

UNIVERSIDADE FEDERAL DE ITAJUBÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO

Identificação Não Intrusiva de Cargas por  
Floresta Aleatória com Otimização Fogos de  
Artifício

**Paulo Ricardo Zambelli Taveira**

Itajubá, 16 de Dezembro de 2019

**UNIVERSIDADE FEDERAL DE ITAJUBÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO**

**Paulo Ricardo Zambelli Taveira**

**Identificação Não Intrusiva de Cargas por  
Floresta Aleatória com Otimização Fogos de  
Artifício**

Dissertação submetida ao Programa de Pós-Graduação em Ciência e Tecnologia da Computação como parte dos requisitos para obtenção do Título de Mestre em Ciências em Ciência e Tecnologia da Computação.

**Área de Concentração: Matemática da Computação**

**Orientador: Dr Carlos Henrique Valério Moraes**

**16 de Dezembro de 2019  
Itajubá**

UNIVERSIDADE FEDERAL DE ITAJUBÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO

Identificação Não Intrusiva de Cargas por  
Floresta Aleatória com Otimização Fogos de  
Artifício

Paulo Ricardo Zambelli Taveira

Dissertação aprovada por banca examinadora em  
14 de Abril de 2020, conferindo ao autor o título de  
**Mestre em Ciências em Ciência e Tecnologia  
da Computação.**

***Banca Examinadora:***

Dr Carlos Henrique Valério Moraes (Orientador)  
Dra. Isabela Neves Drummond  
Dr. Luiz Eduardo da Silva

Itajubá  
2020

---

Paulo Ricardo Zambelli Taveira

Identificação Não Intrusiva de Cargas por Floresta Aleatória com Otimização Fogos de Artifício/ Paulo Ricardo Zambelli Taveira. – Itajubá, 16 de Dezembro de 2019-

85 p. : il. (algumas color.) ; 30 cm.

Orientador: Dr Carlos Henrique Valério Moraes

Dissertação (Mestrado)

Universidade Federal de Itajubá

Programa de Pós-Graduação em Ciência e Tecnologia da Computação, 16 de Dezembro de 2019.

1. Monitoramento de cargas não-intrusiva. 2. Detecção da ocorrência de eventos. 3. Algoritmo de otimização por fogos de artifício.

CDU 07:181:009.3

---

Paulo Ricardo Zambelli Taveira

## **Identificação Não Intrusiva de Cargas por Floresta Aleatória com Otimização Fogos de Artifício**

Dissertação submetida ao Programa de Pós-Graduação em Ciência e Tecnologia da Computação como parte dos requisitos para obtenção do Título de Mestre em Ciências em Ciência e Tecnologia da Computação.

Trabalho aprovado. Itajubá, 14 de Abril de 2020:

---

**Dr Carlos Henrique Valério Moraes**  
Orientador

---

**Dra. Isabela Neves Drummond**

---

**Dr. Luiz Eduardo da Silva**

Itajubá  
16 de Dezembro de 2019

# Agradecimentos

Agradeço à minha família pelo incentivo e conselhos em todos os momentos.

Aos meus colegas de mestrado pelo companheirismo e pelos momentos de distração.

Ao meu orientador Carlos Henrique Valério de Moraes pelo apoio na realização do trabalho e pelo conhecimento compartilhado.

À Universidade Federal de Itajubá por toda estrutura fornecida e à equipe da Pós Graduação em Ciência e Tecnologia da Computação, coordenação e professores, pelos ensinamentos e suporte.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, pela concessão da bolsa de mestrado.

*“Revelemo-nos, mais por atos do que por palavras, dignos de possuir este grande país”  
(Theodomiro Carneiro Santiago)*

# Resumo

O controle de gastos relacionado à energia elétrica vem apresentando um grande crescimento, principalmente em ambientes residenciais. O monitoramento das cargas elétricas acionadas e removidas de uma residência é realizado frequentemente através de *smart-plugs*, fornecendo aos consumidores o intervalo de funcionamento e a potência consumida por cada equipamento. Apesar de uma solução prática de controle e redução de gastos de energia elétrica, possui um custo elevado devido à quantidade de medidores necessários. O problema do custo elevado pode ser contornado utilizando uma proposta de monitoramento de cargas não intrusivo (NILM), onde as medições de tensão e corrente são realizadas na entrada da residência, em contra partida demanda uma etapa extra de processamento. Nessa etapa extra, é necessário calcular a potência, identificar a ocorrência dos eventos e por fim, a identificar qual equipamento foi ligado ou desligado. As propostas desse trabalho foram utilizar um novo padrão de cálculo de potência proposto pela IEEE (1459-2010), a elaboração de um detector de evento do tipo heurístico utilizando janelas de análise flutuante para localização de zonas de estabilidade nos sinais de potência após indicação de uma variação de potência acima de um valor pré-determinado, testes da melhor forma de disposição dos dados do identificador de eventos para a identificação de qual carga foi adicionada ou removida do circuito monitorado, e otimização dos parâmetros do classificador Floresta Aleatória (RF-*Random Forest*) utilizando o algoritmo de otimização fogos de artifício (*Fireworks Algorithm- FA*). Os testes do identificador de eventos proposto e do classificador utilizado foram realizados no *dataset BLUED*, que contém dados coletados em uma residência norte-americana em um período de uma semana. Para os testes do classificador foram utilizados quatro formas diferentes de entrada de dados inicialmente, e posteriormente as duas formas que obtiveram melhores desempenhos foram utilizadas no processo de otimização do classificador. O desempenho do identificador de evento proposto foi comparado com outras publicação que utilizaram abordagens diferentes e obtiveram resultados satisfatórios. E os resultados das classificações foram comparadas entre si, por utilizarem formas de entrada de dados diferentes, e como também um classificador ideal, onde também foram observados uma melhora dos resultados quando comparados com os resultados de um classificador com parâmetros normalmente utilizados, um número maior de árvores foi utilizada em cada RF, mas com limitação na profundidade de cada árvore. E a importância das variáveis envolvidas no processo de classificação também foi calculada, destacando a importância da utilização do novo padrão de potência proposto pela IEEE.

**Palavras-chaves:** NILM, Monitoramento de cargas não intrusivo, *BLUED*, otimização por fogos de artifício, Floresta Aleatória, detecção de eventos heurístico, importância de variáveis.



# Abstract

The control of expenses related to electricity has been showing a great growth, especially in residential environments. Monitoring of electrical loads that are turning on and off from a home are often performed using smart-plugs, providing to the consumers information about operation intervals and power consumed by each device. Despite a practical solution to control and reduce electricity costs, it has a high cost due to the amount of meters required. The high cost problem can be worked around by using a non-intrusive load monitoring proposal (NILM), where voltage and current measurements are taken at the home entrance, in counterpart demand a extra processing step. In this extra step, it is necessary to calculate the powers, identification of the occurrence of events and finally, the identification of which equipment was turned on or off. The proposals of this work were to use a new power calculation standard proposed by the IEEE (1459-2010), the elaboration of a heuristic event detector using floating analysis windows to locate stability zones in the power signals after indicating a power variation above a predetermined value, testing the best way to dispose of event identifier data to identify which load has been added or removed from the monitored circuit, and optimization of the parameters of the Random Forest classifier using the fireworks optimization algorithm (FA). The proposed event identifier and classifier tests were performed on the dataset *BLUED*, which contains data collected at a north american residence over a period of one week. For the classifier tests, four different forms of data entry were used, and subsequently the two forms that obtained the best performances were used in the classifier optimization process. The event identifier results were compared with other publications that used different approaches and obtained satisfactory results. And the results of the classifications were compared to each other, for using different data entry forms, and also as an ideal classifier, where an improvement in the results was also observed when compared with the results of a classifier with commonly used parameters, presenting a larger number of trees used in each RF, but with a limited depth of each tree. And the importance of the variables involved in the classification process were calculated.

**Key-words:** NILM, Non-Intrusive Load Monitoring, BLUED, Firework optimization algorithm, heuristic event detector, variable importance.

# Lista de ilustrações

Figura 1 – Tipos de monitoramento de cargas . . . . .	26
Figura 2 – Processo para identificação de cargas . . . . .	26
Figura 3 – Diagrama de bloco do cálculo das potências utilizados . . . . .	30
Figura 4 – Fluxograma ilustrativo do algoritmo de uma árvore de decisão . . . . .	33
Figura 5 – Visualização das árvores para classificação . . . . .	34
Figura 6 – Exemplificação de bootstrap . . . . .	34
Figura 7 – Demonstração dos processos de explosão de fogos de artifício . . . . .	41
Figura 8 – Fluxograma FA . . . . .	44
Figura 9 – Fluxograma da metodologia proposta . . . . .	45
Figura 10 – Aplicação do filtro de média móvel . . . . .	47
Figura 11 – Processo de salto do pivô . . . . .	49
Figura 12 – Janelas flutuantes . . . . .	50
Figura 13 – Exemplo da disposição dos dados utilizando a variação das caracterís- ticas elétricas . . . . .	52
Figura 14 – Exemplo da disposição dos dados utilizando a forma de onda deslocada	52
Figura 15 – Exemplo da disposição dos dados utilizando a taxa de variação das curvas	53
Figura 16 – Exemplo de eventos identificados na fase A. . . . .	58
Figura 17 – Evento com longo tempo para estabilizar consumo de energia. . . . .	58
Figura 18 – Exemplo de eventos identificados na fase B . . . . .	59
Figura 19 – Exemplo de eventos identificados erroneamente na fase B . . . . .	59
Figura 20 – Importância das variáveis através do método VCE . . . . .	74
Figura 21 – Média ponderada da importância das variáveis através do método FOD	74
Figura 22 – Média ponderada por faixas de intervalos da importância das variáveis através do método FOD . . . . .	75

# Lista de tabelas

Tabela 1 – Disposição dos dados na tabela para treinamento . . . . .	51
Tabela 2 – Disposição dos dados na tabela para treinamento com a forma de onda simples . . . . .	51
Tabela 3 – Matriz de Confusão para o processo de otimização da identificação . . . . .	57
Tabela 4 – Matriz de Confusão para o processo de identificação da fase A . . . . .	59
Tabela 5 – Indicadores de desempenho na fase A . . . . .	60
Tabela 6 – Matriz de Confusão para o processo de identificação da fase B . . . . .	60
Tabela 7 – Indicadores de desempenho na fase B . . . . .	60
Tabela 8 – Matriz de Confusão para o processo de identificação . . . . .	60
Tabela 9 – Indicadores de desempenho geral . . . . .	61
Tabela 10 – Comparativo entre desempenhos do trabalho proposto e as soluções proposta em (ANDERSON et al., 2012b) e (LÜ; LI, 2019) . . . . .	61
Tabela 11 – Matriz de confusão para método de variações das características elétricas . . . . .	62
Tabela 12 – Indicadores do método de variação das características elétricas . . . . .	62
Tabela 13 – Matriz de confusão para método de variações das características elétricas com agrupamento de classes . . . . .	63
Tabela 14 – Indicadores do método de variação das características elétricas com agrupamento de classes . . . . .	63
Tabela 15 – Matriz de confusão para método de forma de onda simples . . . . .	64
Tabela 16 – Indicadores da forma de onda simples . . . . .	64
Tabela 17 – Matriz de confusão para método de forma de onda simples com agrupamento de classes . . . . .	65
Tabela 18 – Indicadores da forma de onda simples agrupada . . . . .	65
Tabela 19 – Matriz de confusão para método de forma de onda deslocada . . . . .	66
Tabela 20 – Indicadores da forma de onda deslocada . . . . .	66
Tabela 21 – Matriz de confusão para método de forma de onda deslocada com agrupamento de classes . . . . .	67
Tabela 22 – Indicadores da forma de onda deslocada agrupada . . . . .	67
Tabela 23 – Matriz de confusão para método de taxa de variação da onda . . . . .	68
Tabela 24 – Indicadores da taxa de variação . . . . .	68
Tabela 25 – Matriz de confusão para método de taxa de variação da onda com agrupamento de classes . . . . .	69
Tabela 26 – Indicadores da taxa de variação da onda com agrupamento . . . . .	69
Tabela 27 – Resumo dos indicadores dos métodos de disposição dos dados. . . . .	69
Tabela 28 – Intervalos dos parâmetros para otimização da RF. . . . .	70
Tabela 29 – Parâmetros otimizado para a Variação das Características Elétricas . . . . .	70

Tabela 30 – Parâmetros otimizado para a Forma de Onda Deslocada . . . . .	70
Tabela 31 – Indicadores da VCE-agrupada otimizados e os padrões. . . . .	71
Tabela 32 – Matriz de confusão para método de VCE-agrupado após a otimização .	71
Tabela 33 – Comparativo dos algoritmos de otimização FWA e PSO. . . . .	72
Tabela 34 – Indicadores da FOD-agrupada otimizados e os padrões. . . . .	72
Tabela 35 – Matriz de confusão para método de FOD-agrupado após a otimização .	73
Tabela 36 – Indicadores dos métodos otimizados e do padrão. . . . .	73
Tabela 37 – Comparação dos classificadores com um classificador ideal . . . . .	73
Tabela 38 – Resumo dos tempos de otimização e detecção dos eventos . . . . .	74
Tabela 39 – Resumo dos tempos de otimização e construção da RF . . . . .	75
Tabela 40 – Tabela de circuitos e <i>labels</i> . . . . .	80

# Lista de abreviaturas e siglas

BLUED	<i>Building-Level fUlly-labeled dataset for Electricity Disaggregation</i>
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
FFT	<i>Fast Fourier Transform</i>
DFT	<i>Discrete Fourier Transform</i>
FSM	<i>Finite State Machine</i>
FA	<i>Fireworks Algorithm</i>
NILM	<i>Non Intrusive Load Monitoring</i>
REDD	<i>Reference Energy Disaggregation Data Set</i>
DT	<i>Decision Tree</i>
RF	<i>Random Forest</i>
ML	<i>Machine Learning</i>
SVM	<i>Support Vector Machine</i>
NN	<i>Neural Network</i>
TP	<i>True Positive</i>
TN	<i>True Negative</i>
FP	<i>False Positive</i>
FN	<i>False Negative</i>
TPP	<i>True Positive Percentage</i>
FPP	<i>False Positive Percentage</i>
IG	<i>Information Gain</i>
BAGGING	<i>Bootstrap Aggregating</i>
GLR	<i>Generalized Likelihood Ratio Detector</i>
GA	<i>Genetic Algorithms</i>

PSO	<i>Particle Swarm Optimization</i>
MOP	<i>Multi-Objective Optimization</i>
SI	<i>Swarm Intelligent</i>
ACO	<i>Ant Colony Optimization</i>
VCE	<i>Variação das Características elétricas</i>
FOS	<i>Forma de Onda Simples</i>
FOD	<i>Forma de Onda Deslocada</i>
TVO	<i>Taxa de Variação da Onda</i>
PQ	<i>Potência Ativa e Reativa</i>

# Lista de símbolos

$v$	Tensão instantânea
$v_1$	Tensão frequência fundamental instantânea
$v_h$	Tensão harmônica instantânea
$i$	Corrente instantânea
$i_1$	Corrente frequência fundamental instantânea
$i_h$	Corrente harmônica instantânea
$\omega$	Frequência angular
$f$	Frequência
$\theta$	Ângulo de fase entre corrente e tensão
$V$	Tensão RMS
$V_0$	Tensão DC
$I$	Corrente RMS
$I_0$	Corrente DC
$p$	Potência instantânea
$P$	Potência ativa
$\bar{P}$	Potência ativa média
$p_a$	Potência instantânea ativa
$p_r$	Potência instantânea reativa
$P_1$	Potência ativa fundamental
$Q$	Potência reativa
$Q_1$	Potência reativa fundamental
$S$	Potência aparente
$S_1$	Potência aparente fundamental

$S_N$	Potência aparente total
$H$	Entropia do sistema
$\chi^2 GOF$	<i>Chi-Square Goodness of Fit</i>
$\sigma^2$	<i>Variância</i>
$B$	<i>Conjunto de dados</i>
$\hat{f}$	<i>Modelo de treinamento</i>
$\hat{S}$	<i>Número máximo</i>
$\hat{\psi}$	<i>Distância entre um classificador ideal e um proposto</i>



# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>19</b>
1.1	Objetivo	20
1.2	Trabalhos Relacionados	21
1.3	Organização do trabalho	22
<b>2</b>	<b>REVISÃO TEÓRICA</b>	<b>24</b>
2.1	<i>Datasets</i> de monitoramentos não-intrusivos	24
2.2	Monitoramento não intrusivo de cargas	25
2.2.1	Aquisição dos sinais de onda da tensão e corrente	27
2.2.2	Cálculo de Potências	27
2.2.3	Potências senoidais	28
2.2.4	Potências não-senoidais	28
2.3	<b>Algoritmos de classificação</b>	<b>31</b>
2.3.1	Árvore de decisão	31
2.3.2	Floresta Aleatória	32
2.4	<b>Técnicas de Inteligencia artificial</b>	<b>36</b>
2.4.1	Identificação de cargas	36
2.4.2	Otimização no método de identificação	36
2.5	<b>Deteccção de Eventos</b>	<b>36</b>
2.6	<b>Considerações Finais</b>	<b>37</b>
<b>3</b>	<b>ALGORITMO DE OTIMIZAÇÃO</b>	<b>38</b>
3.1	<i>Algoritmo de Fogos de Artifício- FA</i>	40
3.1.1	Explosão	40
3.1.2	Mapeamento	42
3.1.3	Faíscas Gaussianas	42
3.1.4	Seleção	43
3.2	<b>Considerações Finais</b>	<b>43</b>
<b>4</b>	<b>METODOLOGIA PROPOSTA</b>	<b>45</b>
4.1	<b>Etapa I- Pré-processamento dos dados</b>	<b>45</b>
4.1.1	Cálculo das potências do <i>dataset</i>	46
4.1.2	Filtro de média móvel	46
4.2	<b>Etapa II - Identificação da ocorrência de eventos</b>	<b>47</b>
4.2.1	Cálculos estatísticos	48
4.2.2	Janelas flutuantes	48

4.2.3	Extração das características dos eventos . . . . .	50
4.2.4	Seleção dos eventos para o treinamento . . . . .	50
<b>4.3</b>	<b>Etapa III - Treinamento e Classificação . . . . .</b>	<b>51</b>
4.3.1	Seleção do formato para treinamento . . . . .	51
4.3.2	Otimização do classificador utilizando o FA . . . . .	53
4.3.3	Desempenho do classificador . . . . .	53
<b>5</b>	<b>RESULTADOS . . . . .</b>	<b>56</b>
<b>5.1</b>	<b>Detecção de evento . . . . .</b>	<b>56</b>
<b>5.2</b>	<b>Seleção do melhor formato dos dados para o treinamento do clas- sificador . . . . .</b>	<b>61</b>
5.2.1	Variação das características elétricas (VCE) . . . . .	61
5.2.2	Forma de onda simples (FOS) . . . . .	63
5.2.3	Forma de onda deslocada (FOD) . . . . .	64
5.2.4	Taxa de variação da onda (TVO) . . . . .	66
5.2.5	Resumo dos indicadores . . . . .	67
<b>5.3</b>	<b>Classificação de cargas . . . . .</b>	<b>68</b>
<b>5.4</b>	<b>Resumo dos tempos de execução . . . . .</b>	<b>73</b>
<b>5.5</b>	<b>Considerações finais . . . . .</b>	<b>75</b>
<b>6</b>	<b>CONCLUSÃO . . . . .</b>	<b>77</b>
	<b>ANEXOS . . . . .</b>	<b>79</b>
	<b>ANEXO A – TABELA DE CIRCUITOS E LABELS . . . . .</b>	<b>80</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>81</b>

# 1 Introdução

Na busca por maior integração entre fornecedores, consumidores e órgãos governamentais (responsáveis por fiscalizar e regulamentar serviços e produtos ligados a energia elétrica) para oferecer maior confiabilidade segurança e eficiência as redes de energia, diversos equipamentos e técnicas vem sendo aplicadas para monitorar o consumo de energia, minimizar a possibilidade de "*black-outs*"(DAVIS; MASSARA, 1996), e estimar tipos de cargas elétricas que são ligadas a rede elétrica.

Um grande aliado a esta busca por integração é o conceito de *Smart Grid* (ou Redes inteligentes, como tem sido traduzido em português), que é a interligação de sistemas de controle e de energia elétrica, que disponibiliza os dados do sistema elétrico coletados para serem usados no planejamento estratégico e nas tomadas de decisão de empresas ou dos órgãos governamentais responsáveis(HART, 1992)(FALCÃO, 2010) .

Os dados gerados pela identificação das cargas acopladas ao sistema podem definir um perfil de consumo e hábitos dos moradores das residências, tais como horários de maior consumo de energia elétrica, quais equipamentos são utilizados simultaneamente, qual a sequência de utilização de equipamentos, se algum equipamento está consumindo energia em horários em que deveria estar desligado. Esses perfis e hábitos podem ser utilizados por fornecedoras de energia para definir pacotes de consumo diferenciados para cada consumidor, ou por empresas, auxiliando na seleção da oferta de produtos para cada cliente. Tais dados, podem ainda formar a entrada de um sistema de automação residencial, podendo prever ações do usuário e atuar em equipamentos que possuam tecnologia *IoT*.

Para disponibilizar esses dados de modo fidedigno e discriminados são necessários, geralmente, que diversos instrumentos de medição sejam acoplados a cada equipamento que se deseja monitorar. Tal método de medição é conhecido por medição intrusiva(*intrusive measurement*), e é largamente utilizado devido a simplicidade de sua implementação. Porém, termina por elevar o custo da aquisição dos dados devido ao número de medidores utilizados ser igual ao número de equipamentos a serem monitorados.

Há, por outro lado, outro método de medição denominado medição não intrusiva (*non-intrusive measurement*), onde poucos medidores são acoplados na entrada do sistema a ser medido, reduzindo o número de equipamentos utilizados e, conseqüentemente, o custo da medição. Porém, esse método não disponibiliza dos dados de cada equipamento separadamente, o que torna as análises mais "superficiais", quando nenhuma outra técnica auxiliar é aplicada. Logo, os dados coletados por esse método necessitam de tratamento através de técnicas de computação, para que o máximo de informações possam

ser extraídas e utilizadas (HART, 1992) (ANDERSON et al., 2012a).

As técnicas de tratamento de dados utilizadas tem geralmente a finalidade de filtrar, calcular e segregar características elétricas dos equipamentos que foram conectados ao sistema monitorado. São utilizados diversos métodos, tais como cálculos simples de potência ativa e reativa, Transformada Rápida de Fourier (*Fast Fourier Transform - FFT*), aplicações de filtros digitais e outras. Quanto maior a precisão das técnicas aplicadas para o tratamento dos dados, mais assertiva é a fase de identificação dos equipamentos e, conseqüentemente, maior exatidão das informações extraídas dos dados coletados (ZOHA et al., 2012).

O método proposto possui um identificador de eventos que utiliza o *dataset* BLUED e seu desempenho é comparado com dois outros identificadores que utilizam o mesmo *dataset*, o detector GLR e o detector híbrido. O identificador proposto tem resultado melhor que o primeiro deles.

O método proposto utiliza quatro abordagens diferentes quanto a forma de disposição dos dados para a classificação a partir do conjunto original do *dataset*, e estas mesmas abordagens também são utilizadas com um conjunto de classes simplificadas, no qual classes com características elétricas semelhantes são agrupadas. Dessas abordagens as que possuem melhores resultados são a variação das características elétricas agrupada (VCE-agrupada) e a forma de onda deslocada agrupada (FOD-agrupada).

O método proposto também realiza o ajuste dos parâmetros do classificador RF através do algoritmo de otimização FA utilizando as formas de disposição dos dados VCE-agrupada e FOD-agrupada, e os resultados das duas otimizações são muito semelhantes. Porém, o classificador RF produzido utilizando o VCE-agrupado é mais simples, possui um número de árvores e profundidade menores. Uma otimização extra é realizada utilizando o VCE-agrupado e o algoritmo de otimização enxame de partículas (PSO). A comparação entre os resultados das técnicas de otimização FA e PSO demonstra desempenho semelhante, porém o RF otimizado com o algoritmo FA produz um modelo mais simples quando analisado o número de árvores, mostrando melhor desempenho do algoritmo de otimização utilizado.

## 1.1 Objetivo

Esse projeto teve como objetivo geral a manipulação de grandes volumes de dados, identificação de ocorrência de eventos, extração de informações úteis a partir deles e a aplicação de um modelo de aprendizado de máquina conhecido por *Random Forest* (Floresta Aleatória, em português) para classificação de cargas residenciais, usando em conjunto o algoritmo de otimização Fogos de Artifício para avaliar seu desempenho.

