



UNIVERSIDADE FEDERAL DO AMAZONAS  
FACULDADE DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**IDENTIFICAÇÃO POR DECOMPOSIÇÃO DE  
SINAIS DE CONSUMO DE ENERGIA ELÉTRICA**

Pierre Vilar Dantas

Manaus – Amazonas

Junho de 2016



Pierre Vilar Dantas

# IDENTIFICAÇÃO POR DECOMPOSIÇÃO DE SINAIS DE CONSUMO DE ENERGIA ELÉTRICA

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica na área de concentração de Processamento Digital de Sinais.

Orientador: Prof. D.Sc. Waldir Sabino da Silva Júnior

## Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

D192i Dantas, Pierre Vilar  
Identificação por decomposição de sinais de consumo de energia elétrica / Pierre Vilar Dantas. 2016  
78 f.: il.; 31 cm.

Orientador: Waldir Sabino da Silva Júnior  
Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Amazonas.

1. desagregação. 2. dicionários. 3. análise de parâmetros. 4. análise de componentes principais. 5. análise singular espectral. I. Silva Júnior, Waldir Sabino da II. Universidade Federal do Amazonas III. Título

Pierre Vilar Dantas

**IDENTIFICAÇÃO POR DECOMPOSIÇÃO DE  
SINAIS DE CONSUMO DE ENERGIA ELÉTRICA**

Banca Examinadora

Prof. D.Sc. Waldir Sabino da Silva Júnior  
Presidente e Orientador

Prof. D.Sc. Celso Barbosa Carvalho

Profa. Ph.D. Eulanda Miranda dos Santos

Manaus – Amazonas

Junho de 2016

# Agradecimentos

Aos meus pais, Juarez e Jandira.

À minha esposa Acácia e ao meu filho Heitor.

Ao meu orientador Prof. D.Sc. Waldir Sabino da Silva Júnior.

Ao Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) da Universidade Federal do Amazonas (UFAM).

A Deus e aos amigos do plano espiritual.

Parte dos resultados apresentados neste trabalho foram obtidos através do Projeto de Pesquisa e formação de recursos humanos, em nível de graduação e pós-graduação, nas áreas de automação industrial, software para dispositivos móveis e TV Digital, financiado pela Samsung Eletrônica da Amazônia Ltda., no âmbito da Lei nº 8.387/91, Art. 2º. Esta pesquisa também foi financiada com recursos da Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM).

Resumo da Dissertação apresentada à UFAM como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica

## IDENTIFICAÇÃO POR DECOMPOSIÇÃO DE SINAIS DE CONSUMO DE ENERGIA ELÉTRICA

Pierre Vilar Dantas

Orientador: Waldir Sabino da Silva Júnior

Programa: Pós-Graduação em Engenharia Elétrica

Na técnica de identificação por decomposição de sinais de consumo de energia elétrica, inferimos o consumo dos dispositivos que compõem um sinal de consumo de energia elétrica. Essa técnica, também denominada de desagregação ou monitoramento não intrusivo, é relevante porque viabiliza obtermos informação sobre o consumo energético individualizado de dispositivos, o que permite outras abordagens sobre o gerenciamento energético, viabiliza uso em redes inteligentes (*smart grids*) e internet das coisas (IoT). O problema de desagregação de energia pode ser tratado através de técnicas por dicionários onde extraímos representatividades de um conjunto de dados de consumo de energia elétrica e realizamos a desagregação. Em nossa proposta, podemos destacar duas contribuições. Na primeira, modificamos o algoritmo steady-state identification (SSI) para contemplar sinais com dimensões variáveis e, a seguir, realizamos uma análise de parâmetros que influenciam na formação dos dicionários e, por consequência, produzem diferentes desempenhos de desagregação. Na segunda, propomos uma metodologia de desagregação por análise de componentes principais. Os experimentos realizados, utilizando a base de dados REDD [1], demonstram que a proposta produz resultados de desagregação de maior acurácia, quando comparado com outras técnicas.

Palavras-chave: desagregação, dicionários, análise de parâmetros, análise de componentes principais, análise singular espectral.

