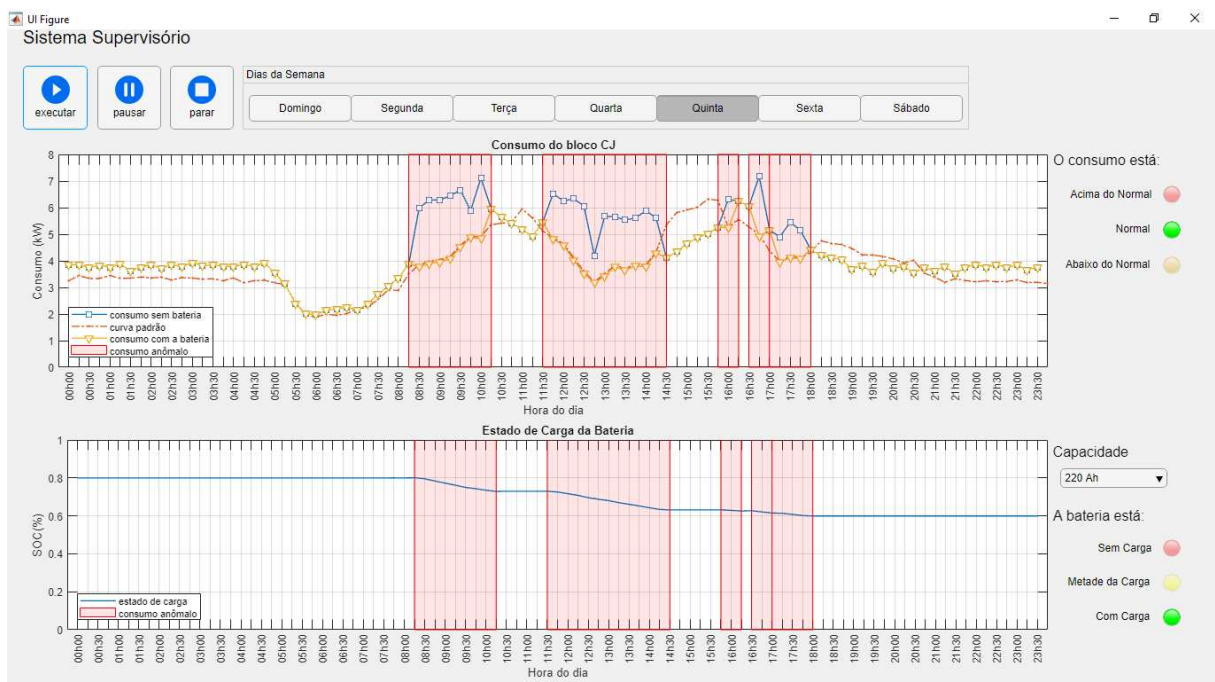
c) Quinta-feira

Figura C.25 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura C.26 – Interface utilizando SAEB de 220 Ah



Fonte: Elaborado pela autora

APÊNDICE C. INTERFACE

d) Sexta-feira

Figura C.27 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura C.28 – Interface utilizando SAEB de 220 Ah



Fonte: Elaborado pela autora

e) Sábado

Figura C.29 – Interface utilizando SAEB de 105 Ah



Fonte: Elaborado pela autora

Figura C.30 – Interface utilizando SAEB de 220 Ah



Fonte: Elaborado pela autora