Como objetivos específicos, foram considerados:

- Utilizar cálculos de potência a partir do novo padrão do IEEE 1459/2010 para obtenção de padrões de treinamento do método de aprendizagem aplicado.
- Avaliar o desempenho da identificação de cargas através da técnica *Random Forest*.
- Otimizar dos parâmetros da técnica *Random Forest*, através do algoritmo de otimização de Fogos de Artíficos.
- Comparar do tempo e performance da técnica *Random Forest*, utilizando outros métodos de otimização.

## 1.2 Trabalhos Relacionados

Diversas propostas foram elaboradas ao longo dos anos após os primeiros trabalhos envolvendo a proposta de monitoramento de cargas no começo dos anos 90. Os trabalhos, propostas e autores que merecem destaque são descritos a seguir.

Um dos primeiros trabalhos com monitoramento de cargas não-intrusivo em ambiente residencial foi desenvolvido em (HART, 1992), tido como uma das referências básicas em todos os trabalhos ligados ao assunto devido a abrangência e riqueza de seu trabalho.

Já um dos primeiros trabalhos a aplicar esse conceito em ambiente industrial foi (ROOS et al., 1994), que utilizou redes neurais para identificação de padrões das cargas elétricas.

Uma das características muito relevante dos trabalhos desenvolvidos é o tipo de equipamento de amostragem dos sinais elétricos. Quando possuem alta taxa de amostragem como em (KATO et al., 2009) e (ENGLERT et al., 2013) (entre  $1kHz$  e  $100kHz$ ) permitem a detecção e análise dos estados de transição dos equipamentos, porém suas implementações são mais caras. Em contra partida, trabalhos com equipamentos de amostragem mais baratos possuem taxas de amostragem mais baixas, geralmente menores que  $10Hz$ , como em (PARADISO et al., 2013), (RIDI; GISLER; HENNEBERT, 2013b) e (RIDI; GISLER; HENNEBERT, 2013a).

Alguns trabalhos foram desenvolvidos com a finalidade de gerar banco de dados, que estão disponíveis para uso, tendo características distintas quanto ao local onde foram desenvolvidas, taxa de amostragem e número de equipamentos monitorados. Entre eles destacam-se REDD (*Reference Energy Disaggregation Data Set*) (KOLTER; JOHNSON, 2011), BLUED (*Building-Level fUlly-labeled dataset for Electricity Disaggregation*) (ANDERSON et al., 2012a) e UK-DALE (*UK recording Domestic Appliance-Level Electricity*) (KELLY; KNOTTENBELT, 2015b).

Os modos de extração de características dos equipamentos monitorados podem ser classificados como características baseadas no tempo ou baseadas na frequência. Quando baseados no tempo, usualmente são utilizadas a potência ativa ( $P$ ) e reativa ( $Q$ ). Porém, não são os únicos, a construção do diagrama PQ permite uma boa percepção de determinados equipamentos dependendo da sua resistência, indutância e capacitância como visto em (LIANG et al., 2009). A tensão e a corrente são utilizadas em (KATO et al., 2009), a trajetória da tensão e corrente ( $V - I$ ) em (LAM; FUNG; LEE, 2007), e os picos de corrente também podem ser utilizados como proposto em (ITO et al., 2004).

Quando baseados na frequência, inicialmente há a necessidade de uma taxa de amostragem de maior ou igual a  $1kHz$ . Quando essa premissa é cumprida, existem duas aplicações básicas para esse fim, a Transformada Rápida de Fourier (FFT- *Fast Transformation Fourier*) e a Transformada discreta de Fourier (DTF -*Discrete Transformation Fourier*). A DTF tem uma eficiência baixa em frequência de amostragem não tão altas, como mostrado em (ZAIDI et al., 2010). A FFT foi utilizada e seu desempenho avaliado em (REINHARDT et al., 2012b), (REINHARDT et al., 2012a) e (MEEHAN et al., 2012).

### 1.3 Organização do trabalho

O presente trabalho foi organizado da seguinte forma:

- No capítulo 1 é feita uma introdução sobre o contexto para o desenvolvimento de métodos de identificação de cargas de forma não intrusiva, contendo as principais justificativas do desenvolvimento da proposta, e são apresentados os objetivos, principais trabalhos relacionados e a organização do trabalho.
- No capítulo 2 é feita uma revisão teórica dos *datasets* existentes, dando foco maior ao *dataset* BLUED (utilizado nesse trabalho), das classificações básicas dos tipos de monitoramento não-intrusivo de cargas, cálculos das potências a serem utilizadas, alguns algoritmos de classificação, técnicas de otimização e detecção de eventos.
- No capítulo 3 é feita uma apresentação sobre o algoritmo de otimização *Firework Algorithm* utilizado.
- No capítulo 4 são apresentados os detalhes do desenvolvimento da solução, incluindo informações sobre as técnicas e algoritmos utilizados, e a forma medir o desempenho deles.
- No capítulo 5 são demonstrados os resultados dos processos de otimização do detector de eventos e do classificador RF, a avaliação das diferentes formas de utilização dos dados para início da etapa de classificação e a comparação da metodologia proposta com outras presente na literatura.

- Por fim, no capítulo 6 é feita a conclusão sobre os experimentos e possíveis melhorias são propostas como trabalhos futuros.

## 2 Revisão teórica

O crescente interesse pela aplicação do conceito de *Smart City* pode apoiar-se na linha de pesquisa de monitoramento não intrusivo e reconhecimento das cargas ligadas a um sistema. Esta linha de pesquisa pode garantir a integração de estruturas já existentes no mercado com os novos modelos *Smarts* que estão sendo criados, tornando desnecessário o descarte completo dos modelos antigos e aquisição dos modelos *Smarts*. Nessa linha de pesquisa o monitoramento das cargas é feito utilizando poucos sensores e a identificação de cargas elétricas é feita utilizando-se diversas técnicas de inteligência artificial, tais como Redes Neurais (RUZZELLI et al., 2010) (KELLY; KNOTTENBELT, 2015a) (BIANSOONGNERN; PLANGKLANG, 2016), modelo oculto de Markov (ou em inglês, *Hidden Markov Models*) (ZIA; BRUCKNER; ZAIDI, 2011), *Support Vector Machine* (SVM) (SRINIVASAN; NG; LIEW, 2005) (KATO et al., 2009) (LIN et al., 2010) (FIGUEIREDO; ALMEIDA; RIBEIRO, 2012) (FIGUEIREDO; ALMEIDA; RIBEIRO, 2011).

Os dados gerados por esse conceito é de grande interesse para diversas empresas e organizações, que conseguem extrair informações, como rotina dos usuários, quantidade de determinados equipamentos elétricos e eletrônicos na residência e horários de consumos energético anormais, que podem ser monetizadas através da venda dessas informações a terceiros ou através de um sistema de recomendação de produtos para impulsionar vendas como analisado em (BORGES; OLIVEIRA, 2010).

Os trabalhos que foram utilizados como base teórica e de comparação são apresentados resumidamente nas seções 2.1, 2.2, 2.3 e 2.4.

### 2.1 *Datasets* de monitoramentos não-intrusivos

Diversos trabalhos recentes focaram em desenvolver *datasets* do monitoramento de ambientes residenciais e comerciais, disponibilizando-os para impulsionar pesquisas relacionadas ao monitoramento de cargas não intrusiva (NILM - *Nonintrusive Load Monitoring*), uma vez que o processo de aquisição dos dados além de longo, trabalhoso e complexo é o passo inicial para o desenvolvimento de algoritmos de identificação de cargas.

Um desses trabalhos foi realizado por (ANDERSON et al., 2012a), onde o *dataset* BLUED (*Building-Level fully-labeled dataset for Electricity Disaggregation*) foi criado a partir do monitoramento do sinal de tensão e corrente na entrada de uma residência norte-americana durante uma semana. Cada evento de transição de carga foi devidamente



nomeado e seu instante de ocorrência foi gravado com auxílio de equipamentos que monitoraram cada equipamento individualmente. A taxa de amostragem usada foi de 12 kHz durante todo o processo. O tamanho do *dataset* é cerca de 300 Gigabytes, contendo aproximadamente 6400 arquivos.

Trabalhos semelhantes também foram realizados por (KOLTER; JOHNSON, 2011) gerando o *dataset REDD (Reference Energy Disaggregation Dataset)* com uma taxa de amostragem de 15 kHz coletado durante vários meses em mais de uma residência norte-americana (tamanho aproximado dos dados é 11 GB por casa por dia, com aproximadamente 1TB no total), por (KELLY; KNOTTENBELT, 2015b) gerando o *UK-DALE (an open-access dataset from the UK recording Domestic Appliance-Level Electricity)* com uma taxa de amostragem de 16 kHz coletado durante quase dois anos em seis residências no Reino Unido (tamanho aproximado dos dados é 4 TB). Ambos os *dataset* utilizaram medidores em cada carga para poder indicar o estado do equipamento (*ON* ou *OFF*).

## 2.2 Monitoramento não intrusivo de cargas

As formas de identificação de assinatura de cargas descritas para o método não-intrusivo em (HART, 1992) são divididas nas análises dos estados estacionários e de transição da carga. No caso da análise estacionária, pode-se subdividir em análises quanto a frequência fundamental (da potência ou corrente) e os harmônicos das correntes. E no caso da análise nos estados de transição pode-se subdividir quanto a forma, tamanho, duração e constantes de tempo das ondas de corrente e potência.

Tanto em (ANDERSON et al., 2012a) quanto em (HART, 1992) foram utilizadas cálculos simples de potência ativa ( $P$ ), reativa ( $Q$ ) e aparente ( $S$ ) para identificação de cargas através das potências, onde se leva em consideração cargas do tipo lineares como descritas em (IEEE, 2010).

Porém, uma nova definição padrão de cálculo de potência elétrica foi feita pela IEEE em (IEEE, 2010), onde é possível quantificar o fluxo de energia elétrica em circuitos de uma e três fases em condições senoidais, não senoidais, balanceadas e desbalanceadas. Tais cálculos permitem a extração de características marcantes na potência de cargas que apresentam comportamento linear ou não, fornecendo uma variedade de novos tipos de potência elétrica.

O NILM é realizado utilizando-se pares de equipamentos de medição dos sinais de tensão e corrente que alimentam um circuito a ser monitorado, geralmente possuindo vários equipamentos e dispositivos que funcionam de forma independente conectados a ele (HART, 1992).

Esse tipo de monitoramento de carga diverge do tradicionalmente utilizado, o moni-

toramento de cargas intrusivo, onde cada carga é monitorada individualmente, utilizando um par de medidores para cada equipamento ligado ao circuito, que permite a fácil identificação de quais equipamentos foram ligados ou desligados (Figura 1a) e seus consumos.

Já no NILM, um par de medidores é posicionado na entrada do circuito a ser monitorado (Figura 1b), o que fornece os dados do circuito como um todo. A quantidade de sensores é mínima na configuração de NILM, porém esse ganho na redução de equipamentos acarreta no aumento na complexidade na identificação dos equipamentos, uma vez que os sinais de corrente e tensão são sobrepostos a medida que cada um dos equipamentos conectados ao circuito monitorados é ligado ou desligado.

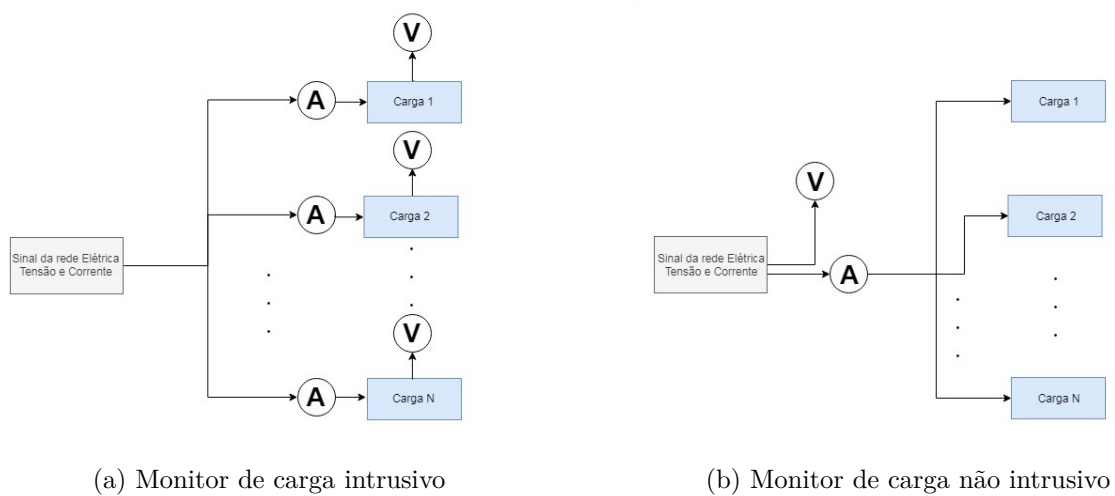


Figura 1 – Tipos de monitoramento de cargas

Para realizar o monitoramento das cargas em circuito é necessário:

- aquisição dos sinais de onda da tensão e corrente;
- cálculo as potências;
- identificação a presença de um evento;
- classificação;

como pode ser observado na Figura 2.



Figura 2 – Processo para identificação de cargas

Em (HART, 1992) foi proposta a classificação dos tipos de equipamentos baseado na sua forma de operação, sendo elas:

- Tipo I - Equipamentos com dois estados (ligado/desligado), tais como lâmpadas;
- Tipo II - Equipamentos com múltiplos estados de operação, definidos com máquinas de estado finito (*Finite State Machine - FSM*), tais como geladeiras e ferro de passar roupa;
- Tipo III - Equipamentos com estados continuamente variáveis, ou seja, não consomem valores fixos de energia, tais como lâmpadas com *dimmer* e furadeiras com controle de velocidade;
- Tipo IV - Equipamentos que ficam ativos por longos períodos de tempo consumindo uma quantidade constante de energia, tais como detector de fumaça e receptores de televisão

### 2.2.1 Aquisição dos sinais de onda da tensão e corrente

Durante a etapa de aquisição de dados, um dos fatores de maior importância é a taxa de aquisição. Quando um projeto tem a pretensão de utilizar de análises ligadas a frequência ou intervalos de transição de estado do equipamento monitorado, a taxa de amostragem deve ser maior que o dobro da frequência do sinal amostrado (teorema de Nyquist (NYQUIST, 1949)(SHANNON, 1949)). Isso garante que o sinal medido não será erroneamente interpretado como sendo um sinal de menor frequência (*aliasing*). E quanto maior a taxa de amostragem nesses casos, maior a quantidade de informações que podem ser extraídas do sinal original, tais como os harmônicos das correntes.

### 2.2.2 Cálculo de Potências

O novo padrão de cálculo de potência do IEEE (IEEE, 2010) foi utilizado, pois fornece meio de quantificar o fluxo de energia elétrica senoidal e não-senoidal em circuito de uma fase. Considerando uma fonte de tensão senoidal dada por 2.1

$$v = \sqrt{2}V \sin(\omega t) \quad (2.1)$$

e corrente senoidal gerada por 2.2

$$i = \sqrt{2}I \sin(\omega t - \theta) \quad (2.2)$$

onde:

$V$  é a tensão RMS (V);

$I$  é a corrente RMS (A);

$\omega$  é frequência angular  $2\pi f$  (rad/s);

$f$  é a frequência da rede elétrica (hz);

$\theta$  é o angulo de fase entre a corrente e tensão (rad);

$t$  é o tempo (s);

Os cálculos de potência utilizados para classificação das cargas monitoradas são divididos em duas partes: potências senoidais e potências não-senoidais.

### 2.2.3 Potências senoidais

A potência instantânea é dada por 2.3 ou 2.4

$$p = vi \quad (2.3)$$

$$p = p_a + p_q \quad (2.4)$$

onde:

$p$  é a potência instantânea;

$p_a$  é a potência ativa instantânea, descrita pela equação 2.5;

$p_q$  é a potência reativa instantânea, descrita pela equação 2.6;;

$$p_a = VI \cos\theta [1 - \cos(2\omega t)] = P [1 - \cos(2\omega t)]; \quad (2.5)$$

$$p_q = -VI \sin(\theta) \sin(2\omega t) = -Q \sin(2\omega t); \quad (2.6)$$

Potência aparente é o produto da tensão RMS (*Root-mean-square*) e da corrente RMS, como descrita pela Equação 2.7:

$$S = VI; \quad (2.7)$$

ou pela raiz quadrada da potência ativa ao quadrado mais a potência reativa ao quadrado, como descrita pela Equação 2.8:

$$S = \sqrt{P^2 + Q^2}; \quad (2.8)$$

### 2.2.4 Potências não-senoidais

Para condições permanentes, a tensão e corrente instantânea não-senoidal têm dois componentes distintos: os componentes na frequência do sistema de potência  $v_1$  e  $i_1$  e os

demais  $v_h$  e  $i_h$  (Equações 2.9 e 2.10).

$$v = v_1 + v_h \quad (2.9)$$

$$i = i_1 + i_h \quad (2.10)$$

onde:

$$v_1 = \sqrt{2}V_1 \text{sen}(\omega t - \alpha_1);$$

$$i_1 = \sqrt{2}I_1 \text{sen}(\omega t - \beta_1);$$

$$v_H = V_0 + \sqrt{2} \sum V_h \text{sen}(h\omega t - \alpha_h);$$

$V_0$  é a componente DC, que normalmente é inexistente no sistema elétrico de potência;

$$i_H = I_0 + \sqrt{2} \sum I_h \text{sen}(h\omega t - \beta_h);$$

$I_0$  é a componente DC, que normalmente é inexistente no sistema elétrico de potência;

Os valores RMS quadráticos correspondentes da tensão e corrente são apresentados nas Equações 2.11 e 2.12, respectivamente:

$$V^2 = \frac{1}{kT} \int_{\tau}^{\tau+kT} v^2 dt = V_1^2 + V_H^2 \quad (2.11)$$

$$I^2 = \frac{1}{kT} \int_{\tau}^{\tau+kT} i^2 dt = I_1^2 + I_H^2 \quad (2.12)$$

onde os valores RMS de  $V_H$  e  $I_H$  são calculados a partir das equações 2.13 e 2.14:

$$V_H^2 = V_0^2 + \sum_{h \neq 1} V_h^2 = V^2 - V_1^2 \quad (2.13)$$

$$I_H^2 = I_0^2 + \sum_{h \neq 1} I_h^2 = I^2 - I_1^2 \quad (2.14)$$

A potência ativa não-senoidal (W) é dada pela equação 2.15:

$$P = P_1 + P_H \quad (2.15)$$

A potência ativa fundamental (W) é dada pela equação 2.16:

$$P_1 = \frac{1}{kT} \int_{\tau}^{\tau+kT} v_1 i_1 dt = V_1 I_1 \cos \theta_1 \quad (2.16)$$

A potência ativa harmônica (W) é dada pela equação 2.17:

$$P_H = V_0 I_0 + \sum_{h \neq 1} V_h I_h \cos \theta_h \quad (2.17)$$

A potência reativa fundamental (var) é dada pela equação 2.18:

$$Q_1 = \frac{\omega}{kT} \int_{\tau}^{\tau+kT} i_1 \left[ \int v_1 dt \right] dt = V_1 I_1 \sin \theta_1 \quad (2.18)$$

A potência aparente (VA) é dada pela equação 2.19:

$$S = VI \quad (2.19)$$

A potência fundamental aparente (VA) é dada pela equação 2.20:

$$S_1^2 = P_1^2 + Q_1^2 \quad (2.20)$$

A potência não fundamental aparente (VA) é dada pela equação 2.21:

$$S_N = \sqrt{S^2 - S_1^2} \quad (2.21)$$

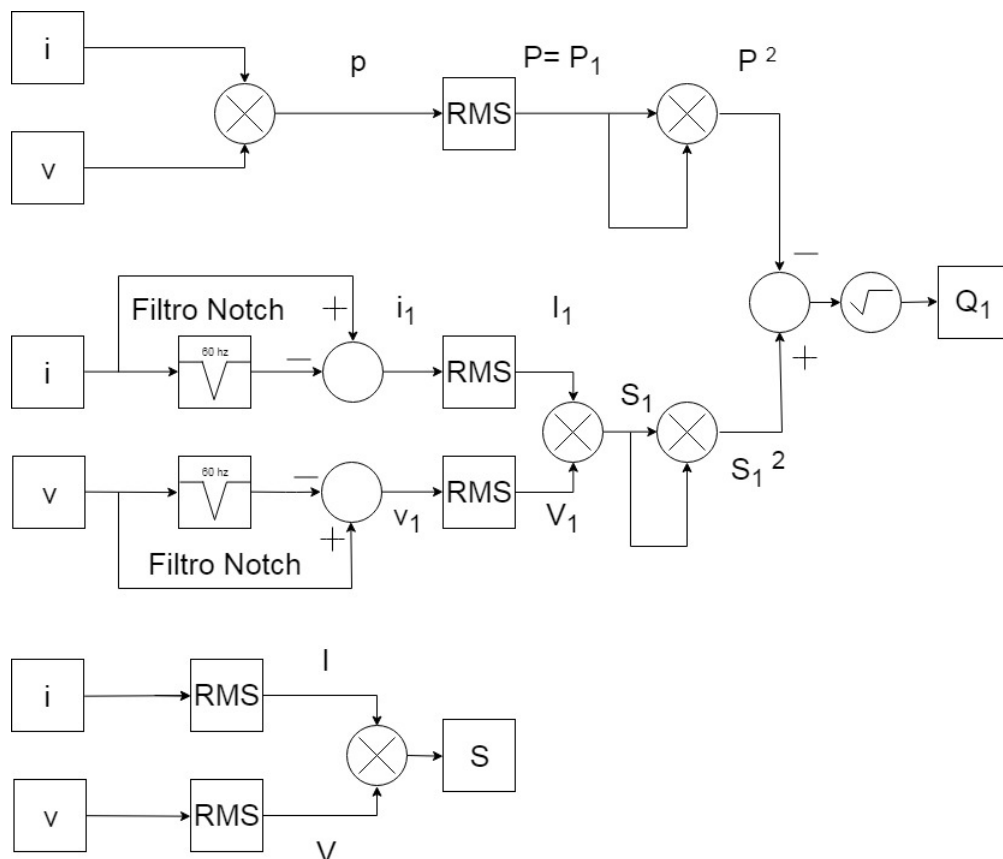


Figura 3 – Diagrama de bloco do cálculo das potências utilizados

## 2.3 Algoritmos de classificação

Existem diversos algoritmos para classificação que são utilizados nas mais diversas aplicações. Os mais utilizados em trabalhos envolvendo o NILM são Redes Neurais (*Neural Network*-NN) como pode ser notado em (KELLY; KNOTTENBELT, 2015a), (BIANSOONGNERN; PLANGKLANG, 2016) e (RUZZELLI et al., 2010), *Support Vector Machine*- SVM que foi utilizado em (SRINIVASAN; NG; LIEW, 2005), (KATO et al., 2009), (LIN et al., 2010), (FIGUEIREDO; ALMEIDA; RIBEIRO, 2012), (FIGUEIREDO; ALMEIDA; RIBEIRO, 2011), *Nearest Neighbors* utilizado em (FIGUEIREDO; ALMEIDA; RIBEIRO, 2012) e (FIGUEIREDO; ALMEIDA; RIBEIRO, 2011), *Fuzzy C-means* abordado em (LIN; TSAI; CHEN, 2011), dentre muitos outros outros.

Outro método de classificação não muito explorado é o de Floresta Aleatória. Floresta Aleatória (ou *Random Forest* - RF, em inglês) é um método de Aprendizado de Máquina (*Machine Learning*- ML) baseado em uma coleção de árvores de decisão (*Decision Tree*- DT) utilizado tanto para classificação quanto para regressão.

RF vem sendo utilizado em diversas outras aplicações como monitoramentos remotos (BELGIU; DRĂGUT, 2016), classificação de terrenos (RODRIGUEZ-GALIANO et al., 2012), classificação de imagens (BOSCH; ZISSERMAN; MUNOZ, 2007), seleção e classificação de informações biológicas (DÍAZ-URIARTE; ANDRES, 2006) (QI, 2012) (BOULESTEIX et al., 2012), dentre outras.

### 2.3.1 Árvore de decisão

Na implementação de uma árvore de decisão (ou em inglês, *Decision Tree* - DT), todas as características/ variáveis do conjunto de dados são utilizadas no treinamento. A seleção de qual variável será utilizada na divisão do nó da árvore é feita através do cálculo da entropia e do ganho de informação.