Abstract of Dissertation presented to UFAM as a partial fulfillment of the requirements for the degree of Master in Electrical Engineering

## ELECTRICAL POWER CONSUMPTION SIGNAL DISAGGREGATION

Pierre Vilar Dantas

Advisor: Waldir Sabino da Silva Júnior

Department: Postgraduate in Electrical Engineering

The identification by decomposition of electricity consumption signals technique, we estimate the consumption of devices that form a power consumption signal. This technique, that can be called disaggregation or nonintrusive load monitoring, is important because it makes possible obtain information about the individual energy consumption of devices, allowing other approaches like power management, use in smart grids and Internet of Things (IoT). Energy disaggregation problem can be approached through dictionaries techniques, which summarize the most significant characteristics of the signals involved to signal disaggregation. In our proposal, we highlight two contributions. In the first, we modify the steady-state identification (SSI) algorithm to deal with signals with variable dimensions and, then, we conducted a parameter analysis that changes the dictionaries and consequently produces different performances of disaggregation. Second, we propose a disaggregation methodology using principal component analysis (PCA). The experiments were made using REDD database [1] and they demonstrate that the proposal produces results with higher accuracy when compared with other techniques.

Keywords: disaggregation; dictionaries; parameter analysis, principal component analysis; singular spectrum analysis.



# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Organização da Dissertação . . . . .	2
<b>2</b>	<b>Fundamentos Teóricos</b>	<b>3</b>
2.1	Introdução . . . . .	3
2.2	Monitoramento Não Intrusivo de Cargas Elétricas . . . . .	4
2.3	Procedimentos para Monitoramento Não Intrusivo de Cargas Elétricas	4
2.3.1	Aquisição de Dados . . . . .	7
2.3.2	Identificação de Eventos . . . . .	7
2.3.3	Assinaturas . . . . .	8
2.3.4	Dicionários . . . . .	10
2.3.5	Procedimento de Desagregação . . . . .	11
2.4	Análise de Componentes Principais . . . . .	12
2.5	Análise Singular Espectral . . . . .	13
2.6	Considerações Finais . . . . .	15
<b>3</b>	<b>Procedimento Proposto para Monitoramento Não Intrusivo de Si-</b>	
	<b>nais de Consumo de Energia Elétrica</b>	<b>16</b>
3.1	Introdução . . . . .	16
3.2	Método de Identificação de Estados Estacionários . . . . .	18
3.3	Assinaturas . . . . .	20
3.4	Dicionários . . . . .	23
3.5	Desagregação . . . . .	24
3.6	Considerações Finais . . . . .	26

<b>4</b>	<b>Procedimentos Experimentais</b>	<b>28</b>
4.1	<i>Setup</i> dos Experimentos . . . . .	28
4.2	Base de Dados . . . . .	29
4.3	Parâmetros que Influenciam na Desagregação . . . . .	30
4.4	Planejamento dos Experimentos . . . . .	31
4.5	Descrição das Métricas . . . . .	32
4.6	Resultados . . . . .	33
4.6.1	Acurácia da Desagregação . . . . .	33
4.6.2	Comparação da Acurácia de Desagregação com Outras Metodologias . . . . .	36
4.6.3	Erro Médio Quadrático de Desagregação dos Dispositivos . . . . .	37
4.7	Análises dos Resultados . . . . .	41
4.7.1	Acurácia da Desagregação . . . . .	41
4.7.2	Método de Organização da Matriz de Soluções de Desagregação <b>C</b> . . . . .	41
4.7.3	Erro Médio Quadrático de Desagregação dos Sinais de Consumo de Energia Elétrica dos Dispositivos . . . . .	41
4.8	Considerações Finais . . . . .	41
<b>5</b>	<b>Procedimento Proposto para Monitoramento Não Intrusivo de Sinais de Consumo de Energia Elétrica Usando Análise de Componentes Principais</b>	<b>43</b>
5.1	Introdução . . . . .	43
5.2	Dicionário . . . . .	44
5.3	Procedimento de Desagregação . . . . .	46
5.4	Considerações Finais . . . . .	48
<b>6</b>	<b>Procedimentos Experimentais</b>	<b>50</b>
6.1	<i>Setup</i> dos Experimentos, Base de Dados e Métricas . . . . .	50
6.2	Planejamento dos Experimentos . . . . .	50
6.3	Resultados . . . . .	52
6.3.1	Apresentação da Acurácia de Desagregação de Outras Metodologias e da Metodologia Proposta . . . . .	52

6.3.2	Erro Médio Quadrático de Desagregação dos Dispositivos . . .	53
6.4	Análise dos Resultados . . . . .	53
6.4.1	Acurácia da Desagregação . . . . .	53
<b>7</b>	<b>Conclusões</b>	<b>55</b>
7.1	Considerações Finais . . . . .	55
7.2	Propostas para Trabalhos Futuros . . . . .	55
	<b>Referências Bibliográficas</b>	<b>57</b>
<b>A</b>	<b>Algoritmo Dissimilarity-based Sparse Subset Selection (DS3)</b>	<b>61</b>