A entropia indica a pureza do grupo dada pela Equação 2.22, onde B é o conjunto de dados com M classes diferentes e independentes, e  $p$  é a ocorrência de uma determinada classe. Sua variação é de zero a um, sendo zero maior pureza (100% de um evento acontecer em determinado conjunto) e um para maior impureza (PINEDA et al., 2006). Para fins de cálculos, assume-se que  $p_{(i)} * \log_2 p_{(i)} = 0$  quando  $p_{(i)}$  for zero.

$$H(B) = - \sum_{i=1}^M p_{(i)} * \log_2 p_{(i)} \quad (2.22)$$

O ganho de informação (*Information Gain*- IG) representa a variação da entropia dado a seleção de determinada variável a ser utilizada para quebra do nó. O IG é calculado através da Equação 2.23, onde B representa o conjunto de dados utilizados, X uma variável

qualquer,  $H(B)$  e  $H(B|X)$  são, respectivamente, a entropia do sistema e a entropia do sistema dado uma determinada variável  $X$  a ser utilizada para quebra do nó.

$$IG(B, X) = H(B) - H(B|X) \quad (2.23)$$

Pode-se implementar árvores de decisão de diversas formas, porém as mais frequentemente utilizadas segundo (PATIL; AGRAWAL; BAVISKAR, 2015) são:

- ID3 - *Iterative Dichotomiser 3* proposta em (QUINLAN, 1986), onde são utilizadas árvores multidirecionais, procurando em cada nó o atributo categórico que separava de maneira a maximizar o ganho de informação para cada estágio (maneira gananciosa). Geralmente um método de poda (*pruning*) é aplicado para melhorar a habilidade de generalização da árvore para dados desconhecidos.
- C4.5- sucessor do ID3 descrito em (QUINLAN, 1993), onde foram removidas as restrições quanto ao tipo de atributos utilizados, não necessitando mais serem categóricos. C4.5 converte a árvore de decisão em regras do tipo *if-then* e o método de poda é aplicado as regras de *if-then* quando a precisão da classificação melhora com a retirada delas. Essa implementação possui um frequência de uso de 54,55% dentre os trabalhos científicos ligados a árvores de decisão.
- CART- *Classification and Regression Trees*, ou árvore de classificação e regressão, proposta em (BREIMAN et al., 1984), onde há suporte também a variáveis numéricas, e não gerava conjunto de regras. As árvores são binárias e utilizam os atributos e *thresholds* (como número mínimo de elementos/dados para quebra do nó) e que geravam o maior ganho de informação. Essa implementação possui um frequência de uso de 40.9% dentre os trabalhos científicos ligados a árvores de decisão.

O fluxograma da Figura 4 representa a implementação de uma árvore de decisão do tipo *CART*, e é baseada em uma função recursiva, tendo como entrada inicial a raiz da árvore, que possui inicialmente todos os elementos com seus respectivos atributos do conjunto a ser classificado. Para cada atributo dos dados no conjunto é calculado o ganho de informação. O atributo que possuir mais ganho de informação é selecionado para separar o conjunto de dados, gerando assim dois novos nós (nós-filhos). O atributo utilizado é removido dos nós filhos. E o processo é repetido para cada nó filho, até que o grupo esteja puro (entropia igual a zero) ou não haja mais atributos.

### 2.3.2 Floresta Aleatória

Em (BREIMAN, 2001) foi proposta a utilização de um conjunto de árvores de decisão, a utilização de um método que é chamado de *Bootstrap Aggregating* (ou *Bag-*



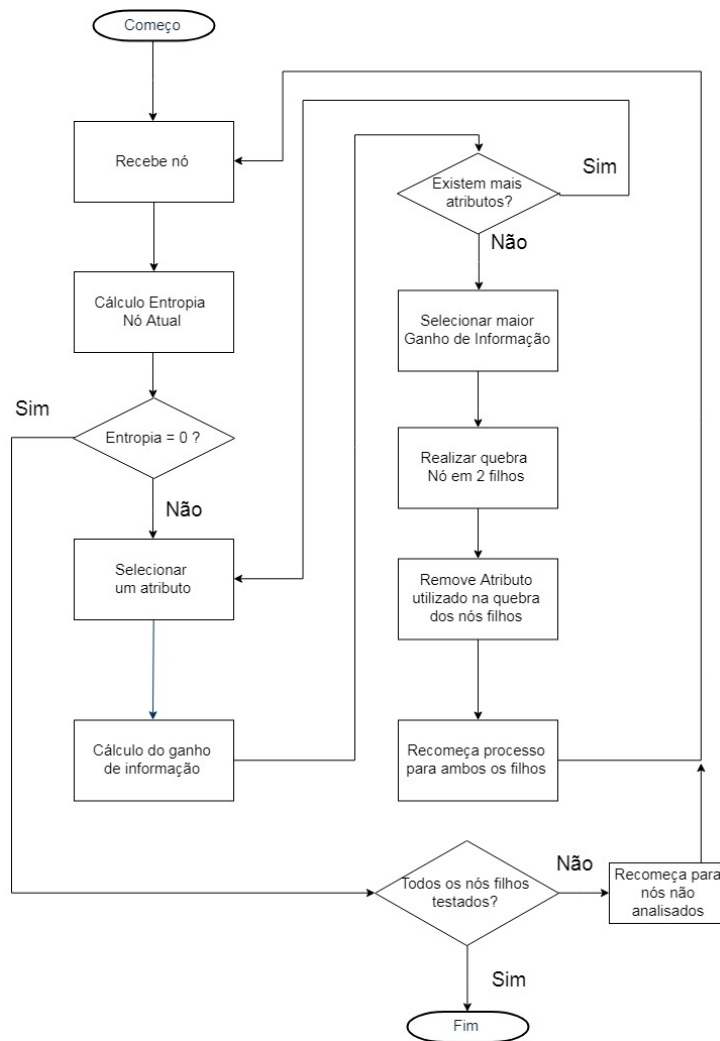


Figura 4 – Fluxograma ilustrativo do algoritmo de uma árvore de decisão

*ging*) e um método para decorrelacionar atributos. Tal proposta é chamada de Floresta Aleatória.

Visualmente, uma RF e uma árvore de decisão são muito parecidas, como pode ser observado na Figura 5a e na Figura 5b, respectivamente. E o procedimento de classificação é basicamente o mesmo, quando um amostra necessita ser classificada, ela é introduzida na RF, que por sua vez a passa por todas as suas árvores de decisão, e o resultado de cada árvore de decisão é coletado. A resposta/classificação final para a entrada é dada a partir da combinação dessa coleção de saídas, geralmente por voto da maioria.

O propósito geral do procedimento de *Bagging* é reduzir a variância estatística nos métodos de aprendizado. O modo como isso é realizado fica claro quando assume-se um conjunto de  $n$  observações independentes  $Z_1, Z_2, \dots, Z_n$ , cada uma como uma variância  $\sigma^2$ . A variância da media  $\bar{Z}$  das observações é dada por  $\sigma^2/n$ . Assim, para reduzir a variância e incrementar a precisão estatística de um método de aprendizado é necessário utilizar vários conjuntos de treinamento, construir modelos de predição separados para cada um,




Figura 5 – Visualização das árvores para classificação

e por fim realizar o cálculo da média dos resultados (JAMES et al., 2013).

Logo, com os modelos de predição  $\hat{f}^1(x), \hat{f}^2(x), \dots, \hat{f}^B(x)$  usando  $B$  conjuntos de treinamentos separadamente, e realizando a média para obtenção de um modelo de predição de baixa variância estatística, que pode ser representado pela Equação 2.24.

$$\hat{f}_{med}(X) = \frac{1}{B} \sum_{b=1}^B \hat{f}^b(x) \tag{2.24}$$

A falta de praticidade acarretada pela necessidade de acesso a múltiplos conjuntos de treinamento pode ser contornada utilizando *bootstrap*, onde pode-se selecionar repetidas amostras de um mesmo conjunto de treinamento, como mostra a Figura 6.




Figura 6 – Exemplificação de bootstrap

Com isso é possível gerar  $B$  conjuntos distintos para o treinamento, e assim treinar  $\hat{f}^{*b}(x)$  modelos. E ao fim, calcular a média de suas saídas, tendo sua representação matemática dada pela Equação 2.25.

$$\hat{f}_{bag}(X) = \frac{1}{B} \sum_{b=1}^B \hat{f}^{*b}(x) \tag{2.25}$$

Porém, a utilização do *Bagging* sozinho pode gerar diversas árvores semelhantes, caso existam atributos correlacionados e um deles seja dominante sobre os demais para a classificação de determinadas amostras. O que não é vantajoso, uma vez que diversas árvores de decisão selecionariam esse atributo dominante para quebra dos nós no começo da árvore. E a média de várias árvores de decisão altamente correlacionadas não acarretam em uma redução da variação total.

Para solucionar esse problema, cada operação de quebra dos nós leva em consideração uma quantidade aleatória de  $m$  atributos, escolhidos no conjunto total de  $p$  atributos. Logo, a quebra leva em consideração somente um desses  $m$  atributos. E uma nova quantidade de  $m$  atributos é selecionada para cada uma das próximas operações de quebra. Esse é o processo que descorrelaciona os atributos, uma vez que, em média,  $(p-m)/p$  atributos não serão considerados, e as árvores de decisão resultantes serão menos dependentes e, conseqüentemente, mais confiáveis.

E a partir da descorrelação dos atributos é possível extrair o fator de importância de cada atributo para a classificação.

Os parâmetros para a construção de uma RF são:

- Número de máximo de árvores;
- Tamanho mínimo para quebra de cada nós;
- Profundidade Máxima das árvores;
- Quantidade de atributos a serem considerados por quebra.
- Mínimo de ganho de informação para ocorrer a quebra. Auxilia a evitar o overfitting;
- Relação entre a quantidade de observações com repetição e a quantidade total de observações.

A complexidade de uma *RF* pode ser simplificada para a Equação 2.26, onde  $m$  é o número de árvores utilizadas na floresta,  $n$  é o número de instâncias utilizadas e  $v$  é o número de atributos utilizados por nó, não levando em consideração o processo de seleção dos atributos.

$$O(v * m * n \log(n)) \quad (2.26)$$

Quando limitada a altura da árvore a Equação 2.26 pode ser reescrita para a Equação 2.27, onde  $h$  é a altura limitante da árvore.

$$O(v * m * n * h) \quad (2.27)$$

## 2.4 Técnicas de Inteligência artificial

Técnicas de inteligência artificial são utilizadas de duas formas distintas no contexto de monitoramento de cargas não intrusivos: classificação das cargas e otimização nos métodos de identificação.

### 2.4.1 Identificação de cargas

Em (HART, 1992) e (GONÇALVES et al., 2010) foram utilizadas técnicas de aglomeração (*Clusters*) para a classificação dos equipamentos ligados ao circuito monitorado avaliando as potências ativas e reativas e plotando os resultados em um plano PQ (potência ativa-potência reativa). Redes neurais foram utilizadas em (ROOS et al., 1994) com a função de classificação dos eventos baseados também nas potências ativas e reativas das cargas monitoradas.

### 2.4.2 Otimização no método de identificação

Uma das técnicas utilizadas para otimização é a Otimização por Enxame de Partículas (*PSO- Particle Swarm Optimization*). Em (CHANG et al., 2013) é utilizada essa técnica de otimização para definir a "janela" de amostras na qual os dados são relevantes para classificação do equipamento. Outra técnica utilizada são os Algoritmos Genéticos (*Genetic Algorithms - GA*). Em (LIN; TSAI; CHEN, 2011) é utilizada para otimizar parâmetros em um classificador Fuzzy, e em (CHANG et al., 2011) é utilizado para otimizar a seleção dos parâmetros de classificação.

## 2.5 Detecção de Eventos

O processo inicial na maioria dos NILM's é a detecção de eventos, ou seja, detectar a ocorrência de variações na potência elétrica no circuito monitorado que indiquem o acionamento ou desligamento de um equipamento. Tipicamente, o processo de detecção de eventos pode ser abordado de três maneiras distintas (ANDERSON et al., 2012b) (BAETS et al., 2017): heurística especializada, modelos probabilísticos e filtros coincidentes.

Abordagem heurística especializada utiliza a elaboração de regras para detecção dos eventos, em geral tem poucos parâmetros que necessitam de ser ajustados inicialmente. Em (HART, 1992) e (FARINACCIO; ZMEUREANU, 1999) foram desenvolvidos detectores que necessitaram de ajustes prévios ao início do processo de identificação. A abordagem denominada Modelos Probabilísticos geram probabilidades para decidir se houve ou não a ocorrência de um evento. Para realizar tal ação é necessário um processo de treinamento para ajustar algumas variáveis, bem como aprendizado de modelos estatísticos para as cargas do circuito. Os dois modelos probabilísticos mais conhecidos e

amplamente utilizados com esse fim são o modelo de razão probabilístico generalizado (GLR - *Generalized Likelihood Ratio*) e o  $\chi^2$  *Godness-of-fit* ( $\chi^2$  GOF). Aplicações desses métodos podem ser observadas em (ANDERSON et al., 2012b), (BAETS et al., 2017) e (YANG; SOH; YAP, 2014). E os filtros coincidentes extraem as características da forma de onda do sinal de potência e o correlaciona com padrões conhecidos.

Para realizar a função de identificador de eventos no presente trabalho foi utilizada a abordagem heurística, utilizando cálculos estatísticos, conforme Seção 4.2.

## 2.6 Considerações Finais

Os trabalhos citados utilizam em sua maioria a classificação das cargas baseadas nas características das potências ativas e reativas de cada carga. Diferenciam-se no método aplicado para detecção de tais características, que mostra-se eficiente nos casos em que equipamentos distintos possuem a combinação de potências ativas e reativas distintas (GONÇALVES et al., 2010) e nos casos dos equipamentos monitorados serem de porte maior (alta potência consumida). As técnicas de otimização utilizadas impactam no desempenho na fase de treinamento dos algoritmos de classificação, e consequentemente na precisão das classificações.

Todos os *dataset* apresentados são densos e ricos na quantidade de dados, e o escolhido para ser utilizado foi o *BLUED*, devido a facilidade de acesso aos dados, ao tamanho reduzido quanto comparado aos demais e a boa taxa de amostragem utilizada.

O tipo de identificação de eventos abordado nesse trabalho é focado nos estados permanentes.

A abordagem de RF é interessante por levantar a importância das variáveis envolvidas no processo de classificação e possui uma boa capacidade de generalização devido ao *bootstrap*, como pode ser observado em outras aplicações onde há presença de muitas variáveis envolvidas (KUMAR; CHOUDHARY, 2012) (CHEN; ISHWARAN, 2012).

O novo padrão de potência da IEEE traz novas possibilidades para classificar os equipamentos monitorados, uma vez que calcula potências não senoidais no sinal.

### 3 Algoritmo de Otimização

Métodos de otimização possuem dois propósitos distintos. Um é a seleção de parâmetros para otimizar a performance de um sistema. Isto é, quando tem-se um sistema em funcionamento, e esse sistema depende de parâmetro, restritos ou não, que necessitam ser escolhidos por um operador, e a escolha apropriada ou não causa um desempenho melhor ou pior, que pode ser medido através de objetivos relevantes ou funções de avaliação (*fitness*). Em sistemas reais, geralmente a interação entre esses parâmetros nem sempre pode ser realizada analiticamente, logo o operador deve buscar técnicas apropriadas, visando a otimização do sistema, ou pelo menos uma aproximação de um ponto ótimo.

O segundo propósito é o de teste e avaliação de modelos quantitativos por processo iterativo. Isto é, um modelo é construído e, posteriormente, dados são coletados e utilizados para testar esse modelo através de uma função de *fitness*. O resultado pode ser chamado de função de erro (ou *misfit function*). E caso haja discrepância entre o modelo e os resultados, o modelo é modificado. Esse processo é repetido até que o problema seja resolvido, chegue a um limite de interações pré-estabelecido ou nenhuma resposta diferente seja encontrada (CHAMBERS, 2000).

Quando o processo de otimização é realizado em torno de um único objetivo, pode dizer que se trata de uma otimização simples (*Single Objective Optimization- SOP*), onde deve-se maximizar ou minimizar uma determinada função que consolida de forma genérica vários objetivos em um único. Esse tipo de otimização é útil para prover a ideia de como o problema se comporta, porém não fornece um conjunto de soluções que levam a diferentes resultados, onde cada qual otimiza a solução focando em diferentes objetivos.

No caso de diversos objetivos conflitantes, temos outro tipo de otimização, a otimização multi-objetivo (*Multi-Objective Optimization- MOP*), onde quase nunca existe uma única solução, mas sim um conjunto de soluções que geram uma combinação de soluções ótimas, chamada de fronteira de Pareto (SAVIC, 2002).

E para cada tipo de problema a ser otimizado existe um método de otimização mais adequado, dependente do tipo das variáveis de entrada, da possibilidade de uma modelagem matemática que represente o problema de forma fidedigna ou não, a possibilidade de utilização de determinados cálculos matemáticos (NARIÑO; MARTHA; MENEZES, 2014) (MARTI, 2005).

Os conceitos básicos numa otimização são:

- Variáveis de estado- são as características do sistema, sendo os parâmetros que são controlados para a otimização;

- Função Objetivo- é a função das variáveis de estado, na qual o desempenho da otimização é avaliado;
- Restrições- são as limitações que devem ser seguidas pelas variáveis de estado, nas quais o sistema viola condições pré-definidas ou indesejadas;
- Espaço de Busca- é a região ou espaço que engloba as soluções possíveis, delimitado pelas restrições;
- Ponto Ótimo- é a combinação das variáveis de estado que apresentaram melhor avaliação pela função objetivo;
- Valor Ótimo- é o resultado da função objetivo quando avaliada no ponto ótimo;
- Solução Ótima- é a combinação do valor ótimo e do ponto ótimo, podendo ser uma solução global ou local;

Dentre os diversos métodos de otimização, os modelos baseados em Enxame Inteligente (*Swarm Intelligence* - SI), termo inicialmente citado em (BENI, 1989), são bem explorados na literatura. Consiste de métodos que empregam uma população de indivíduos, sendo cada indivíduo a representação de uma combinação de variáveis de estado para um dado problema, e um ambiente que representa a função objetivo de um dado problema. E através da interação desses indivíduos entre si e com o ambiente buscam um ponto ótimo no ambiente em que estão, gerando assim uma solução ótima.

Alguns exemplos de algoritmos desse tipo de otimização são:

- Busca estocástica difusa (*Stochastic diffusion search*) (BISHOP, 1989)
- Enxame de Partículas (*Swarm Particle Optimization*- PSO) (EBERHART; KENNEDY, 1995)
- Colônia de Formigas (*Ant Colony Optimization* - ACO) (DORIGO; CARO, 1999)

Dentre os algoritmos de otimização SI, um dos mais utilizados é o PSO (MAVROVOUNIOTIS; LI; YANG, 2017), inspirado no comportamento de pássaros, que busca por soluções ótimas em problemas de D-dimensões. Assim como o PSO, a maioria dos algoritmos de enxame inteligente são bio-inspirados, isto é, a ideia básica do processo de otimização que utilizam foi retirado da observação do comportamento de colônias de animais, insetos e outros seres vivos na natureza.

Um outro algoritmo mais recente, porém não bio-inspirado, é a otimização por Fogos de Artifício (*Fireworks Algorithm*- FA), inspirado na explosão de fogos de artifício, proposto em (TAN; ZHU, 2010). Esse será o algoritmo utilizado nesse trabalho para a

otimização dos parâmetros do classificador escolhido, e será detalhado seu método de funcionamento na seção 3.1.

### 3.1 Algoritmo de Fogos de Artifício- FA

O algoritmo parte da explosão de fogos de artifícios em locais aleatórios, e uma porção de faíscas (*sparks*) preenche o espaço em volta de cada local das explosões. O processo de explosão realiza uma busca ao redor de um ponto específico. O algoritmo utiliza N vetores de parâmetros de D-dimensões  $x_i^G$  como a população básica de cada geração. O parâmetro i varia de 1 a N e o parâmetro G é o indicador das gerações.

Cada indivíduo na população passa pelo processo de explosão, gerando consequentemente faíscas ao redor de si. E as duas melhores faíscas são selecionadas para a próxima geração.

São apresentadas mais a fundo as estratégias de explosão na seção 3.1.1, mapeamento na seção 3.1.2, fagulhas gaussianas na seção 3.1.3 e seleção na seção 3.1.4.

#### 3.1.1 Explosão

Em um show pirotécnico podem ser observados dois possíveis comportamentos dos fogos de artifício. Quando bem confeccionados, uma grande quantidade de fagulhas são geradas ao redor da explosão inicial, e quando mal confeccionados, apenas algumas fagulhas são geradas bem dispersas do ponto de explosão. A mesma lógica é utilizada no FA, quando a explosão é realizada em uma área promissora, ou seja, próxima a um ponto ótimo, haverá diversas faíscas próximas desse ponto, gerando um bom fogo de artifício (Figura 7a). Porém, caso a explosão tenha ocorrido longe de um ponto ótimo, processo de dispersão das faíscas será maior, gerando um fogo de artifício ruim (Figura 7b) (TAN et al., 2013).

Supondo um FA, implementando uma minimização de um problema como expressa pela equação 3.1:

$$\min f(x), x_{min} \leq x \leq x_{max} \quad (3.1)$$

onde  $f(x)$  é a função *fitness* a ser minimizada,  $x = x_1, x_2, \dots, x_d$  são as localizações no espaço,  $x_{min}$  e  $x_{max}$  são os limites do espaço de busca.

Quando uma faísca explode, essa faísca é extinta e outras aparecem ao redor de onde estava. A estratégia de explosão parte dessa ideia para produzir novos indivíduos por explosão. Existem dois parâmetros que necessitam ser determinados. O primeiro é o



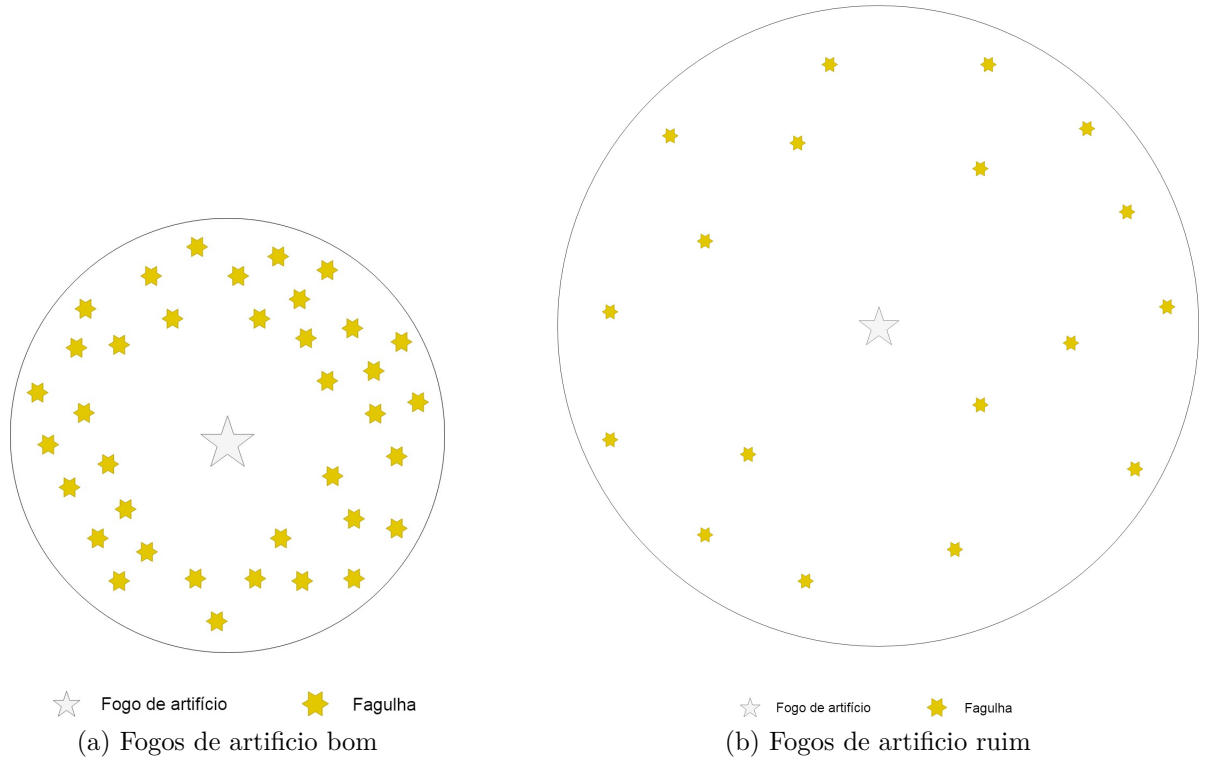


Figura 7 – Demonstração dos processos de explosão de fogos de artifício

número de faíscas, definido pela equação 3.2.

$$S_i = \hat{S} * \frac{Y_{max} - f(x_i) + \varepsilon}{\sum_{i=1}^N (Y_{max} - f(x_i) + \varepsilon)} \quad (3.2)$$

Na Equação 3.2,  $S_i$  representa o número de faíscas geradas por indivíduo na população,  $i$  varia de 1 a  $N$ . Para controlar o número total de faíscas  $\hat{S}$  é mantido constante. Supondo que o objetivo da otimização seja minimizar a função, a variável  $Y_{max}$  representa a pior valor da função *fitness* na geração atual, e  $f(x_i)$  representa o valor da função *fitness* do indivíduo  $x_i$ . O último parâmetro ( $\varepsilon$ ) serve exclusivamente para evitar que o denominador se torne zero.

De acordo com (TAN; ZHU, 2010) resultados não muito satisfatórios são encontrados se  $S_i$  é muito grande. Então, para evitar isso, é necessário criar limites para  $S_i$  segundo a equação 3.3.

$$S_i(x) = \begin{cases} (\alpha \cdot \hat{S}), & \text{se } S_i < \alpha \cdot \hat{S}. \\ (\beta \cdot \hat{S}), & \text{se } S_i > \beta \cdot \hat{S}. \\ \hat{S}, & \text{Caso contrário} \end{cases} \quad (3.3)$$

Onde  $\alpha$  e  $\beta$  são constantes e  $\alpha < \beta < 1$ . Valores típicos e com bons resultados experimentais são  $\alpha=0,04$  e  $\beta=0,8$ , segundo teste realizados em (TAN; ZHU, 2010).

O segundo parâmetro nessa estratégia é amplitude das faíscas, dada pela Equação 3.4.

$$A_i = \hat{A} * \frac{f(x_i) - Y_{min} + \varepsilon}{\sum_{i=1}^N (f(x_i) - Y_{min} + \varepsilon)} \quad (3.4)$$

Na Equação 3.4,  $A_i$  representa amplitude de um indivíduo  $x_i$  para gerar a explosão e para controlar a amplitude máxima  $\hat{A}$  é mantido constante. O melhor valor da função *fitness*  $Y_{min}$  na geração atual é usado para calcular a amplitude. O último parâmetro ( $\varepsilon$ ) serve exclusivamente para evitar que o denominador se torne zero. Um indivíduo que esteja muito próximo das fronteiras do problema, pode ocorrer de uma faísca ser gerada fora do espaço de busca. Nesse caso, o método de mapeamento é utilizado para manter a faísca dentro do espaço de busca.

Além da estratégia de explosão, outra estratégia para gerar faísca é utilizada, a estratégia de faíscas gaussianas, que será discutida na Seção 3.1.3.

### 3.1.2 Mapeamento

A estratégia de mapeamento garante que todos os indivíduos gerados permaneçam no espaço de busca. Caso apareçam indivíduos fora do espaço de busca, eles são mapeados para dentro do espaço de busca através da equação 3.5.

$$x_i = x_{min} + |x_i| \% (x_{max} - x_{min}) \quad (3.5)$$

onde  $x_i$  representa a posição de uma faísca que aparece fora do espaço de busca,  $x_{min}$  e  $x_{max}$  são os valores de máximo e mínimo, respectivamente, do espaço de busca que uma faísca pode assumir. O símbolo % representa o resto da divisão inteira.

### 3.1.3 Faíscas Gaussianas

Com a finalidade de manter a diversidade entre os indivíduos de uma população, a estratégia de faísca gaussiana é utilizada para gerar faíscas com distribuição gaussiana. Supondo que a posição atual de um indivíduo seja dada por  $x_k^j$ , a faísca gaussiana é dada pela equação 3.6:

$$x_k^j = x_k^j * g \quad (3.6)$$

onde  $g$  é um número aleatório na distribuição gaussiana, como mostra a equação 3.7:

$$g = \text{Gaussiana}(1, 1) \quad (3.7)$$

O parâmetro  $g$  segue uma distribuição gaussiana com valor médio e desvio padrão iguais a 1.

Após a explosão normal e a criação das faíscas gaussianas, é necessário escolher os indivíduos para a próxima geração. Usualmente, utiliza uma seleção baseada na distância.

### 3.1.4 Seleção

Na seleção dos indivíduos para a próxima geração, o melhor indivíduo, o que teve melhor valor na função *fitness*, é sempre selecionado primeiro. Depois os próximos  $(N - 1)$  indivíduos são selecionados com base na distância aos demais. Os indivíduos mais distantes dos demais tem maior chance de serem selecionados em relação os mais próximos dos demais.

A distância geral entre duas posições no espaço pode ser calculada segundo a equação 3.8.

$$R(x_i) = \sum_{j \in K} d(x_i, x_j) = \sum_{j \in K} \|x_i - x_j\| \quad (3.8)$$

onde as posições  $x_i$  e  $x_j$  ( $i \neq j$ ) podem ser quaisquer posições e  $K$  é o conjunto de todas as posições atuais. Para o cálculo das distâncias pode ser utilizado qualquer método, tais como distância Euclidiana e distância Manhattan. Em (TAN; ZHU, 2010) foi utilizada distância euclidiana, como pode ser observada pela equação 3.9.

$$d(x_i, x_j) = |f(x_i) - f(x_j)| \quad (3.9)$$

onde  $f(x_i)$  é a equação *fitness* para a posição  $x_i$  e  $d(x_i, x_j)$  representa a distância entre duas posições.

E, por último, é calculada a possibilidade de selecionar uma posição baseada na distância da posição em relação a somatória das posições de todas as posições, como mostra a equação 3.10. O método de seleção da roleta foi aplicado para selecionar as posições baseado nas suas probabilidades.

$$p(x_i) = \frac{R(x_i)}{\sum_{j \in K} R(x_j)} \quad (3.10)$$

Assim, os indivíduos com grande distância dos demais tem maior chance de serem selecionados. Desse modo, garante-se a diversidade da população.

O fluxograma 8 resume o funcionamento do FA.

## 3.2 Considerações Finais

FA cumpre três das quatro necessidades do usuário sugeridas em (STORN; PRICE, 1997), que são:

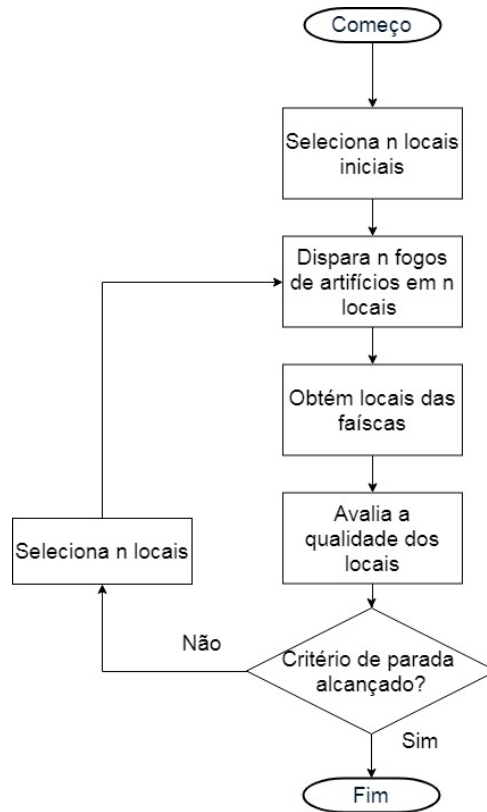


Figura 8 – Fluxograma FA

- Processar funções lineares, não-lineares e multi-modelos;
- Pode ser paralelizado com a finalidade de lidar com a complexidade dos problemas;
- Possui boas propriedades de convergência e sempre encontra um mínimo.

A complexidade desse algoritmo pode ser aproximada a partir da quantidade de gerações ( $G$ ), número de fogos de artificios ( $N$ ), número de faiscas produzidas pela estratégia de explosão normal ( $m$ ) e o número de faiscas produzidas pela estratégia de faiscas gaussianas ( $\hat{m}$ ), sendo reduzida a  $O(G * (N + m + \hat{m}))$  (TAN; ZHU, 2010).

## 4 Metodologia Proposta

A metodologia proposta envolve a leitura do *dataset* escolhido (*BLUED*), cálculo das potências elétricas segundo (IEEE, 2010), identificação dos eventos utilizando a ferramenta estatística desenvolvida e otimizada, seleção dos intervalos dos eventos ocorridos no *dataset* para extração das variações nas características elétricas, seleção dos eventos a serem utilizados no treinamento do classificador, treinamento do classificador *RF* utilizando o algoritmo de otimização *FW* e construção da matriz de confusão. A Figura 9 ilustra o esquema da metodologia proposta, dividida em três etapas. Todas as rotinas foram implementadas em *C#*

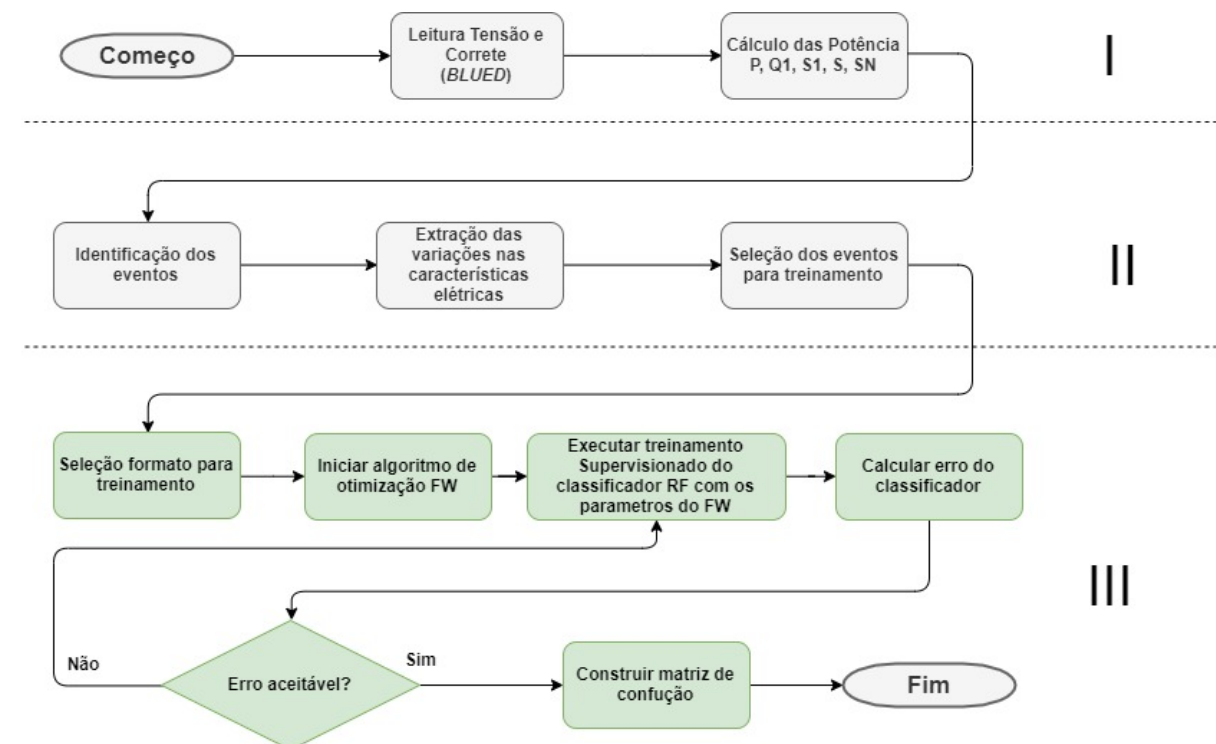


Figura 9 – Fluxograma da metodologia proposta

A escolha da RF como classificador deu-se pela facilidade da implementação da técnica em dispositivos embarcados, pela velocidade de resposta a cada nova entrada e pela baixa variância de suas respostas. A técnica de otimização FA foi escolhida pela baixa quantidade de parâmetros de ajuste e de trabalhos relacionados a área de NILM e RF.

### 4.1 Etapa I- Pré-processamento dos dados

Nessa fase ocorre o pré-processamento dos dados do *dataset*. Cada amostra no *dataset* contém informação sobre o instante da medição ( $t$ ), corrente na fase A ( $I_A$ ),

corrente na fase B ( $I_B$ ) e tensão na fase A ( $V_A$ ). Os dados de tensão e corrente devem ser utilizados para calcular as potências segundo as Equações na seção 2.2.

#### 4.1.1 Cálculo das potências do *dataset*

Para os cálculos das potências associadas a fase B foi necessário o cálculo da tensão B ( $V_B$ ), sendo defasado em  $180^\circ$  graus da tensão A ( $V_A$ ), sendo assim,  $V_B$  pode ser representado pela equação 4.1.

$$V_B = -V_A \quad (4.1)$$

As amostras dos dados podem ser utilizadas de duas formas distintas para os cálculos das potências: contínua ou por ciclo. Na forma contínua são utilizadas  $n$  amostras para calcular a potência em um período  $t$ , e no cálculo da potência no período  $t + 1$  é removido a amostra mais antiga e adicionada uma nova para o novo cálculo, como pode ser observado na equação 4.2.

$$\begin{aligned} p(t) &= v(0) * i(0) + v(1) * i(1) + \dots + v(n) * i(n) \\ p(t + 1) &= v(1) * i(1) + v(2) * i(2) + \dots + v(n + 1) * i(n + 1) \end{aligned} \quad (4.2)$$

Já na forma por ciclos o cálculo de uma potência no período  $t$  utiliza  $n$  amostras, e no cálculo da potência no período  $t + 1$  são removidos as  $n$  amostras e adicionadas novas  $n$  amostras, como pode ser observado na Equação 4.3.

$$\begin{aligned} p(t) &= v(0) * i(0) + v(1) * i(1) + \dots + v(n) * i(n) \\ p(t + 1) &= v(n + 1) * i(n + 1) + v(n + 2) * i(n + 2) + \dots + v(2n) * i(2n) \end{aligned} \quad (4.3)$$

Ambas as formas de cálculo para qualquer potência em qualquer instante é necessário pelo menos um ciclo completo de amostras, sendo assim,  $n$  necessita ser pelo menos 200 para o *dataset* utilizado (com frequência de aquisição de 12 khz).

Para os cálculos das potências fundamentais são necessários aplicações de filtros para eliminar frequências diferentes da fundamental (60 hz para o presente *dataset*). Um filtro *Notch* foi utilizado para remover a frequência desejada dos dados de entrada e os resultados são removidos dos dados originais, resultando nos dados contendo somente a frequência fundamental, como pode ser observado na Figura 3. O filtro necessita de um número mínimo de amostras para conseguir filtrar corretamente a frequência desejada.

#### 4.1.2 Filtro de média móvel

A aplicação de um filtro para as potências calculadas é necessária para eliminar variações rápidas e curtos intervalos de tempo, tais como variações normais no sinal e ruídos, o que pode dificultar no processo de identificação dos eventos (abordado em 4.2).

O filtro mais indicado para essa aplicação é o filtro de média móvel que suaviza a curva das potências calculadas, utilizando a equação 4.4.

$$P(i) = \frac{1}{N} \sum_{n=0}^N P(i+n) \quad (4.4)$$

A ação do filtro pode ser observada na Figura 10, que apresenta o sinal original (Figura 10a) e o resultado de configurações diferentes para o filtro móvel (Figura 10b, Figura 10c e Figura 10d).

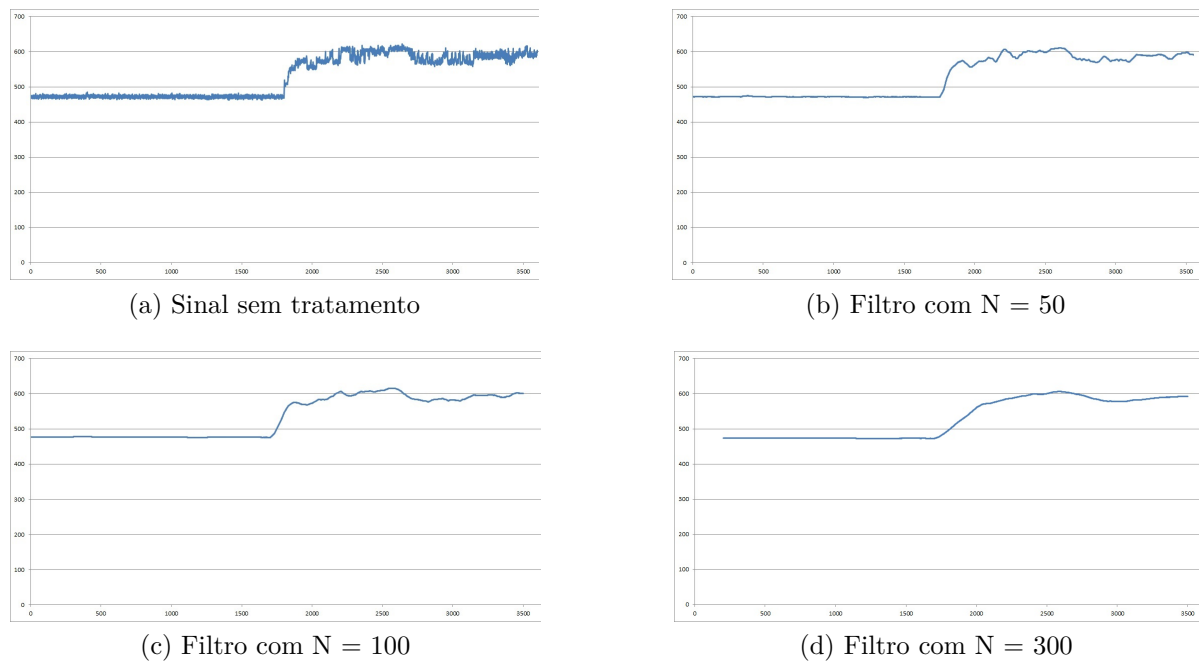


Figura 10 – Aplicação do filtro de média móvel

O parâmetro  $N$  do filtro é otimizado através do *FWA* de forma melhorar o desempenho do identificador, almejando a minimização do erro de identificador.

## 4.2 Etapa II - Identificação da ocorrência de eventos

Para a função de identificação de eventos desenvolvida foram utilizadas janelas de análise dos dados de uma série temporal e cálculos estatísticos, semelhante aos desenvolvidos em (ANDERSON et al., 2012b), porém sem o sistema probabilístico de votação.

Os princípios utilizados na abordagem desenvolvida baseia-se na utilização de janelas flutuantes (que se deslocam a partir de um ponto fixo), filtros de média móveis e análise da variância das medidas entre as janelas para detecção da ocorrência de eventos buscando seus estados de estabilidades (antes e depois de sua atuação). Esses princípios serão descritos na seção 4.2.1.

### 4.2.1 Cálculos estatísticos

Para cada conjunto de dados analisados a média do conjunto necessita ser calculada segundo a equação 4.5:

$$\bar{P} = \frac{1}{k} \sum_{i=1}^k P_i \quad (4.5)$$

onde:

$\bar{P}$  é a média aritmética das potências no intervalo de tempo analisado;

$P_i$  é i-ésima potência do conjunto;

$k$  é a quantidade de amostras no intervalo de tempo analisado;

Utilizando a média do conjunto analisado é possível calcular a variância dos valores utilizando a formula 4.6 :

$$\sigma^2 = \frac{1}{k} \sum_{i=1}^k (\bar{P} - P_i)^2 \quad (4.6)$$

onde:

$\sigma^2$  é a variância das medidas no intervalo de tempo analisado;

$\bar{P}$  é a média das potências no intervalo de tempo analisado;

$P_i$  é i-ésima potência do conjunto;

$k$  é a quantidade de amostras no intervalo de tempo analisado;

### 4.2.2 Janelas flutuantes

A proposta de identificação por janelas flutuantes se baseia inicialmente no monitoramento das potências utilizadas para identificação das cargas. Um *buffer* de potências é preenchido com  $n$  amostras de potências sequenciais (quantidade  $n$  suficiente para detectar-se o evento de maior tempo de acionamento ou desligamento de carga possível). Um pivô é utilizado para referenciar um ponto específico do *buffer* (para todos os experimentos foi utilizado o centro do *buffer*), e as janelas pré e pós eventos de tamanhos previamente definidos ( $w_{pre}$  e  $w_{pos}$ ) foram alocadas adjacentes ao pivô inicialmente. Quando detectada uma variação mínima de potência maior que um limite pre-definido ( $P_{thr}$ ), como mostra a equação 4.7, é considerado inicialmente que um evento ocorreu nesse instante. A confirmação desse evento é feita através do deslocamento das janelas pré e pós no sentido de distanciar-se do pivô a uma distância pré-definida máxima ( $dist_{max}$ ).

$$|P_{pos} - P_{pre}| > P_{thr} \quad (4.7)$$



Para cada nova posição assumida pelas janelas, suas médias e variâncias são calculadas. O ponto onde cada janela (pré e pós evento) apresenta menor variância são utilizados para confirmar se foi possível detectar evento para o instante em análise. São realizadas comparações com as variâncias limites ( $\sigma_{limite}^2[i]$ ), sequencialmente, conforme a equação 4.8.

$$\sigma_{limite}^2[0] < \sigma_{limite}^2[1] < \sigma_{limite}^2[2] < \sigma_{limite}^2[3] \quad (4.8)$$

A fim de evitar que um mesmo evento seja indicado novamente como uma nova ocorrência do mesmo evento ao mover o pivô para a próxima posição foi definido um salto do pivô, de forma que sua nova posição seria tal que a janela anterior ( $w_{pre}$ ) estivesse na posição da janela pós ( $w_{pos}$ ) do ponto de estabilidade do evento detectado. Esse procedimento pode ser observado no exemplo da Figura 11.

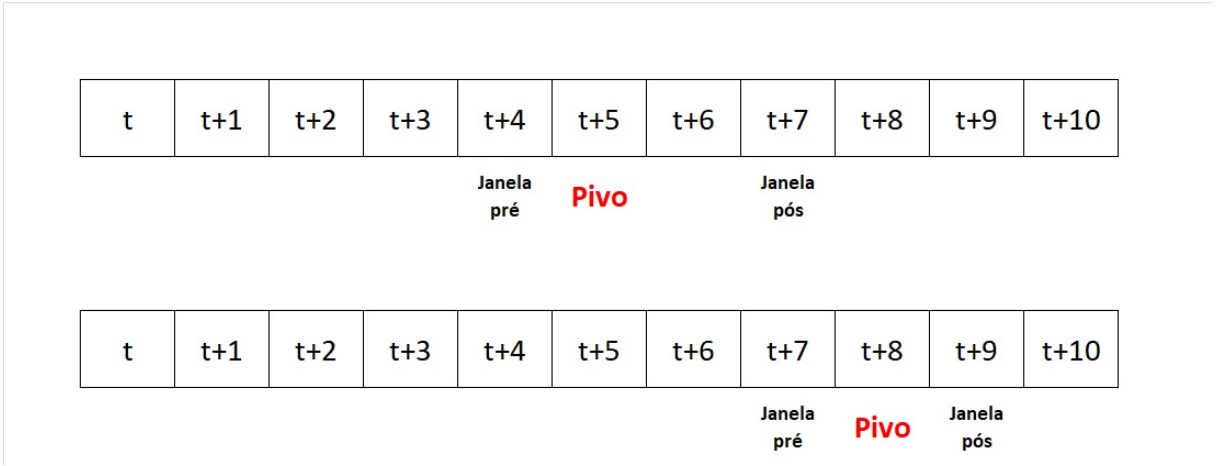


Figura 11 – Processo de salto do pivô

A Figura 12 exemplifica uma sequência de potências calculadas no tempo (12a), onde é possível visualizar em 13b o início do processo de busca por regiões estáveis, onde o pivô é indicado pela linha roxa e as janelas pré e pós são indicados pelo espaço entre as linhas verdes, adjacente inicialmente entre si. Em 12c visualiza-se o final do processo, onde as janelas se deslocaram para longe do pivô, até atingir regiões estáveis (baixas variâncias) nas extremidades.

Os parâmetros  $\sigma_{thrpre}^2$  e  $\sigma_{thrpos}^2$  foram otimizados focando em minimizar o erro da identificação de eventos, e os parâmetros  $w_{pre}$ ,  $w_{pos}$  e  $dist_{max}$  foram escolhidos de forma experimental. O otimizador enxame de partícula foi escolhido por conveniência.

A complexidade do algoritmo é  $O(N^2)$ , uma vez que há uma busca no vetor com as amostras pelo instante com uma variação de potência maior que o  $P_{Thr}$  e outra busca dentro dessa para buscar as zonas de estabilidade anterior e posterior.

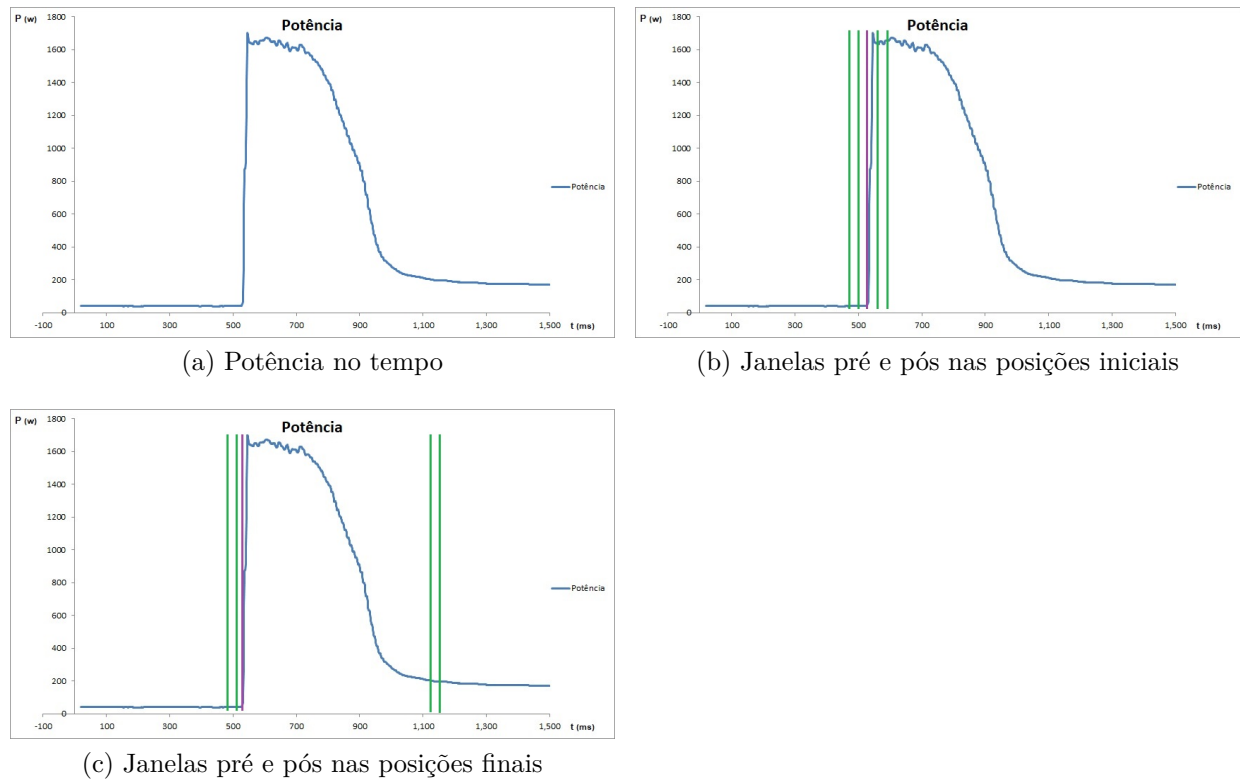


Figura 12 – Janelas flutuantes

### 4.2.3 Extração das características dos eventos

Durante o processo de identificação da ocorrência de eventos as janelas utilizadas ao redor do pivô contêm as potências calculadas para esses instantes. A diferença entre essas potências forneceram as características elétricas adicionadas ou removidas com o acionamento ou remoção de um equipamento qualquer ao sistema monitorado. Para simplificar o processo de classificação os valores absolutos das características elétricas foram utilizados, reduzindo dimensão do problema. Porém, isso gera a perda da informação se a carga foi adicionada ou retirada do sistema.

### 4.2.4 Seleção dos eventos para o treinamento

O *dataset BLUED* possui mais de 35 circuitos monitorados e demarcados (com *labels*), porém dentre esses apenas 28 desses circuitos representam uma única carga. Os *labels* e equipamentos podem ser observados na tabela 40 no anexo A.

Os *labels* superiores a 204 indicam circuitos que possuem mais de um equipamento ligado a eles ou equipamentos desconhecidos. Logo, eles não podem e não foram utilizados na fase de treinamento, pois introduziriam erros no treinamento no algoritmo de classificação uma vez que as características elétricas que representam e os *labels* não refletiriam em um único equipamento.

Outros eventos que não foram selecionados para a fase de treinamento são os de eventos que ocorreram simultaneamente, uma vez que as características elétricas podem ficar mascaradas devido a sobreposição dos eventos. Esses eventos em situações reais em uma única residência tem baixa probabilidade de acontecerem (menos de 1,5% no *dataset* utilizado).

### 4.3 Etapa III - Treinamento e Classificação

Essa etapa consiste na seleção do formato para o treinamento, no treinamento e otimização do classificador *RF* e análise do desempenho do classificador.

#### 4.3.1 Seleção do formato para treinamento

A forma de dispor dos dados a serem utilizados impacta diretamente no desempenho do classificador. Para avaliar a melhor forma de dispor os dados são testadas 4 formas diferentes, sendo elas:

- Variação das características elétricas (VCE)
- Forma de onda simples (FOS)
- Forma de onda deslocada (FOD)
- Taxa de variação das ondas (TVO)

E também é avaliado a desempenho dessas formas de disposição dos dados quando ocorre um agrupamento de classes com características elétricas similares.

A variação das características elétricas baseia-se na utilização da variação de cada uma das características elétricas antes e após o evento. Para fins de diminuição da ordem de complexidade do problema, os sinais são desconsiderados. As variações das características são dispostas em uma tabela (1). Esse processo pode ser observado na Figura 13.

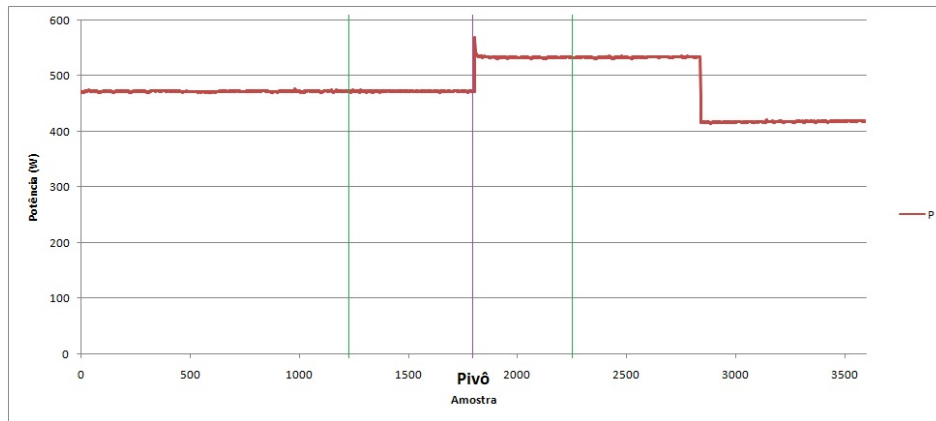
$\Delta I$	$\Delta V$	$\Delta I1$	$\Delta V1$	$\Delta P$	$\Delta Q1$	$\Delta S$	$\Delta S1$	$\Delta Sn$	Classe
------------	------------	-------------	-------------	------------	-------------	------------	-------------	-------------	--------

Tabela 1 – Disposição dos dados na tabela para treinamento


Para os demais modos de disposições dos dados um intervalo de tempo é selecionado ao redor do pivô, os dados são dispostos sequencialmente, como demonstrado na tabela 2, onde  $i$  é o início e  $n$  é o final do intervalo analisado.

$I(i \rightarrow n)$	$V(i \rightarrow n)$	$I1(i \rightarrow n)$	$V1(i \rightarrow n)$	$P(i \rightarrow n)$	$Q1(i \rightarrow n)$	$S(i \rightarrow n)$	$S1(i \rightarrow n)$	$Sn(i \rightarrow n)$
----------------------	----------------------	-----------------------	-----------------------	----------------------	-----------------------	----------------------	-----------------------	-----------------------

Tabela 2 – Disposição dos dados na tabela para treinamento com a forma de onda simples



(a) Gráfico da potência no tempo, com pivô e intervalos



(b) Janelas pré e pós nas posições iniciais

Figura 13 – Exemplo da disposição dos dados utilizando a variação das características elétricas

Na forma de onda simples, nenhum tratamento é necessário nos dados utilizados.

Na forma de onda deslocada, a onda é deslocada verticalmente baseando esse deslocamento no ponto onde o pivô se encontra, movendo-o para o ponto zero, como pode ser observado na Figura 14.

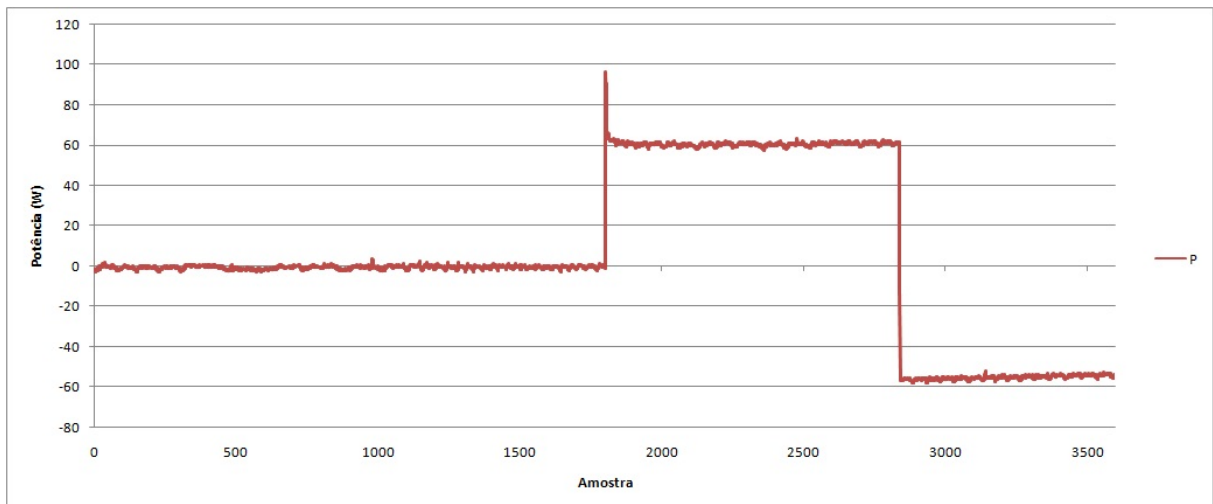


Figura 14 – Exemplo da disposição dos dados utilizando a forma de onda deslocada

Na taxa de variação das ondas, um intervalo de tempo é selecionado ao redor do pivô e é calculada a taxa de variação nesse intervalo, como pode ser observado na Figura 15.

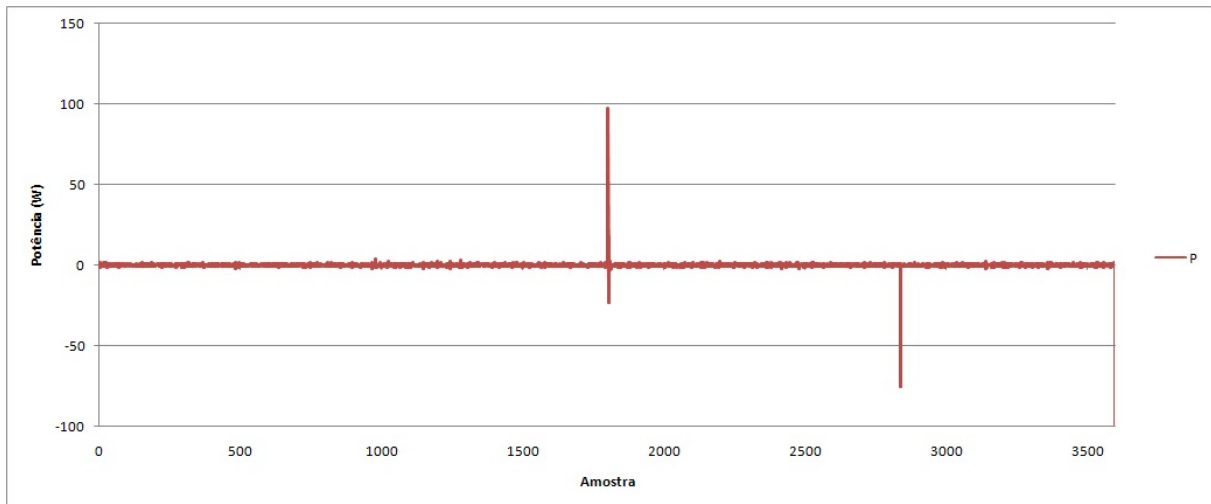


Figura 15 – Exemplo da disposição dos dados utilizando a taxa de variação das curvas

### 4.3.2 Otimização do classificador utilizando o FA

A otimização do classificador é realizada *off-line* otimizando parâmetros de construção da RF, sendo eles:

- *Trees*;
- *Maximum Tree Depth*;
- *Feature Per Split*;
- *Sub Sample Ratio*;

O algoritmo de otimização utilizado é o FWA (apresentado em 3.1) e posteriores comparações com outros métodos de otimização são realizadas. O objetivo da otimização é minimizar o erro de classificação, focado no cálculo da acurácia do sistema.

### 4.3.3 Desempenho do classificador

O desempenho do classificador foi avaliado através da matriz de confusão. A matriz demonstra os resultados através do agrupamento das saídas do classificador segundo os seguintes conceitos (PROVOST; KOHAVI, 1998):

- Verdadeiro Positivo (*true positive* - TP): Evento classificado e corresponde a realidade;
- Verdadeiro Negativo (*true negative* - TN): Evento não classificado corresponde a não existência com o real;
- Falso Positivo (*false positive* - FP): Evento classificado, porém erroneamente com a realidade;

- Falso Negativo (*false negative* - FN): evento não classificado, porém existente na realidade;

Com esses conceitos é possível calcular métricas para indicar o desempenho do classificador, sendo eles:

- Acurácia - Calcula a proporção de classificações corretas, sem discriminar se é verdadeiro positivo ou verdadeiro negativo, em relação a todos os dados, como mostra a equação 4.9;

$$Acurácia = \frac{TP + TN}{TP + FP + TN + FN} \quad (4.9)$$

- Sensibilidade (*Recall*) - Calcula a proporção de verdadeiros positivos em relação a todos os positivos, como mostra a equação 4.10. Assume também o nome de porcentagem de verdadeiros positivos (TPP-*True Positive Percentage*). Demonstra a capacidade do sistema em classificar corretamente a ocorrência de um determinado evento.

$$Sensibilidade = \frac{TP}{TP + FN} \quad (4.10)$$

- Especificidade (*Specificity*)- Calcula a proporção de verdadeiros negativos em relação a todos os negativos, como mostra a equação 4.11. Demonstra a capacidade do sistema em classificar corretamente a ausência de eventos.

$$Especificidade = \frac{TN}{TN + FP} \quad (4.11)$$

- Precisão - Calcula a proporção de identificações positivas corretas em relação ao total de eventos positivos, como mostra a equação 4.12.

$$Precisão = \frac{TP}{TP + FP} \quad (4.12)$$

- Eficiência - Calcula a média aritmética da Sensibilidade e da Especificidade, como mostra a equação 4.13.

$$Eficiência = \frac{Sensibilidade + Especificidade}{2} \quad (4.13)$$

- Porcentagem de Falsos Verdadeiros (FPP-*False Positive Percentage*)- Calcula porcentagem de falsos verdadeiros em relação a quantidade total de eventos negativos, como mostra a equação 4.14.

$$FPP = \frac{FP}{FP + TN} \quad (4.14)$$

- F-Score - Conhecida também como F1-Score, calcula a média harmônica da precisão e da sensibilidade, como mostra a equação 4.15.

$$F - Score = 2 * \frac{Precisão * Sensibilidade}{Precisão + Sensibilidade} \quad (4.15)$$

O erro do sistema também é calculado com a distância euclidiana do ponto ótimo para o ponto formado por (FPP,TPP), como pode ser observado na Equação 4.16, método implementado inicialmente em (ANDERSON et al., 2012b) e utilizado para comparação dos resultados. O ponto ótimo é dado por (0,1), pois tem-se 0% falsos positivos e 100% de verdadeiros positivos. Quanto menor o resultado, mais próximo do ponto ótimo, consequentemente, melhor o desempenho do identificador.

$$Erro = \|(0, 1) - (FPP, TPP)\| \quad (4.16)$$

Ou como alternativa, pode-se utilizar 4.17 para calcular o desempenho.

$$\begin{aligned} \hat{\psi} &= 1 - Erro \\ &= 1 - \|(0, 1) - (FPP, TPP)\| \end{aligned} \quad (4.17)$$

## 5 Resultados

A avaliação das metodologias propostas foram realizadas das seguintes maneiras:

- Otimização dos parâmetros para a identificação de ocorrência de eventos utilizando uma parte dos dados do *dataset*;
- Validação dos parâmetros otimizados para a identificação de ocorrência de eventos no *dataset* completo;
- Análise das possíveis fontes de erro do processo de identificação;
- Avaliação de qual formato dos dados provê melhor resultados para a classificação;
- Otimização dos parâmetros do classificador;
- Avaliação do desempenho do método com parâmetros otimizados;
- Análise das possíveis fontes de erro do processo de classificação;

As características do equipamento utilizado para a realização dos teste são:

- Processador Intel i5-3230M 2,60 GHz;
- Memória RAM de 8,00 GB;
- Sistema operacional Windows 7 Ultimate.

### 5.1 Detecção de evento

Pelo fato do *dataset* ser muito extenso, o processo de otimização foi realizado em um segmento dele, escolhido observando principalmente a quantidade de eventos na fase B, devido a complexidade de detecção dos eventos das cargas e a quantidade de ruído presente nessa fase. O segmento escolhido contém os arquivos numerados de 1601 e 2000, que correspondem ao intervalo de tempo do dia 22/10/2011 entre 06:40:00 e 17:00:00. O total de eventos presente nesse intervalo é 311 eventos, sendo 36 na fase A e 275 na fase B.

Os parâmetros utilizados no PSO foram:

- Máximo de interações =20;
- Número de partículas =16;



- Peso para melhor partícula local =2;
- Peso para melhor partícula global=2.

Os parâmetros do melhor indivíduo na otimização foram:

- $N_A = 50$ ;
- $\sigma_{ThrPreA}^2 = 0,01$ ;
- $\sigma_{ThrPosA}^2 = 0,0033$ ;
- $N_B = 200$ ;
- $\sigma_{ThrPreB}^2 = 0,01$ ;
- $\sigma_{ThrPosB}^2 = 0,0033$ ;

Como definido pela Equação 4.8 os limites das variância ( $\sigma_{limite}^2$ ) tem como base o valor otimizado, assumindo os seguintes valores:

- $\sigma_{limite}^2[0] = \sigma_{Thr}^2$ ;
- $\sigma_{limite}^2[1] = 3 * \sigma_{limite}^2[0]$ ;
- $\sigma_{limite}^2[2] = 6 * \sigma_{limite}^2[0]$ ;
- $\sigma_{limite}^2[3] = 12 * \sigma_{limite}^2[0]$ ;


Na tabela 3 apresenta a matriz de confusão para os resultados do melhor candidato a partir da otimização dos parâmetros  $N_A$ ,  $\sigma_{ThrPreA}^2$ ,  $\sigma_{ThrPosA}^2$ ,  $N_B$ ,  $\sigma_{ThrPreB}^2$ ,  $\sigma_{ThrPosB}^2$ .

	Detectado A	$\overline{DetectadoA}$	Detectado B	$\overline{DetectadoB}$
Evento	34	2	259	16
$\overline{Evento}$	3	2444	197	917

Tabela 3 – Matriz de Confusão para o processo de otimização da identificação

A tabela 3 representa as matrizes de confusão para o processo de teste com o melhor candidato da otimização. Como pode ser observado o total de ocorrência de evento (Evento) na Fase A é 36 ( $TP+FN$ ) e na Fase B é 275 ( $TP+FN$ ). O total de não ocorrência de evento ( $\overline{Evento}$ ) foi aproximado a partir do tempo total do fragmento do (dataset), levando em consideração o evento com maior tempo de transição. Logo, a quantidade de não eventos é igual ao tempo total monitorado segmentado em intervalos de 15 segundos menos o número de ocorrência de eventos. Isto gerou para a fase A 2444 não eventos e 917 para a fase B.

A Figura 16a e a Figura 16b mostram o deslocamento das janelas (linhas verdes) em relação ao pivô (linhas roxas). Na Figura 16a nota-se um deslocamento da janela pós que ultrapassa o pico de consumo de energia, alcançando uma posição com variância baixa ( $< 0,4$ ) indicando uma região estável na região pós evento, e na região anterior, a janela basicamente não se moveu, uma vez que já atendia o parâmetro de baixa variância. Na Figura 16b o processo é semelhante, porém sem o pico de consumo, facilitando o processo de localização das zonas de estabilidade em torno do pivô.



(a) Evento de uma carga com pico de energia.

(b) Evento de uma carga sem pico de energia.

Figura 16 – Exemplo de eventos identificados na fase A.

A Figura 17 mostra um caso que o algoritmo foi capaz de localizar, com boa precisão, zonas de estabilidade pós evento mesmo quando o evento em questão leve um grande tempo para estabilizar.

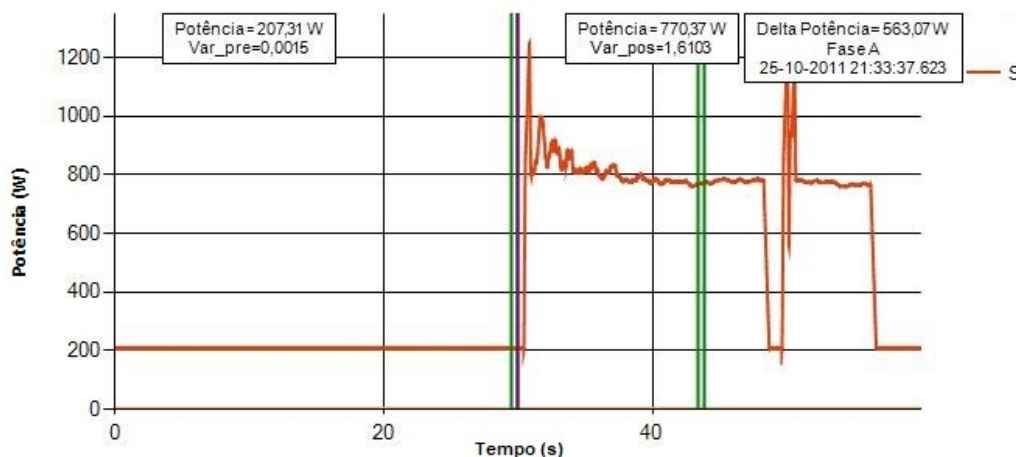


Figura 17 – Evento com longo tempo para estabilizar consumo de energia.

A Figura 18a e a Figura 18b mostram o mesmo processo na fase B. Nota-se a presença de ruído na potência, que faz com que a variância nas janelas pré e pós sejam mais altas que na Figura 16a e na Figura 16b. Outra característica visível é um maior deslocamento das janelas pré e pós em relação ao pivô, devido a busca por uma região de menor variância.

O mesmo processo que possibilitou localizar as zonas de estabilidade no caso da Figura 17, a janela flutuante, gerou os erros mostrado na Figura 19a e na Figura 19b. Na

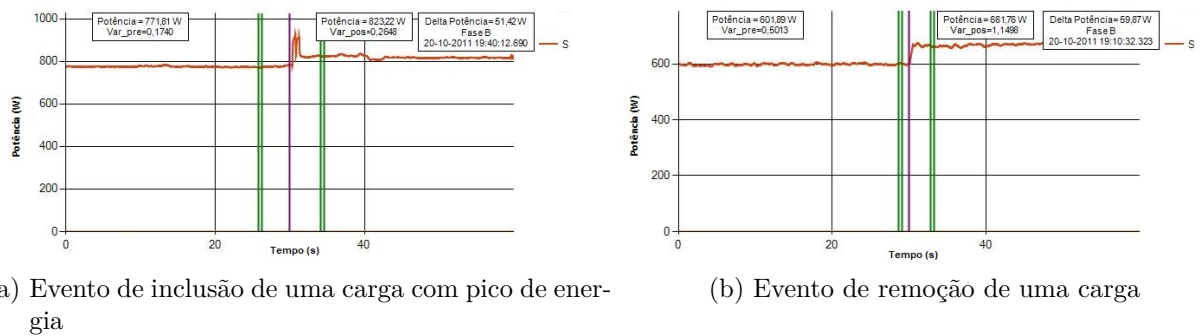


Figura 18 – Exemplo de eventos identificados na fase B

Figura 19a deveriam ser indicados, no intervalo entre as janelas demarcadas, 4 eventos distintos (adição, remoção, adição e remoção da carga monitorada) ao invés de um único. E na Figura 19b deveriam ser indicados, também no intervalo delimitado pelas janelas pré e pós, 3 eventos distintos (adição, remoção e adição da carga) ao invés de um único que esta englobando todos eles. Isso ocorreu devido ao avanço da janela flutuante, que passou por outros eventos sem delimitar a busca por uma região de estabilidade levando em conta a variação na potência maior que a variação limite ( $P_{thr}$ ).

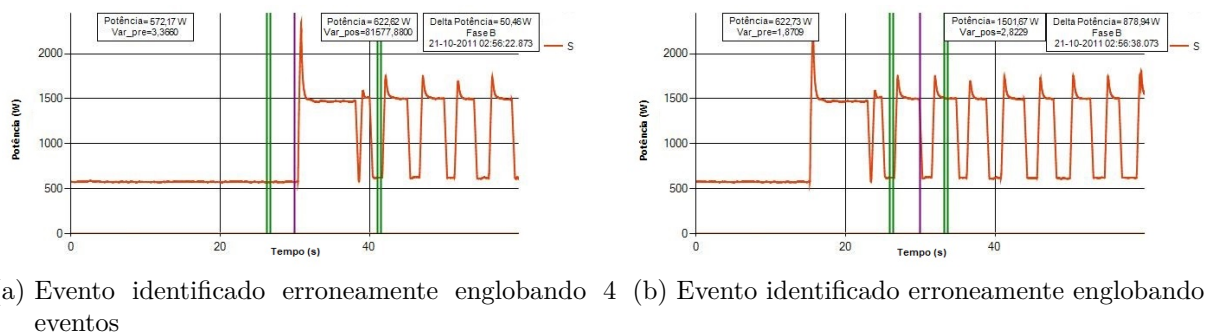


Figura 19 – Exemplo de eventos identificados erroneamente na fase B

A tabela 4 representa a matriz de confusão para o processo de identificação da fase A. Como pode ser observado o total de ocorrência de evento (Evento) nessa fase é 892 ( $TP + FN$ ). O total de não ocorrência de evento ( $\overline{Evento}$ ) foi aproximado a partir do tempo total de monitoramento, levando em consideração o evento com maior tempo de transição. Logo, a quantidade de não eventos é igual ao tempo total monitorado segmentado em intervalos de 30 segundos menos o número de ocorrência de eventos. Isto gerou para a fase A 19268 não eventos.

	Detectado	$\overline{Detectado}$
Evento	830	62
$\overline{Evento}$	82	19268

Tabela 4 – Matriz de Confusão para o processo de identificação da fase A

Utilizando esses dados foi calculado os desempenhos do identificador para a fase A com as Equações 4.9, 4.10, 4.11 e 4.13. O desempenho é apresentado na tabela 5, utilizando os cálculos demonstrados na secção 4.3.3.

Indicadores Fase A	%
Acurácia	99,29
Sensibilidade	93,05
Especificidade	99,58
Eficiência	96,31

Tabela 5 – Indicadores de desempenho na fase A

A tabela 6 representa a matriz de confusão para o processo de identificação da fase B. Como pode ser observado o total de ocorrência de evento (*Evento*) nessa fase é 1563 ( $TP + FN$ ). O total de não ocorrência de evento ( $\overline{Evento}$ ) foi aproximado exatamente como o da fase A. Logo, a quantidade de não eventos é 18597 não eventos.

	Detectado	$\overline{Detectado}$
<i>Evento</i>	1251	312
$\overline{Evento}$	763	18597

Tabela 6 – Matriz de Confusão para o processo de identificação da fase B

Utilizando esses dados foi calculado os desempenhos do identificador para a fase B com as Equações 4.9, 4.10, 4.11 e 4.13. O desempenho é apresentado na tabela 7.

Indicadores Fase B	%
Acurácia	98,22
Sensibilidade	62,12
Especificidade	99,46
Eficiência	80,79

Tabela 7 – Indicadores de desempenho na fase B

A tabela 8 mostra a combinação das tabelas 4 e 6. A partir da qual é possível montar a tabela 9 que contém os indicadores de desempenho do sistema como um todo.

	Detectado	$\overline{Detectado}$
<i>Evento</i>	2081	374
$\overline{Evento}$	845	37865

Tabela 8 – Matriz de Confusão para o processo de identificação

Para estabelecer um comparativo de desempenho com o identificador GLR (*Generalized Likelihood Ratio*) em (ANDERSON et al., 2012b) e com o identificador híbrido desenvolvido em (LU; LI, 2019) deve-se calcular também a porcentagem de verdadeiros positivos (*True Positive percentage*- TPP) e a porcentagem de falsos positivos (*False Positive percentage*- TPP), como mostrado na seção 4.3.3, e após isso calcular o desempenho

Indicadores Gerais	%
Acurácia	98,01
Sensibilidade	71,12
Especificidade	99,36
Eficiência	85,24

Tabela 9 – Indicadores de desempenho geral

com a função de desempenho com a Equação 4.17. Possibilitando a comparação entre as implementações, como pode ser vista na tabela 10.

	Proposta (%)	GLR (%)	Híbrida (%)
Fase A	88	78	94
Fase B	47	49	–

Tabela 10 – Comparativo entre desempenhos do trabalho proposto e as soluções proposta em (ANDERSON et al., 2012b) e (LU; LI, 2019)

Como pode ser observado, o identificador proposto tem um desempenho superior na identificação na fase A e um desempenho ligeiramente inferior na fase B quando comparada com o identificador GLR. Porém, quando comparado ao identificador híbrido apresenta um desempenho inferior em relação a fase A. Os dados referente a fase B do identificador híbrido não estão disponível para comparação.

Esse resultados demonstram que mesmo com as falhas apontadas no identificador, a solução proposta é viável.

## 5.2 Seleção do melhor formato dos dados para o treinamento do classificador

As 4 formas de dispor os dados discutidas na subsecção 4.3.1 foram testadas com uma mesma configuração de *RF* e seus resultados são comparados através das suas matrizes de confusão e seus indicadores discutidos na subsecção 4.3.3.

### 5.2.1 Variação das características elétricas (VCE)

Quando utilizado o método de disposição dos dados VCE obtemos a matriz de confusão na tabela 11 e os indicadores na tabela 12.

Analisando a matriz de confusão apresentada na tabela 11 nota-se que uma grande quantidade de classificações corretas do classificador, observadas na diagonal principal. Porém, algumas classes apresentam uma baixas taxas de precisão e de sensibilidade, como as classes 101, 102, 120, 128, 135 e 151.

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v	w	x	y	z	aa	ab	ac	classificado como	
0	24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	1	a=101	
23	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	b=102
0	0	17	1	2	0	0	0	1	0	0	0	1	0	0	1	0	0	0	0	0	0	0	0	0	0	1	0	0	c=103	
0	0	1	10	0	0	0	0	0	0	0	0	1	1	1	0	0	0	0	0	0	0	1	0	0	0	0	1	0	d=108	
0	0	1	0	613	0	0	0	0	0	0	0	0	0	0	0	3	0	0	1	1	0	0	0	0	0	0	0	0	e=111	
0	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	0	0	0	f=112	
0	0	0	0	0	0	33	0	0	0	8	0	0	0	0	0	0	1	0	3	0	0	0	0	0	0	0	0	0	g=118	
0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	7	0	0	1	0	0	0	1	0	1	0	0	2	h=120	
0	0	0	0	0	0	0	0	26	0	0	3	0	0	0	0	1	0	0	1	0	0	0	0	0	2	1	0	0	i=123	
0	0	0	0	0	0	0	0	0	20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	j=127	
0	0	0	0	0	0	11	0	0	0	37	0	0	0	0	0	22	0	0	1	6	0	0	0	0	0	0	0	0	k=128	
0	0	0	1	0	0	0	0	1	0	0	51	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	l=129	
0	0	2	0	0	0	0	0	0	0	1	1	137	0	0	0	3	0	1	2	0	0	0	0	1	0	1	1	0	m=131	
0	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	n=132	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	40	0	0	0	0	0	0	0	0	0	0	0	0	0	0	o=134	
0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	p=135	
0	0	0	0	2	0	2	3	2	0	14	0	1	0	0	0	113	0	0	3	6	0	0	0	0	1	0	1	2	q=140	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	12	0	0	0	0	0	0	0	0	0	4	0	r=147	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	0	1	0	0	1	0	0	0	s=148	
0	1	0	0	2	1	1	0	1	0	2	0	0	0	0	0	5	0	0	35	0	4	0	0	0	1	0	0	1	t=149	
0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	3	0	0	1	15	1	0	0	1	0	0	0	0	u=150	
2	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	2	0	0	5	3	4	0	0	0	0	0	0	0	v=151	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	57	0	0	0	0	0	0	w=152	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	4	1	0	0	0	0	0	x=153	
0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	1	0	0	1	0	0	0	47	0	5	0	0	y=155	
0	1	0	0	1	1	0	0	1	0	0	0	1	0	0	0	0	0	2	0	0	0	1	0	1	88	0	1	0	z=156	
0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	2	0	0	0	0	0	7	0	21	0	0	aa=157		
0	1	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0	14	0	ab=158	
1	0	0	0	1	0	0	0	0	0	0	1	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	33	ac=159	

Tabela 11 – Matriz de confusão para método de variações das características elétricas

Indicadores	%
Acurácia	98,62
Sensibilidade	84,29
Especificidade	99,21
Precisão	84,22
F-score	84,08
Eficiência	91,75

Tabela 12 – Indicadores do método de variação das características elétricas

Grande parte dessas classificações erradas para essas classes ocorrem pela classificação de classes com características elétricas semelhantes, como no caso das lâmpadas e monitores.

Para minimizar esses erros, foi proposto o agrupamento de classes semelhantes. Sendo assim, as classes 101 e 102 foram agrupadas e renomeadas para 104 (monitores), as classes 128 e 140 viraram 141 (lâmpadas tipo 1), e as classes 147, 149, 151, 155, 157 e 159 tornaram-se 105 (lâmpadas tipo 2).

A partir dessa alteração no *dataset* obteve-se a nova matriz de confusão na tabela 13 e seus indicadores na tabela 14.

Como pode ser observado a redução dessas 10 classes agrupadas em 3 novas, gerou um melhor desempenho do classificador, que pode ser observado nos valores da diagonal principal da matriz de confusão na tabela 13.

A classe 104 foi corretamente identificada 50 vezes, de um total de 51 instâncias. Com isso gerou-se uma TPP de 98,0% contra 0,0% e 4,0% das antigas classes 101 e 102,

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v	classificado como	
50	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	a=104
0	16	1	1	0	0	0	1	0	0	1	2	0	0	1	1	0	0	0	0	0	0	0	b=103
0	0	12	0	0	0	0	0	0	0	0	1	1	1	0	0	0	0	1	0	0	0	0	c=108
0	1	0	613	0	0	0	0	0	4	0	0	0	0	0	1	0	0	0	0	0	0	0	d=111
0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	0	e=112
0	0	0	0	0	31	0	0	0	10	0	1	0	0	0	3	0	0	0	0	0	0	0	f=118
0	0	0	0	0	0	2	0	0	6	0	0	0	0	0	4	0	0	0	1	1	0	0	g=120
0	0	0	0	1	0	0	25	0	3	3	0	0	0	0	1	0	0	0	0	0	1	0	h=123
0	0	0	0	0	0	0	0	0	20	0	0	0	0	0	0	0	0	0	0	0	0	0	i=127
0	0	0	4	0	11	4	1	0	191	0	2	0	0	0	7	0	5	0	0	1	1	0	j=141
0	0	0	0	0	0	0	1	0	0	51	1	0	0	0	1	0	0	0	0	0	0	0	k=129
0	1	0	0	0	0	0	0	0	4	2	138	0	0	0	4	0	0	0	0	1	0	0	l=131
0	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0	0	0	0	0	0	0	0	m=132
0	0	1	0	0	0	0	0	0	0	0	0	0	0	39	0	0	0	0	0	0	0	0	n=134
0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	o=135
6	0	0	3	0	3	1	4	0	13	1	0	0	0	0	182	0	1	0	0	0	0	0	p=105
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	1	0	1	0	0	q=148
0	0	0	0	0	0	0	0	0	6	0	1	0	0	0	3	0	12	0	0	0	0	0	r=150
0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	57	0	0	0	0	s=152
0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	4	0	0	0	t=153
1	0	0	1	0	0	0	1	0	0	0	0	0	0	0	4	2	0	0	0	88	1	0	u=156
1	0	0	0	0	0	0	0	0	0	2	0	0	0	0	1	0	0	0	0	1	14	0	v=158

Tabela 13 – Matriz de confusão para método de variações das características elétricas com agrupamento de classes

Indicadores	%
Acurácia	98,47
Sensibilidade	89,91
Especificidade	99,04
Precisão	89,60
F-score	89,65
Eficiência	94,47

Tabela 14 – Indicadores do método de variação das características elétricas com agrupamento de classes

respectivamente.

Já a classe 105 classificou corretamente 182 instâncias de um total de 214, gerando uma TPP de 85,0%, contra 75,0%, 64,8%, 23,5%, 83,9%, 65,6% e 84,6% das antigas classes 47,149, 151, 155, 157 e 159, respectivamente.

### 5.2.2 Forma de onda simples (FOS)

Utilizando a forma de onda das características elétricas sem nenhum processamento adicional obteve-se a matriz de confusão apresentada na tabela 15 e os indicadores apresentados na tabela 16.

Observa-se na tabela 15 que a diagonal principal possui várias posições nulas, ou seja, classificações erradas. Além das classes com problema de classificação vistas na matriz de confusão na tabela 11, diversas outras apresentaram baixo índice de acertos, dentre elas estão 103, 112, 118, 120, 129, 148, 150, 152, 153, 156 e 158.

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v	w	x	y	z	aa	ab	ac	classificado como	
0	22	0	0	0	0	0	0	0	0	0	1	0	0	0	0	2	0	0	0	0	1	0	0	0	0	0	0	0	0	a=101
21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	1	0	0	1	0	0	0	0	0	b=102
0	0	12	0	0	0	0	0	1	0	0	3	1	0	0	0	4	0	0	2	0	0	0	0	1	0	0	0	0	c=103	
0	0	0	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	d=108	
0	0	0	0	614	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	1	0	e=111	
0	0	0	0	0	0	0	0	1	0	2	0	0	0	0	0	4	0	0	0	0	0	0	0	0	0	0	0	1	f=112	
0	0	1	0	0	0	4	0	1	0	17	1	0	0	0	0	12	0	0	5	0	0	0	0	1	0	1	0	2	g=118	
0	0	1	0	0	0	0	0	0	0	2	0	0	0	0	0	9	0	0	1	0	0	0	0	0	1	0	0	0	h=120	
0	0	0	0	0	0	0	0	7	0	3	13	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	5	i=123	
0	0	0	0	0	0	0	0	0	20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	j=127	
0	0	0	0	0	0	11	0	1	0	23	1	0	0	0	0	28	0	0	7	0	1	0	0	3	0	1	0	1	k=128	
0	0	0	0	0	0	0	0	6	0	2	38	0	0	0	0	7	0	0	1	0	0	0	0	0	0	0	0	0	l=129	
0	0	0	0	0	0	0	0	0	0	0	0	150	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	m=131	
0	0	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	n=132	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	40	0	0	0	0	0	0	0	0	0	0	0	0	0	o=134	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	p=135	
1	1	0	0	0	0	3	2	0	0	15	2	2	0	0	0	91	0	0	14	3	2	4	0	5	0	3	0	2	q=140	
0	0	0	0	8	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0	0	0	0	0	0	0	0	0	0	r=147	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	0	0	0	s=148	
1	1	0	0	0	0	7	0	0	0	7	1	0	0	0	0	23	0	0	3	4	1	1	0	4	0	0	0	1	t=149	
0	0	0	0	0	0	0	0	0	0	4	0	0	0	0	0	8	0	0	6	3	0	0	0	1	0	0	0	0	u=150	
5	0	0	0	0	0	0	0	0	0	2	1	0	0	0	0	4	0	0	2	0	0	0	1	0	0	1	0	1	v=151	
0	0	1	0	0	0	0	0	0	0	2	4	0	0	0	0	6	0	0	0	0	0	41	0	3	0	0	0	1	w=152	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	1	0	0	0	0	0	0	1	0	0	x=153	
1	1	0	0	0	0	1	0	0	0	5	5	0	0	0	0	17	0	0	4	0	1	2	0	15	0	3	0	1	y=155	
0	0	0	0	21	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	75	0	1	0	z=156	
0	0	0	0	0	0	1	0	0	0	4	3	1	0	0	0	8	0	0	0	1	0	0	0	6	0	6	0	2	aa=157	
0	0	0	1	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	8	0	ab=158	
0	0	0	0	0	0	0	0	5	0	7	1	1	0	0	0	5	0	0	0	0	0	1	0	0	0	0	0	19	ac=159	

Tabela 15 – Matriz de confusão para método de forma de onda simples

Indicadores	%
Acurácia	97,13
Sensibilidade	69,22
Especificidade	97,89
Precisão	67,78
F-score	67,83
Eficiência	83,55

Tabela 16 – Indicadores da forma de onda simples

Para fins de comparação a mesma proposta de agrupamento foi aplicada. O mesmo agrupamento de classes feito na tabela 13 foi realizado para essa forma de disposição dos dados e a matriz de confusão na tabela 17 e os indicadores na tabela 18 foram construídos.

Após o agrupamento das classes similares ao se comparar os indicadores na tabela 16 e os indicadores na tabela 18 nota-se que os indicadores de sensibilidade e precisão melhoraram demonstrando o aumento da quantidade de TP sobre o total de classificações de determinada classe (TP+FN) e do aumento da quantidade de TN sobre o total real de eventos de cada classe (TP+FP). O indicador de especificidade apresentou uma pequena queda, porém, o indicador de eficiência uma melhora.

### 5.2.3 Forma de onda deslocada (FOD)

Utilizando a forma de onda das características elétricas com deslocamento obteve-se a matriz de confusão na tabela 19 e os indicadores na tabela 20.

Comparando-se a matriz de confusão na tabela 19 com a matriz confusão na tabela



a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v	classificado como	
45	0	0	0	0	0	0	0	0	2	0	0	0	0	0	4	0	0	0	0	0	0	0	a=104
0	13	0	0	0	0	0	0	0	4	2	1	0	0	0	4	0	0	0	0	0	0	0	b=103
0	0	14	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	c=108
0	0	0	616	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	1	0	d=111
0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	3	0	0	0	0	0	0	0	e=112
1	0	0	0	0	4	0	0	0	26	0	0	0	0	0	14	0	0	0	0	0	0	0	f=118
1	0	0	0	0	0	0	0	0	9	0	0	0	0	0	4	0	0	0	0	0	0	0	g=120
0	0	0	0	0	0	0	4	0	7	9	0	0	0	0	14	0	0	0	0	0	0	0	h=123
0	0	0	0	0	0	0	0	20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	i=127
4	0	0	0	0	9	0	0	0	151	2	2	0	0	0	58	0	0	1	0	0	0	0	j=141
0	0	0	0	0	0	0	3	0	9	37	0	0	0	0	3	0	1	1	0	0	0	0	k=129
0	0	0	0	0	0	0	0	0	1	0	149	0	0	0	0	0	0	0	0	0	0	0	l=131
0	0	1	0	0	0	0	0	0	0	0	0	7	0	0	0	0	0	0	0	0	0	0	m=132
0	0	0	0	0	0	0	0	0	0	0	0	0	40	0	0	0	0	0	0	0	0	0	n=134
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	o=135
8	0	0	10	0	4	0	2	0	62	0	2	0	0	0	124	0	1	1	0	0	0	0	p=105
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	0	0	q=148
0	0	0	0	0	0	0	0	0	10	0	0	0	0	0	12	0	0	0	0	0	0	0	r=150
1	0	0	0	0	0	0	0	0	11	2	0	0	0	0	11	0	0	33	0	0	0	0	s=152
0	0	0	0	0	0	0	0	0	3	0	0	0	0	0	3	0	0	0	0	0	0	0	t=153
0	0	0	20	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	75	2	0	u=156
0	0	1	5	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	5	7	0	v=158

Tabela 17 – Matriz de confusão para método de forma de onda simples com agrupamento de classes

Indicadores	%
Acurácia	95,92
Sensibilidade	77,18
Especificidade	96,94
Precisão	75,18
F-score	75,36
Eficiência	87,06

Tabela 18 – Indicadores da forma de onda simples agrupada

15, onde ambas utilizando a forma da onda para classificação, é evidente um maior número de elementos presentes na diagonal principal, indicando maior número de classificações corretas.

Comparado-se os indicadores na tabela 20 com os indicadores na tabela 16 nota-se uma melhora considerável na sensibilidade e precisão, uma melhora sutil na especificidade e acurácia.

Para fins de comparação a mesma proposta de agrupamento foi aplicada. O mesmo agrupamento de classes feito na tabela 13 para essa forma de disposição dos dados, a matriz de confusão na tabela 21 e os indicadores na tabela 22 foram construídos.

No confronto dos indicadores na tabela 20 com os indicadores na tabela 18 nota-se um aumento de todos os índices, destacando-se o indicador sensibilidade com o maior aumento.

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v	w	x	y	z	aa	ab	ac	classificada como	
0	16	0	0	0	0	0	0	0	0	1	0	0	0	0	0	5	0	0	3	0	1	0	0	0	0	0	0	0	0	a=101
13	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	9	0	0	1	0	1	0	0	0	0	0	0	0	0	b=102
0	0	15	0	2	0	0	0	1	0	0	3	0	0	0	0	0	0	0	0	0	0	1	0	2	0	0	0	0	c=103	
0	0	1	8	0	0	0	0	0	0	0	2	0	4	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	d=108	
0	0	0	0	613	0	0	0	0	0	0	1	1	0	0	0	3	0	0	0	0	0	0	0	1	0	0	0	0	e=111	
0	0	0	0	0	0	0	0	2	0	1	0	0	0	0	0	4	0	0	1	0	0	0	0	0	0	0	0	0	f=112	
0	0	0	0	0	0	29	0	0	0	10	0	0	0	0	0	3	0	0	2	0	0	1	0	0	0	0	0	0	g=118	
0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	10	0	0	0	1	0	1	0	0	0	0	0	0	h=120	
0	0	0	0	0	0	0	0	30	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0	0	0	0	0	0	i=123	
0	0	0	0	0	0	0	0	0	20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	j=127	
0	0	0	0	0	0	10	0	0	0	30	0	0	0	0	0	35	0	0	2	0	0	0	0	0	0	0	0	0	k=128	
0	0	0	0	1	0	0	0	0	0	0	53	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	l=129	
0	0	0	0	0	0	0	0	0	0	0	0	149	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	m=131	
0	0	0	1	0	0	0	0	0	0	0	0	0	6	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	n=132	
0	0	0	0	0	0	0	0	0	0	0	1	0	39	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	o=134	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	0	p=135	
0	0	0	0	0	0	0	0	0	0	4	0	0	0	0	0	138	0	0	3	0	0	2	0	2	0	0	1	0	q=140	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	16	0	0	0	0	0	0	0	0	0	0	0	r=147	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	0	0	0	3	0	0	0	0	s=148	
0	0	0	0	1	0	4	0	0	0	3	0	0	0	0	0	33	0	0	10	1	0	0	0	1	0	0	0	1	t=149	
0	0	0	0	1	0	0	0	0	0	7	0	0	0	0	0	9	0	0	1	4	0	0	0	0	0	0	0	0	u=150	
2	0	0	0	1	0	0	0	0	0	4	0	0	0	0	0	8	0	0	1	0	0	0	0	0	0	0	1	0	v=151	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	58	0	0	0	0	0	0	w=152	
0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	2	0	0	0	2	0	0	0	1	0	0	0	0	x=153	
0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	47	0	6	0	0	0	y=155	
0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0	1	0	1	93	0	1	z=156	
0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0	20	0	8	0	1	aa=157	
0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	15	0	ab=158	
0	0	1	0	0	0	0	0	0	0	1	1	0	0	0	0	20	0	0	0	0	0	0	0	0	0	0	0	16	ac=159	

Tabela 19 – Matriz de confusão para método de forma de onda deslocada

Indicadores	%
Acurácia	98,35
Sensibilidade	80,75
Especificidade	98,79
Precisão	79,26
F-score	78,70
Eficiência	89,77

Tabela 20 – Indicadores da forma de onda deslocada

### 5.2.4 Taxa de variação da onda (TVO)

Utilizando a taxa de variação da forma de onda das características elétricas obteve-se a matriz de confusão na tabela 23 e os indicadores na tabela 24.

Comparando o desempenho desse método com o do método da forma de onda simples, nota-se queda de todos os indicadores de desempenho, destacando-se as quedas acentuadas na sensibilidade, eficiência e precisão.

Para fins de comparação a mesma proposta de agrupamento foi aplicada. O mesmo agrupamento de classes feito na tabela 13 para essa forma de disposição dos dados a matriz de confusão na tabela 25 e os indicadores na tabela 26 foram construídos.

No confronto dos indicadores 24 com os indicadores 26, nota-se queda de todos os indicadores de desempenho, destacando-se as quedas acentuadas na sensibilidade, eficiência e precisão.

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v	classificado como	
33	0	0	0	0	0	0	0	0	13	0	0	0	0	0	5	0	0	0	0	0	0	0	a=104
0	15	0	1	0	0	0	0	0	1	3	0	0	0	0	3	0	0	1	0	0	0	0	b=103
0	0	10	0	0	0	0	0	0	1	1	0	4	0	0	0	0	0	0	0	0	0	0	c=108
0	0	1	612	0	0	0	0	0	3	1	1	0	0	0	1	0	0	0	0	0	0	0	d=111
0	0	0	0	0	0	0	0	0	3	0	0	0	0	0	5	0	0	0	0	0	0	0	e=112
0	0	0	0	0	28	0	0	0	13	0	0	0	0	0	3	0	0	1	0	0	0	0	f=118
0	0	0	0	0	0	0	0	0	11	0	0	0	0	0	1	0	1	1	0	0	0	0	g=120
0	0	0	0	0	0	0	31	0	2	0	0	0	0	0	1	0	0	0	0	0	0	0	h=123
0	0	0	0	0	0	0	0	20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	i=127
0	0	0	0	0	9	0	0	0	199	0	0	0	0	0	16	0	0	3	0	0	0	0	j=141
0	0	0	1	0	0	0	0	0	0	52	0	0	0	0	0	0	0	0	0	0	0	1	k=129
0	0	0	0	0	0	0	0	0	0	0	150	0	0	0	0	0	0	0	0	0	0	0	l=131
0	0	1	0	0	0	0	0	2	0	0	0	5	0	0	0	0	0	0	0	0	0	0	m=132
0	0	0	0	0	0	0	0	0	0	0	1	0	39	0	0	0	0	0	0	0	0	0	n=134
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	o=135
2	0	0	0	0	2	0	0	0	42	1	0	0	0	0	165	0	0	2	0	0	0	0	p=105
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	3	0	0	q=148
0	0	0	1	0	0	0	0	0	18	0	0	0	0	0	3	0	0	0	0	0	0	0	r=150
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	56	0	0	0	0	s=152
0	0	0	0	0	0	0	0	0	4	0	0	0	0	0	2	0	0	0	0	0	0	0	t=153
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	3	0	0	1	0	92	1	0	u=156
0	0	0	0	0	0	0	0	0	0	3	0	0	0	0	1	0	0	1	0	0	14	0	v=158

Tabela 21 – Matriz de confusão para método de forma de onda deslocada com agrupamento de classes

Indicadores	%
Acurácia	98,06
Sensibilidade	87,84
Especificidade	98,63
Precisão	86,55
F-score	86,73
Eficiência	93,24

Tabela 22 – Indicadores da forma de onda deslocada agrupada

### 5.2.5 Resumo dos indicadores

Os indicadores de todos os métodos utilizados são resumidos na tabela 27. Estão destacados os dois melhores métodos para cada indicador de desempenho.

Os dois métodos com melhores desempenho são VCE-agrupada e FOD-agrupada, respectivamente, quando analisados a partir dos indicadores da precisão, especificidade, sensibilidade e eficiência, nesta ordem.

Os métodos TVO e TVO-agrupada apresentaram os piores indicadores dentre todos os métodos.

O indicador acurácia não foi utilizado nas comparações entre os métodos devido ao fato de não apresentar informações profundas, como a propensão do classificador na identificação de TP, TN, FP ou FN. Esses detalhes sobre as propensões do classificador são fornecidas pelos outros indicadores.

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v	w	x	y	z	aa	ab	ac	classificado como
0	13	0	0	0	0	0	0	0	0	1	0	0	0	0	0	11	0	0	0	0	1	0	0	0	0	0	0	0	a=101
12	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	10	0	0	1	0	1	0	0	0	0	0	0	0	b=102
0	0	0	0	0	0	0	0	1	0	2	1	6	0	0	0	12	0	0	1	0	0	1	0	0	0	0	0	0	c=103
0	0	0	0	9	0	0	0	0	2	0	0	4	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	d=108
0	0	0	0	618	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	e=111
0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	5	0	0	0	0	0	0	0	0	0	0	0	0	f=112
0	0	0	0	0	0	0	0	0	0	11	0	0	0	0	0	32	0	0	1	0	0	0	0	1	0	0	0	0	g=118
0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	12	0	0	0	0	0	0	0	0	0	0	0	0	h=120
0	0	0	0	0	0	0	0	1	0	1	4	6	0	0	0	20	0	0	1	0	0	0	0	0	0	0	0	1	i=123
0	0	0	0	11	0	0	0	0	9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	j=127
0	0	0	0	0	0	6	0	1	0	4	0	2	0	0	0	63	0	0	0	0	0	0	0	1	0	0	0	0	k=128
0	0	0	0	0	0	0	0	1	0	1	7	14	0	0	0	28	0	0	1	0	0	1	0	0	0	0	0	1	l=129
0	0	0	0	0	0	0	0	0	0	0	0	150	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	m=131
0	0	0	0	7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	n=132
0	0	0	0	1	0	0	0	0	0	1	0	17	0	2	0	18	0	0	0	0	0	1	0	0	0	0	0	0	o=134
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	p=135
0	0	0	0	0	0	1	0	0	0	6	1	5	0	0	0	132	0	0	0	0	0	1	0	3	0	0	0	1	q=140
0	0	0	0	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	r=147
0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	s=148
0	0	0	0	0	0	1	0	0	0	6	0	2	0	0	0	40	0	0	1	0	0	1	0	3	0	0	0	0	t=149
0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	19	0	0	1	0	0	0	0	0	0	0	0	0	u=150
2	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	13	0	0	1	0	0	0	0	0	0	0	0	0	v=151
0	0	0	0	0	0	0	0	0	0	3	4	2	0	0	0	45	0	0	2	0	0	0	0	2	0	0	0	0	w=152
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	x=153
0	0	0	0	0	0	0	0	0	0	5	1	2	0	0	0	47	0	0	0	0	0	0	1	0	0	0	0	0	y=155
0	0	0	0	92	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	4	0	0	0	z=156
0	0	0	0	0	0	0	0	0	0	1	0	4	0	0	0	23	0	0	0	0	0	2	0	1	0	0	0	1	aa=157
0	0	0	0	17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	ab=158
0	0	0	0	0	0	0	0	0	0	1	0	3	0	0	0	34	0	0	0	0	0	1	0	0	0	0	0	0	ac=159

Tabela 23 – Matriz de confusão para método de taxa de variação da onda

Indicadores	%
Acurácia	93,60
Sensibilidade	53,54
Especificidade	93,87
Precisão	45,31
F-score	44,19
Eficiência	73,71

Tabela 24 – Indicadores da taxa de variação

### 5.3 Classificação de cargas

Para a etapa de otimização e classificação das cargas foram utilizadas as 2 formas de disposição de dados que apresentaram melhor desempenho na etapa de seleção do formato dos dados: a variação das características elétricas (VCE) e a forma de onda deslocada (FOD). Foram utilizadas essas formas com o agrupamento de classes devido ao melhor desempenho.

Os intervalos dos parâmetros utilizados para a otimização utilizando o FA são destacados na tabela 28. Para os limites inferiores foram utilizados os valores mínimos que o método *RF* permite. O número de árvores (*Trees*) deve ser no mínimo 1, a profundidade máxima das árvores (*Maximum Trees Depth*) deve ser no mínimo 1, as características mínimas para quebra deve ser maior que zero, e a porcentagem das amostras totais utilizada para treinamento de cada árvore (*Sub Sample Ratio*) deve ser maior que zero.

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v	classificado como
27	0	0	0	0	0	0	0	0	15	0	0	0	0	0	9	0	0	0	0	0	0	a=104
0	0	0	0	0	0	0	0	0	14	0	2	0	0	0	8	0	0	0	0	0	0	b=103
0	0	1	8	0	0	0	0	3	0	0	4	0	0	0	0	0	0	0	0	0	0	c=108
0	0	0	617	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	0	d=111
0	0	0	0	0	0	0	0	0	5	0	1	0	0	0	2	0	0	0	0	0	0	e=112
0	0	0	0	0	0	0	0	0	24	0	0	0	0	0	21	0	0	0	0	0	0	f=118
0	0	0	0	0	0	0	0	0	10	0	0	0	0	0	4	0	0	0	0	0	0	g=120
0	0	0	0	0	0	0	2	0	23	0	0	0	0	0	9	0	0	0	0	0	0	h=123
0	0	1	7	0	0	0	0	8	1	0	0	0	0	0	1	0	0	0	0	2	0	i=127
0	0	0	0	0	5	0	0	0	169	0	1	0	0	0	52	0	0	0	0	0	0	j=141
0	0	0	0	0	0	0	0	0	25	3	4	0	0	0	22	0	0	0	0	0	0	k=129
0	0	0	0	0	0	0	0	0	0	0	150	0	0	0	0	0	0	0	0	0	0	l=131
0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	m=132
0	0	0	0	0	0	0	0	0	15	0	12	0	1	0	12	0	0	0	0	0	0	n=134
0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	o=135
1	0	0	16	0	1	0	0	0	120	0	1	0	0	0	75	0	0	0	0	0	0	p=105
0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	q=148
0	0	0	0	0	0	0	0	0	13	0	0	0	0	0	9	0	0	0	0	0	0	r=150
0	0	0	0	0	0	0	0	0	32	0	0	0	0	0	26	0	0	0	0	0	0	s=152
0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	t=153
0	0	0	93	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	4	0	u=156
0	0	0	17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	v=158

Tabela 25 – Matriz de confusão para método de taxa de variação da onda com agrupamento de classes

Indicadores	%
Acurácia	92,07
Sensibilidade	60,92
Especificidade	92,94
Precisão	58,10
F-score	53,73
Eficiência	76,93

Tabela 26 – Indicadores da taxa de variação da onda com agrupamento

Indicadores	VCE %	VCE-agrupada %	FOS %	FOS-agrupada %	FOD %	FOD-agrupada %	TVO %	TVO-agrupada %
Acurácia	<b>98,62</b>	<b>98,47</b>	97,13	95,92	98,35	98,06	93,60	92,07
Sensibilidade	84,29	<b>89,91</b>	69,22	77,18	80,75	<b>87,84</b>	53,54	60,92
Especificidade	<b>99,21</b>	<b>99,04</b>	97,89	96,94	98,79	98,63	93,87	92,94
Precisão	84,22	<b>89,60</b>	67,78	75,18	79,26	<b>86,55</b>	45,31	58,10
F-score	84,08	<b>89,65</b>	67,83	75,36	78,70	<b>86,73</b>	44,19	53,73
Eficiência	91,75	<b>94,47</b>	83,55	87,06	89,77	<b>93,24</b>	73,71	76,93

Tabela 27 – Resumo dos indicadores dos métodos de disposição dos dados.

A configuração utilizada no otimizador FA foram:

- Número total de faíscas  $\hat{S} = 50$ ;
- Amplitude máxima  $\hat{A} = 40$ ;
- Número de explosões  $N = 25$ ;
- Limite inferior  $\alpha = 0,04$ ;

Parâmetro	Intervalo
<i>Trees</i>	1 – 3000
<i>Maximum Trees Depth</i>	1 – 100
<i>Feature Per Split</i>	1 - Número de parâmetros
<i>Sub Sample Ratio</i>	1 – 100%

Tabela 28 – Intervalos dos parâmetros para otimização da RF.

- Limite Superior  $\beta = 0,8$ ;
- Número de gerações  $G = 50$ ;

Os resultados da otimização dos parâmetros de cada uma das formas estão apresentados nas tabelas 29 e 30.

Parâmetro	Otimizado	Padrão
<i>Trees</i>	557	100
<i>Maximum Trees Depth</i>	23	Ilimitado
<i>Feature Per Split</i>	3	1
<i>Sub Sample Ratio %</i>	79	100

Tabela 29 – Parâmetros otimizado para a Variação das Características Elétricas

Parâmetro	Otimizado	Padrão
<i>Trees</i>	996	100
<i>Maximum Trees Depth</i>	32	Ilimitado
<i>Feature Per Split</i>	22	1
<i>Sub Sample Ratio %</i>	100	100

Tabela 30 – Parâmetros otimizado para a Forma de Onda Deslocada

Os indicadores obtidos utilizando a forma de disposição de dados VCE são apresentados na tabela 31 na coluna "Otimizado", junto aos indicadores da tabela 14 na coluna "Padrão". A matriz de confusão da classificação é apresentada na tabela 32.

Como pode ser observado quando comparado os indicadores sensibilidade, especificidade e eficiência os valores do classificador otimizado ficam ligeiramente inferior (não mais que 0,34%).

Porém, no indicador precisão, o classificador com parâmetros otimizados apresenta uma melhora de aproximadamente de 5% quando comparada com o padrão, e essa melhora acarreta na elevação do parâmetro F-score.

Uma segunda otimização foi realizada com a forma de disposição dos dados VCE-agrupado, mas dessa vez utilizando o algoritmo PSO. Os resultados da otimização e o comparativo tanto dos índices quanto dos parâmetros obtidos estão descritos na tabela 33. Como pode ser observado ambos os algoritmos obtiveram resultados semelhantes,

Indicadores	Otimizado(%)	Padrão(%)
Acurácia	98,37	98,47
Sensibilidade	89,57	89,91
Especificidade	98,96	99,21
Precisão	89,33	84,22
F-Score	89,28	84,08
Eficiência	94,26	94,47

Tabela 31 – Indicadores da VCE-agrupada otimizados e os padrões.

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v	Classificado como	
51	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	a=104
0	16	1	3	0	0	0	0	0	0	0	1	0	0	1	1	0	0	0	0	0	0	1	b=103
0	0	11	0	0	0	0	0	0	0	1	1	1	1	0	0	0	0	1	0	0	0	0	c=108
0	1	0	611	0	0	1	0	0	3	0	0	0	0	0	3	0	0	0	0	0	0	0	d=111
0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	0	e=112
0	0	0	0	0	31	0	0	0	10	0	1	0	0	0	3	0	0	0	0	0	0	0	f=118
0	0	0	2	0	0	1	0	0	5	0	0	0	0	0	5	0	0	0	1	0	0	0	g=120
0	0	0	0	0	0	0	26	0	3	2	0	0	0	0	2	0	0	0	0	1	0	0	h=123
0	0	0	0	0	0	0	0	20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	i=127
0	0	0	4	0	12	2	1	0	193	0	0	0	0	0	6	1	6	0	1	0	1	0	j=141
0	0	0	0	0	0	0	1	0	0	52	0	0	0	0	1	0	0	0	0	0	0	0	k=129
0	3	0	0	0	0	0	0	0	4	2	135	0	0	0	4	1	0	0	0	0	1	0	l=131
0	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0	0	0	0	0	0	0	0	m=132
0	0	0	0	0	0	0	0	0	0	0	0	0	40	0	0	0	0	0	0	0	0	0	n=134
0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	o=135
5	0	0	3	0	3	1	4	0	14	1	0	0	0	0	180	0	2	0	0	0	1	0	p=105
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	1	0	1	0	0	q=148
0	0	0	0	0	0	0	0	0	6	0	1	0	0	0	4	0	11	0	0	0	0	0	r=150
0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	57	0	0	0	0	s=152
0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	4	0	0	0	t=153
2	0	0	1	0	0	0	1	0	0	0	0	0	0	0	5	2	0	0	0	86	1	0	u=156
1	0	0	0	0	0	0	0	0	0	2	0	0	0	0	1	0	0	0	0	0	1	14	v=158

Tabela 32 – Matriz de confusão para método de VCE-agrupado após a otimização

diferindo entre si em no máximo 0,17 %, implicando em um ponto de convergência em comum. A partir dos teste realizados não pode-se afirmar qual das duas técnicas de otimização tem melhor desempenho. O mesmo comparativo não foi realizado para a forma de disposição FOD-agrupado, devido a proximidade dos resultados obtidos nos testes do FA e PSO.

Os indicadores obtidos utilizando a forma de disposição de dados FOD são apresentados na tabela 34, junto aos indicadores da tabela 22. A matriz de confusão da classificação é apresentada na tabela 35.

Como pode ser observado todos os indicadores apresentaram melhoras no desempenho do classificador, apesar de serem pequenas (não mais que 0,69%).

Comparando os dois métodos otimizados pode-se afirmar que o desempenho de ambos é muito próximo, com leves variações em quase todos os índices analisados. Os que mostram maiores diferenças são o *F – Score* e a precisão.

Utilizando a comparação do classificador com um classificador ideal, como descrito

		FA	PSO
Parâmetros	<i>Trees</i>	557	704
	<i>Maximum Trees Depth</i>	23	25
	<i>Feature Per Split</i>	3	4
	<i>Sub Sample Ratio (%)</i>	79	99
Índices (%)	Acurácia	98,37	98,42
	Sensibilidade	89,57	89,74
	Especificidade	98,96	98,99
	Precisão	89,33	89,35
	F-Score	89,28	89,44
	Eficiência	94,26	94,36

Tabela 33 – Comparativo dos algoritmos de otimização FWA e PSO.

Indicadores	Otimizado(%)	Padrão(%)
Acurácia	98,17	98,06
Sensibilidade	88,53	87,84
Especificidade	98,69	98,63
Precisão	87,19	86,55
F-Score	87,37	86,73
Eficiência	93,61	93,24

Tabela 34 – Indicadores da FOD-agrupada otimizados e os padrões.

na equação 4.17, são obtidos os resultados demonstrado na tabela 37. Esse resultado corrobora os resultados obtidos utilizando os demais indicadores de desempenho, uma vez que o desempenho de ambos os classificadores são muito próximos entre si.

Uma informação extraída da *RF* é a importância de cada variável no processo de classificação. No caso do método de classificação que utiliza o VCE como modo de disposição de dados, a importância das variáveis é mostrada na Figura 20. As variáveis  $V, V1, I, I1$  são as com maior importância nesse classificador.

O agrupamento da importância das variáveis no método FOD necessitou ser realizado, devido as diversas ondas de características elétricas sendo utilizadas nas classificações.

Dois agrupamentos foram realizados: a média ponderada de cada uma das características, utilizando a importância e a quantidade de nós em que cada variável é utilizada para quebra dos nós nas árvores da *RF*, e a média ponderada utilizando a importância e faixas de tamanho fixo de 100 variáveis.

O primeiro agrupamento pode ser visto na Figura 21, onde observa-se que as variáveis de maior importância para a classificação são  $V, V1, I$  e  $I1$ .

O segundo agrupamento pode ser visto no gráfico 22, onde percebe-se que as primeiras 16 faixas de variáveis correspondem as variáveis  $V, V1, I$  e  $I1$ .



a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v	<-Classificado como	
34	0	0	0	0	0	0	0	0	13	0	0	0	0	0	4	0	0	0	0	0	0	0	a=104
0	15	0	1	0	0	0	0	0	1	3	0	0	0	0	4	0	0	0	0	0	0	0	b=103
0	1	8	0	0	0	0	0	0	0	2	0	4	0	0	1	0	0	0	0	0	0	0	c=108
0	0	0	613	0	0	0	0	0	3	1	1	0	0	0	1	0	0	0	0	0	0	0	d=111
0	0	0	0	0	0	0	0	0	3	0	0	0	0	0	5	0	0	0	0	0	0	0	e=112
0	0	0	0	0	28	0	0	0	13	0	0	0	0	0	3	0	0	1	0	0	0	0	f=118
0	0	0	0	0	0	0	0	0	13	0	0	0	0	0	0	0	0	1	0	0	0	0	g=120
0	0	0	0	0	0	0	32	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0	h=123
0	0	0	0	0	0	0	0	20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	i=127
0	0	0	0	0	9	0	0	0	202	0	0	0	0	0	13	0	0	3	0	0	0	0	j=141
0	0	0	1	0	0	0	0	0	0	53	0	0	0	0	0	0	0	0	0	0	0	0	k=129
0	0	0	0	0	0	0	0	0	0	0	150	0	0	0	0	0	0	0	0	0	0	0	l=131
0	0	1	0	0	0	0	0	1	0	0	0	6	0	0	0	0	0	0	0	0	0	0	m=132
0	0	0	0	0	0	0	0	0	0	0	1	0	39	0	0	0	0	0	0	0	0	0	n=134
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	o=135
2	0	0	0	0	3	0	0	0	39	1	0	0	0	0	167	0	0	2	0	0	0	0	p=105
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	0	2	0	0	q=148
0	0	0	0	0	0	0	0	0	21	0	0	0	0	0	1	0	0	0	0	0	0	0	r=150
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	58	0	0	0	0	s=152
0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	1	0	0	0	0	0	0	0	t=153
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	3	0	0	1	0	92	1	0	u=156
0	0	0	1	0	0	0	0	0	0	1	0	0	0	0	1	0	0	1	0	0	0	15	v=158

Tabela 35 – Matriz de confusão para método de FOD-agrupado após a otimização

Indicadores	VCE-Otimizado(%)	FOD-Otimizado(%)	$\Delta$ (%)
Acurácia	98,37	98,17	0,20
Sensibilidade	89,57	88,53	1,04
Especificidade	98,96	98,69	0,27
Precisão	89,33	87,19	2,14
F-Score	89,28	87,37	1,91
Eficiência	94,26	93,61	0,65

Tabela 36 – Indicadores dos métodos otimizados e do padrão.

Classificador	TPP (%)	FPP (%)	$\hat{\psi}$ (%)
Ideal	100	0	100
VCE-Otimizado	89,57	1,04	98,06
FOD-Otimizado	88,53	1,31	97,75

Tabela 37 – Comparação dos classificadores com um classificador ideal

O segundo agrupamento pode ser visto no gráfico 22, onde percebe-se que as primeiras 16 faixas de variáveis correspondem as variáveis  $V, V1, I$  e  $I1$ .

## 5.4 Resumo dos tempos de execução

A tabela 38 apresenta os tempos gastos na otimização do processo de detecção de eventos, como discutido na seção 5.1, e o tempo de execução do detector de eventos com os parâmetros otimizados em todo o *dataset*.

A tabela 39 apresenta os tempos gastos no processo de otimização dos parâmetros da RF e os tempos de construção da RF para ambos os métodos de disposição dos dados.




Figura 20 – Importância das variáveis através do método VCE

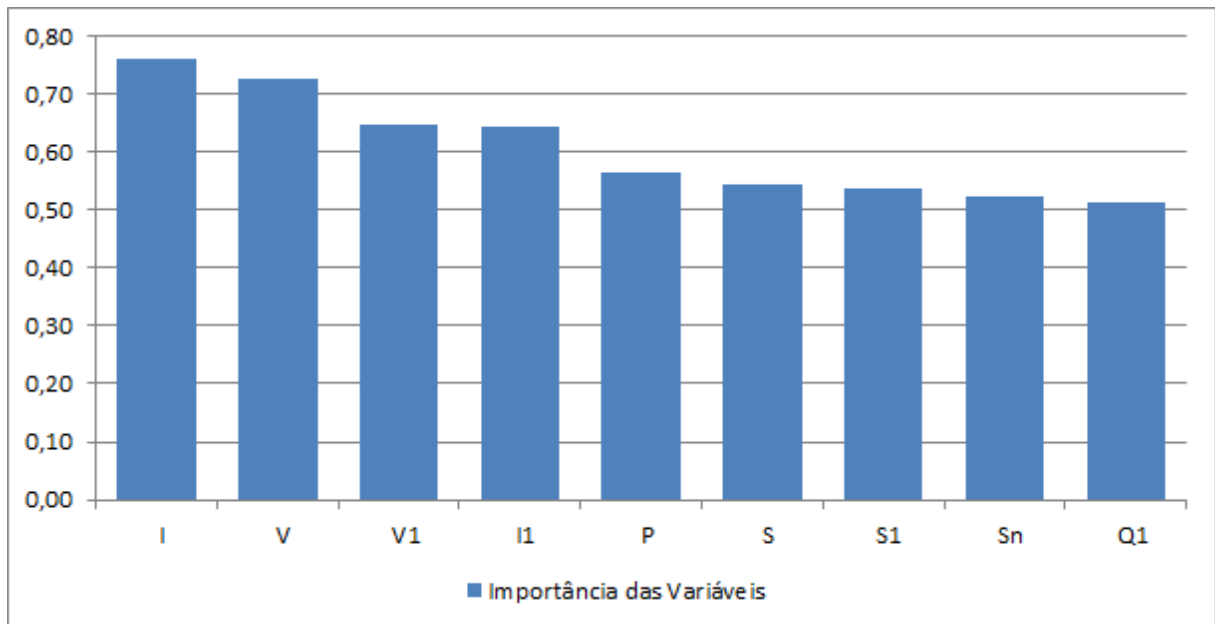


Figura 21 – Média ponderada da importância das variáveis através do método FOD

Otimização (h)	Deteccção dos eventos (h)
246,4	1,08

Tabela 38 – Resumo dos tempos de otimização e deteção dos eventos

O tempo de otimização do VCE-Agrupado é bem menor que do FOD-Agrupado devido a quantidade de variáveis de entrada que cada um possui. E a diferença de tempo entre os métodos de disposição dos dados tem uma redução considerável quando analisada em relação a construção da RF.

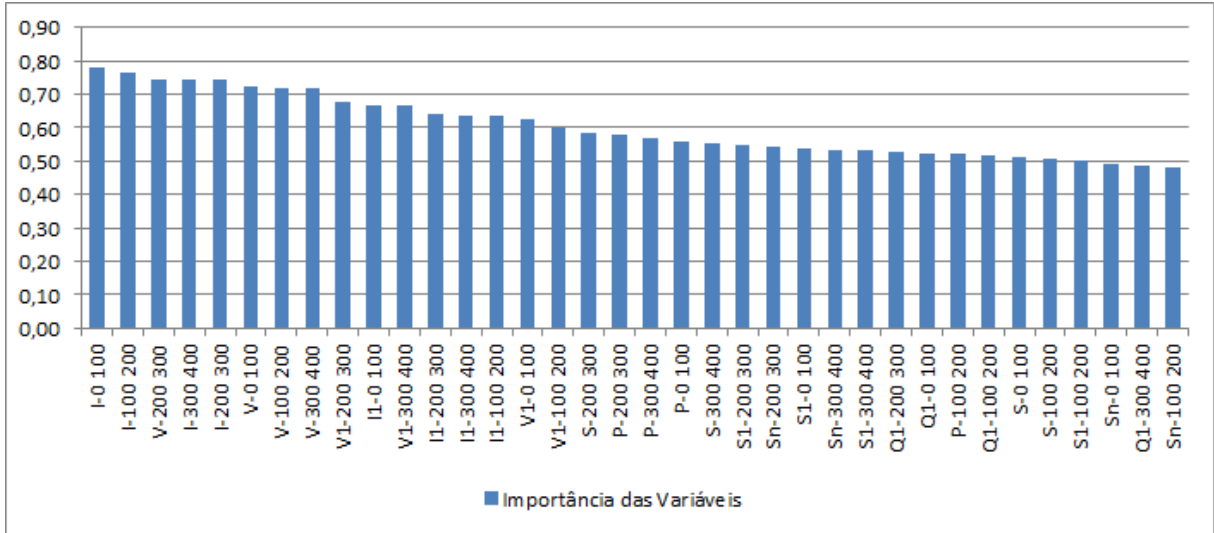


Figura 22 – Média ponderada por faixas de intervalos da importância das variáveis através do método FOD

	Otimização (h)	Construção da RF (s)
VCE-Agrupado	5,12	0,74
FOD-Agrupado	205,7	8,79

Tabela 39 – Resumo dos tempos de otimização e construção da RF

## 5.5 Considerações finais

O identificador de eventos proposto se mostrou eficiente, mas proposta de detecção de eventos por meio de janelas flutuantes deve ser lapidada para melhorar seu desempenho. Uma vez que realiza saltos após detectar variação na potência acima do limite definido na busca por regiões de estabilidade, gerando ocasionalmente erro ao não detectar possíveis eventos de curta duração e/ou transição ocorrido adjacente a um evento com longo tempo de transição, como pode ser observado na Figura 19.

A utilização do novo padrão de potência da IEEE (IEEE, 2010) oferece uma gama de novas possibilidades para auxiliar na classificação dos eventos. Porém, nos intervalos onde ocorrem transições podem aparecer valores inexistentes, devido ao comportamento e tempo de resposta do filtro aplicado e os cálculos para obter  $Q_1$ ,  $S_1$  e  $S_N$ , já os cálculos das potências  $S$  e  $P$  não possuem atrasos e não estão sujeitos a esse problema. Logo, a utilização desses cálculos não são apropriados para classificações baseadas nas transições sem que haja algumas suposições que necessitam ser validadas. Como pode ser visto a importância das variáveis na Figura 20, Figura 21 e Figura 22, os cálculos do novo padrão da IEEE demonstraram ser bons parâmetros para classificação dos eventos.

O processo de otimização utilizando a forma VCE mostrou melhora no desempenho quando analisado o F-score. O ganho no desempenho do F-score pode ser justificado simplesmente pelo aumento do número de árvores, como visto na tabela 29. A diminuição

da porcentagem das amostras totais utilizada para o treinamento ocasionou a queda de identificação em algumas classes, uma vez que certas amostras ficaram de fora do processo de treinamento. A seleção da profundidade também se mostrou irrelevante nesse caso, uma vez que o número máximo de atributos utilizando a forma VCE é igual a 9. Logo, a profundidade máxima é menor que o número de característica, não limitando assim o aprofundamento das árvores da *RF*.

O processo de classificação utilizando a forma FOD teve uma melhora de desempenho de aproximadamente 4% após a otimização. A profundidade máxima da árvore nesse método já serviu como limitante no crescimento das árvores na *RF*, uma vez que poderia chegar a uma altura de 3600, correspondente a quantidade de variáveis de entrada. Uma outra vantagem notada por essa forma de disposição dos dados é a não necessidade de utilizar um detector de evento que localize as zonas de estabilidade (um processo custoso computacionalmente), uma vez que utiliza a forma de onda deslocada em um intervalo ao redor do instante identificado com ocorrência de evento.

O processo de otimização utilizando a forma FOD gastou um tempo muito maior que quando utilizando a forma VCE, cerca de 40 vezes mais como pode ser observado na tabela 39, devido a quantidade de variáveis de entrada em cada, 3600 variáveis por amostra na forma FOD contra 9 variáveis por amostra na forma VCE.

## 6 Conclusão

O trabalho desenvolvido apresenta um método não intrusivo de identificação de cargas elétricas baseado no classificador *Random Forest* (RF) e na otimização por Fogos de Artifício (FA). A proposta do método é utilizar a capacidade da RF de produzir resultados com baixa variância devido ao procedimento de *Bagging* e a facilidade de trabalhar com grandes volumes de dados.

Os parâmetros da RF são otimizados pelo algoritmo de otimização FA para alcançar um melhor desempenho de classificação. O FA foi escolhido devido a baixa quantidade de parâmetros de ajuste e de trabalhos relacionados a área de NILM e RF.

O método proposto possui em três etapas: pré-processamento dos dados, identificação da ocorrência de eventos, e treinamento e classificação. A primeira etapa realiza os cálculos das potências e filtra os dados do *dataset*. A segunda etapa detecta a ocorrência de eventos baseando-se na alteração da características elétrica total. E a terceira etapa otimiza a RF através do algoritmo de otimização FA e utiliza os eventos detectados na segunda etapa como dados de treinamento e validação.

O *dataset* BLUED é utilizado no método proposto, e trabalhos relacionados a ele são utilizados como referências para comparações de resultados. A abordagem de identificação de eventos do método proposto é comparada com outras duas abordagens disponíveis na literatura, detector GLR e detector híbrido, que utilizaram o mesmo *dataset*. E apresenta resultado melhor que o primeiro.

O método proposto também utiliza quatro abordagens diferentes quanto a forma de disposição dos dados para a classificação a partir do conjunto de classes originais do *dataset*, e estas mesmas abordagens também são utilizadas com um conjunto de classes simplificadas, onde classes com características elétricas são agrupadas. As duas que tem melhores desempenhos dentre as outras são: a variação das características elétricas agrupada (VCE-agrupada) e a forma de onda deslocada agrupada (FOD-agrupada).

Na etapa da otimização do classificador RF com o algoritmo FA, as formas de disposição dos dados VCE-agrupada e FOD-agrupada são utilizadas e os resultados das otimizações em ambos os casos são muito semelhantes. Porém, o classificador RF produzido utilizando o VCE-agrupado é mais simples, possui um número de árvores e profundidades menores. Uma otimização extra é realizada utilizando o VCE-agrupado, por apresentar um construção mais simples e com desempenho semelhante a outra forma de disposição dos dados, e o algoritmo de otimização enxame de partículas (PSO). A comparação entre os resultados das técnicas FA e PSO demonstra resultados de desempenho quase similares, porém, o RF otimizado com o algoritmo FA produz um modelo mais simples

quando analisado o número de árvores, mostrando melhor desempenho do algoritmo de otimização utilizado.

As contribuições desse trabalho para a área de NILM foram a proposta de agrupamento das cargas com características elétricas semelhantes, o desenvolvimento do método de detecção de eventos utilizando janelas flutuantes, as formas de disposição dos dados de entrada para a utilização no classificador, em especial a VCE-agrupada e a FOD-agrupada, e a otimização dos parâmetros do classificador RF utilizando o algoritmo Fogos de Artífício.

Trabalhos futuros para ampliar e melhorar esse trabalho são propostos a seguir:

- Melhorias no método de detecção de eventos devem ser feitas para eliminar não detecção de eventos subsequentes, onde há ocorrência de eventos de longo tempo para estabilização junto a outros eventos.
- Utilização de restrições com a finalidade de parar o avanço das janelas flutuantes ao se detectar nova variação de potência em janelas subsequentes a posição de avanço maiores que a variação de potência limite ( $P_{thr}$ ), evitando que eventos sejam agrupados nessa etapa.
- Aplicar outros tipos de filtros para analisar o desempenho das potências do novo padrão de potência da IEEE (IEEE, 2010) para medir desempenho em intervalos de transição.
- Desenvolvimento de identificação de eventos baseados nas ondas de corrente e tensão, eliminando a necessidade de cálculos das potências.
- Criação de protótipo de dispositivo embarcado com as implementações utilizadas no trabalho para teste em ambientes controlados e posterior estudo de viabilidade para comercialização.

# Anexos

## ANEXO A – Tabela de circuitos e *labels*

Label	Circuito
101	Lâmpada da mesa - sala de visita
102	Lâmpada alta da mesa - sala de visita
103	Porta da garagem
108	Triturador da cozinha
111	Geladeira
112	Sistema de audio e video - sala de visita
118	Computador 1
120	Laptop 1
123	Receptor/ DVR/ Bluray player - Porão
127	Compressor de ar
128	Monitor LCD
129	TV
131	Impressora
132	Secador de cabelo
134	Ferro de passar
135	Tomada livre- Sala de visita
140	Monitor 2
147	Luzes do quintal
148	Luz da lavanderia
149	Luzes do escritório
150	Luz do closet
151	Luz do corredor superior
152	Luz da escada do corredor
153	Luz da entrada da cozinha
155	Luz central da cozinha
156	Luzes do banheiro superior
157	Luz central da sala de jantar
158	Luzes do quarto
159	Luzes do porão
204	Circuito 4
207	Circuito 7
209	Circuito 9
210	Circuito 10
211	Circuito 11
>1000	Equipamentos desconhecidos

Tabela 40 – Tabela de circuitos e *labels*



# Referências

- ANDERSON, K. et al. Blued: A fully labeled public dataset for event-based non-intrusive load monitoring research. In: *Proceedings of the 2nd KDD workshop on data mining applications in sustainability (SustKDD)*. [S.l.: s.n.], 2012. p. 1–5. [20](#), [21](#), [24](#), [25](#)
- ANDERSON, K. D. et al. Event detection for non intrusive load monitoring. In: IEEE. *IECON 2012-38th Annual Conference on IEEE Industrial Electronics Society*. [S.l.], 2012. p. 3312–3317. [11](#), [36](#), [37](#), [47](#), [55](#), [60](#), [61](#)
- BAETS, L. D. et al. On the bayesian optimization and robustness of event detection methods in nilm. *Energy and Buildings*, Elsevier, v. 145, p. 57–66, 2017. [36](#), [37](#)
- BELGIU, M.; DRĂGUȚ, L. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 114, p. 24–31, 2016. [31](#)
- BENI, G. The concept of cellular robotic system. In: IEEE. *Proceedings IEEE International Symposium on Intelligent Control 1988*. [S.l.], 1989. p. 57–62. [39](#)
- BIANSOONGNERN, S.; PLANGKLANG, B. Nonintrusive load monitoring (nilm) using an artificial neural network in embedded system with low sampling rate. In: IEEE. *2016 13th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*. [S.l.], 2016. p. 1–4. [24](#), [31](#)
- BISHOP, J. Stochastic searching networks. In: IET. *1989 First IEE International Conference on Artificial Neural Networks, (Conf. Publ. No. 313)*. [S.l.], 1989. p. 329–331. [39](#)
- BORGES, D. M.; OLIVEIRA, F. L. Análise e comparação dos sistemas de recomendação de produtos existentes em três empresas de comércio eletrônico (ce): saraiva, submarino e amazon. *Submarino e Amazon*, 2010. [24](#)
- BOSCH, A.; ZISSERMAN, A.; MUNOZ, X. Image classification using random forests and ferns. In: IEEE. *2007 IEEE 11th international conference on computer vision*. [S.l.], 2007. p. 1–8. [31](#)
- BOULESTEIX, A.-L. et al. Overview of random forest methodology and practical guidance with emphasis on computational biology and bioinformatics. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, Wiley Online Library, v. 2, n. 6, p. 493–507, 2012. [31](#)
- BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, n. 1, p. 5–32, 2001. [32](#)
- BREIMAN, L. et al. Classification and regression trees. Wadsworth, 1984. [32](#)
- CHAMBERS, L. D. *The practical handbook of genetic algorithms: Applications*. [S.l.]: Chapman and Hall/CRC, 2000. [38](#)
- CHANG, H.-H. et al. Feature extraction of non-intrusive load-monitoring system using genetic algorithm in smart meters. In: IEEE. *2011 IEEE 8th International Conference on e-Business Engineering*. [S.l.], 2011. p. 299–304. [36](#)

- CHANG, H.-H. et al. Particle-swarm-optimization-based nonintrusive demand monitoring and load identification in smart meters. *IEEE Transactions on Industry Applications*, IEEE, v. 49, n. 5, p. 2229–2236, 2013. 36
- CHEN, X.; ISHWARAN, H. Random forests for genomic data analysis. *Genomics*, Elsevier, v. 99, n. 6, p. 323–329, 2012. 37
- DAVIS, G. A.; MASSARA, J. M. *Apparatus and method for controlling an electrical load and monitoring control operations and the electrical load*. [S.l.]: Google Patents, 1996. US Patent 5,576,700. 19
- DÍAZ-URIARTE, R.; ANDRES, S. A. D. Gene selection and classification of microarray data using random forest. *BMC bioinformatics*, BioMed Central, v. 7, n. 1, p. 3, 2006. 31
- DORIGO, M.; CARO, G. D. Ant colony optimization: a new meta-heuristic. In: IEEE. *Proceedings of the 1999 congress on evolutionary computation-CEC99 (Cat. No. 99TH8406)*. [S.l.], 1999. v. 2, p. 1470–1477. 39
- EBERHART, R.; KENNEDY, J. Particle swarm optimization. In: CITESEER. *Proceedings of the IEEE international conference on neural networks*. [S.l.], 1995. v. 4, p. 1942–1948. 39
- ENGLERT, F. et al. How to auto-configure your smart home?: High-resolution power measurements to the rescue. In: ACM. *Proceedings of the fourth international conference on Future energy systems*. [S.l.], 2013. p. 215–224. 21
- FALCÃO, D. M. Integração de tecnologias para viabilização da smart grid. *III Simpósio Brasileiro de Sistemas Elétricos*, p. 1–5, 2010. 19
- FARINACCIO, L.; ZMEUREANU, R. Using a pattern recognition approach to disaggregate the total electricity consumption in a house into the major end-uses. *Energy and Buildings*, Elsevier, v. 30, n. 3, p. 245–259, 1999. 36
- FIGUEIREDO, M.; ALMEIDA, A. D.; RIBEIRO, B. Home electrical signal disaggregation for non-intrusive load monitoring (nilm) systems. *Neurocomputing*, Elsevier, v. 96, p. 66–73, 2012. 24, 31
- FIGUEIREDO, M. B.; ALMEIDA, A. D.; RIBEIRO, B. An experimental study on electrical signature identification of non-intrusive load monitoring (nilm) systems. In: SPRINGER. *International Conference on Adaptive and Natural Computing Algorithms*. [S.l.], 2011. p. 31–40. 24, 31
- GONÇALVES, H. et al. Non-intrusive load monitoring. 2010. 36, 37
- HART, G. W. Nonintrusive appliance load monitoring. *Proceedings of the IEEE*, IEEE, v. 80, n. 12, p. 1870–1891, 1992. 19, 20, 21, 25, 27, 36
- IEEE. Ieee standard definitions for the measurement of electric power quantities under sinusoidal, nonsinusoidal, balanced, or unbalanced conditions. *IEEE Std 1459-2010 (Revision of IEEE Std 1459-2000)*, n. 1459-2010, p. 1–50, March 2010. 25, 27, 45, 75, 78
- ITO, M. et al. A method of appliance detection based on features of power waveform. In: IEEE. *2004 International Symposium on Applications and the Internet. Proceedings*. [S.l.], 2004. p. 291–294. 22

- JAMES, G. et al. *An introduction to statistical learning*. [S.l.]: Springer, 2013. v. 112. 34
- KATO, T. et al. Appliance recognition from electric current signals for information-energy integrated network in home environments. In: SPRINGER. *International Conference on Smart Homes and Health Telematics*. [S.l.], 2009. p. 150–157. 21, 22, 24, 31
- KELLY, J.; KNOTTENBELT, W. Neural nilm: Deep neural networks applied to energy disaggregation. In: ACM. *Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments*. [S.l.], 2015. p. 55–64. 24, 31
- KELLY, J.; KNOTTENBELT, W. The uk-dale dataset, domestic appliance-level electricity demand and whole-house demand from five uk homes. *Scientific data*, Nature Publishing Group, v. 2, p. 150007, 2015. 21, 25
- KOLTER, J. Z.; JOHNSON, M. J. Redd: A public data set for energy disaggregation research. In: *Workshop on Data Mining Applications in Sustainability (SIGKDD)*, San Diego, CA. [S.l.: s.n.], 2011. v. 25, n. Citeseer, p. 59–62. 21, 25
- KUMAR, C.; CHOUDHARY, A. A top-down approach to classify enzyme functional classes and sub-classes using random forest. *EURASIP Journal on Bioinformatics and Systems Biology*, Springer, v. 2012, n. 1, p. 1, 2012. 37
- LAM, H. Y.; FUNG, G.; LEE, W. A novel method to construct taxonomy electrical appliances based on load signatures of. *IEEE Transactions on Consumer Electronics*, IEEE, v. 53, n. 2, p. 653–660, 2007. 22
- LIANG, J. et al. Load signature study—part i: Basic concept, structure, and methodology. *IEEE transactions on power Delivery*, IEEE, v. 25, n. 2, p. 551–560, 2009. 22
- LIN, G.-y. et al. Applying power meters for appliance recognition on the electric panel. In: IEEE. *2010 5th IEEE Conference on Industrial Electronics and Applications*. [S.l.], 2010. p. 2254–2259. 24, 31
- LIN, Y.-H.; TSAI, M.-S.; CHEN, C.-S. Applications of fuzzy classification with fuzzy c-means clustering and optimization strategies for load identification in nilm systems. In: IEEE. *2011 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE 2011)*. [S.l.], 2011. p. 859–866. 31, 36
- LU, M.; LI, Z. A hybrid event detection approach for non-intrusive load monitoring. *arXiv preprint arXiv:1903.09180*, 2019. 11, 60, 61
- MARTI, K. *Stochastic optimization methods*. [S.l.]: Springer, 2005. v. 2. 38
- MAVROVOUNIOTIS, M.; LI, C.; YANG, S. A survey of swarm intelligence for dynamic optimization: Algorithms and applications. *Swarm and Evolutionary Computation*, Elsevier, v. 33, p. 1–17, 2017. 39
- MEEHAN, P. et al. Temporal and frequency analysis of power signatures for common household appliances. In: IET. *Symposium on ICT and Energy Efficiency and Workshop on Information Theory and Security (CICT 2012)*. [S.l.], 2012. p. 22–27. 22
- NARIÑO, G. A. R.; MARTHA, L. F.; MENEZES, I. F. M. de. *Otimização de risers em catenária com amortecedores hidrodinâmicos*. Dissertação (Mestrado) — PUC-Rio, 2014. 38

- NYQUIST, h. E. Certain topics in telegraph transmission theory. *Proc. IRE*, v. 37, p. 10–21, 1949. 27
- PARADISO, F. et al. Ann-based appliance recognition from low-frequency energy monitoring data. In: IEEE. *2013 IEEE 14th International Symposium on "A World of Wireless, Mobile and Multimedia Networks" (WoWMoM)*. [S.l.], 2013. p. 1–6. 21
- PATIL, M. S.; AGRAWAL, M. M.; BAVISKAR, M. V. R. Efficient processing of decision tree using id3 & improved c4. 5 algorithm. 2015. 32
- PINEDA, J. O. d. C. et al. A entropia segundo claude shannon: o desenvolvimento do conceito fundamental da teoria da informação. *Pontifícia Universidade Católica. São Paulo*, 2006. 31
- PROVOST, F.; KOHAVI, R. Glossary of terms. *Journal of Machine Learning*, v. 30, n. 2-3, p. 271–274, 1998. 53
- QI, Y. Random forest for bioinformatics. In: *Ensemble machine learning*. [S.l.]: Springer, 2012. p. 307–323. 31
- QUINLAN, J. R. Induction of decision trees. *Machine learning*, Springer, v. 1, n. 1, p. 81–106, 1986. 32
- QUINLAN, J. R. *C4. 5: programs for machine learning*. [S.l.]: Morgan Kaufmann, 1993. 32
- REINHARDT, A. et al. On the accuracy of appliance identification based on distributed load metering data. In: IEEE. *2012 Sustainable Internet and ICT for Sustainability (SustainIT)*. [S.l.], 2012. p. 1–9. 22
- REINHARDT, A. et al. Electric appliance classification based on distributed high resolution current sensing. In: IEEE. *37th Annual IEEE Conference on Local Computer Networks-Workshops*. [S.l.], 2012. p. 999–1005. 22
- RIDI, A.; GISLER, C.; HENNEBERT, J. Automatic identification of electrical appliances using smart plugs. In: IEEE. *2013 8th International Workshop on Systems, Signal Processing and their Applications (WoSSPA)*. [S.l.], 2013. p. 301–305. 21
- RIDI, A.; GISLER, C.; HENNEBERT, J. Unseen appliances identification. In: SPRINGER. *Iberoamerican Congress on Pattern Recognition*. [S.l.], 2013. p. 75–82. 21
- RODRIGUEZ-GALIANO, V. F. et al. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 67, p. 93–104, 2012. 31
- ROOS, J. et al. Using neural networks for non-intrusive monitoring of industrial electrical loads. In: IEEE. *Conference Proceedings. 10th Anniversary. IMTC/94. Advanced Technologies in I & M. 1994 IEEE Instrumentation and Measurement Technology Conference (Cat. No. 94CH3424-9)*. [S.l.], 1994. p. 1115–1118. 21, 36
- RUZZELLI, A. G. et al. Real-time recognition and profiling of appliances through a single electricity sensor. In: IEEE. *2010 7th Annual IEEE Communications Society Conference on Sensor, Mesh and Ad Hoc Communications and Networks (SECON)*. [S.l.], 2010. p. 1–9. 24, 31

- SAVIC, D. Single-objective vs. multiobjective optimisation for integrated decision support. 2002. [38](#)
- SHANNON, C. E. Communications in the presence of noise. *Proc. IRE*, v. 37, p. 10–21, 1949. [27](#)
- SRINIVASAN, D.; NG, W.; LIEW, A. Neural-network-based signature recognition for harmonic source identification. *IEEE transactions on power delivery*, IEEE, v. 21, n. 1, p. 398–405, 2005. [24](#), [31](#)
- STORN, R.; PRICE, K. Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization*, Springer, v. 11, n. 4, p. 341–359, 1997. [43](#)
- TAN, Y. et al. Introduction to fireworks algorithm. *International Journal of Swarm Intelligence Research (IJSIR)*, IGI Global, v. 4, n. 4, p. 39–70, 2013. [40](#)
- TAN, Y.; ZHU, Y. Fireworks algorithm for optimization. In: SPRINGER. *International conference in swarm intelligence*. [S.l.], 2010. p. 355–364. [39](#), [41](#), [43](#), [44](#)
- YANG, C. C.; SOH, C. S.; YAP, V. V. Comparative study of event detection methods for non-intrusive appliance load monitoring. *Energy Procedia*, Elsevier, v. 61, p. 1840–1843, 2014. [37](#)
- ZAIDI, A. A. et al. Load recognition for automated demand response in microgrids. In: IEEE. *IECON 2010-36th Annual Conference on IEEE Industrial Electronics Society*. [S.l.], 2010. p. 2442–2447. [22](#)
- ZIA, T.; BRUCKNER, D.; ZAIDI, A. A hidden markov model based procedure for identifying household electric loads. In: IEEE. *IECON 2011-37th Annual Conference of the IEEE Industrial Electronics Society*. [S.l.], 2011. p. 3218–3223. [24](#)
- ZOHA, A. et al. Non-intrusive load monitoring approaches for disaggregated energy sensing: A survey. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 12, n. 12, p. 16838–16866, 2012. [20](#)