# Lista de Figuras

2.1	Extração de dicionários de sinal de consumo de energia elétrica. . . . .	6
2.2	Desagregação de um sinal de consumo de energia elétrica. . . . .	6
2.3	Estados estacionários e transições em um sinal de consumo de energia elétrica com $s_{min} = 3$ e $\epsilon = 4$ . . . . .	8
2.4	Variação dos parâmetros $s_{min}$ e $\epsilon$ na identificação de estados estacionários. . . . .	9
2.5	Tipos de operação de equipamentos. . . . .	9
2.6	Exemplos de assinaturas representadas por diagrama de estados finitos. . . . .	10
3.1	Representação da matriz de assinaturas $\mathbf{S}$ em forma matricial e em diagrama de estados finitos. . . . .	22
4.1	Acurácia da desagregação. . . . .	34
4.2	Acurácia da desagregação. . . . .	36
4.3	Erro médio quadrático da desagregação do dispositivo 1. . . . .	38
4.4	Erro médio quadrático da desagregação do dispositivo 2. . . . .	38
4.5	Erro médio quadrático da desagregação do dispositivo 3. . . . .	38
4.6	Erro médio quadrático da desagregação do dispositivo 4. . . . .	39
4.7	Erro médio quadrático da desagregação do dispositivo 5. . . . .	39
4.8	Erro médio quadrático da desagregação do dispositivo 6. . . . .	39
4.9	Erro médio quadrático da desagregação do dispositivo 7. . . . .	40
4.10	Erro médio quadrático da desagregação do dispositivo 8. . . . .	40
4.11	Erro médio quadrático da desagregação do dispositivo 9. . . . .	40
5.1	Extração de dicionários usando SSA. . . . .	45
5.2	Desagregação de um sinal de consumo de energia elétrica usando SSA. . . . .	47

# Lista de Algoritmos

1	<i>Steady-state identification variable dimension</i> (SSI-VD) . . . . .	21
2	<i>Steady-state identification similar dimension</i> (SSI-SD) . . . . .	21
3	Extração das assinaturas . . . . .	22
4	Extração de dicionários . . . . .	24
5	Elaboração da matriz de soluções de desagregação . . . . .	25
6	Procedimento de desagregação . . . . .	26
7	Elaboração do dicionário usando SSA . . . . .	46
8	Execução da desagregação usando SSA . . . . .	49
9	<i>Algoritmo</i> Dissimilarity-based Sparse Subset Selection ( <i>DS3</i> ) . . . . .	61

# Lista de Tabelas

4.1	Identificação dos dispositivos da casa nº 2 do REDD [1]. . . . .	30
4.2	Combinações dos parâmetros que influenciam a desagregação. . . . .	31
4.3	Métodos de organização da matriz de soluções de desagregação <b>C</b> . . .	32
4.4	Combinações dos parâmetros que influenciam a desagregação. . . . .	34
4.5	Acurácia de metodologias aplicadas à casa nº 2 da base de dados REDD [1]. . . . .	37
4.6	Acurácia da metodologia SSI-SD (proposta) de acordo com o método de organização da matriz de soluções de desagregação <b>C</b> , usando a casa nº 2 da base de dados REDD [1]. . . . .	37
6.1	Valores dos parâmetros usados na desagregação . . . . .	52
6.2	Acurácia de metodologias aplicadas à casa nº 2 da base de dados REDD [1]. . . . .	53
6.3	Acurácia das metodologias SSI-SD e SSI-SD-PCA (propostas), usando a casa nº 2 da base de dados REDD [1]. . . . .	53
6.4	Erro médio quadrático de desagregação dos dispositivos . . . . .	54

# Lista de Símbolos

$L$	quantidade de dispositivos que compõem um sistema de consumo de energia elétrica
$i$	índice do dispositivo que compõe o sinal de consumo de energia elétrica total, $i = \{1, 2, \dots, L\}$
$s_{min}$	quantidade mínima de amostras de um estado estacionário
$\epsilon$	amplitude máxima entre amostras de um estado estacionário
$\gamma$	parâmetro de regularização do algoritmo DS3
$\Gamma$	matriz de parâmetros de regularização do algoritmo DS3
$\alpha$	parâmetro de correção do algoritmo DS3
$\bar{x}(t)$	sinal de consumo de energia elétrica total que se deseja desagregar
$x(t)$	sinal de consumo de energia elétrica total
$x_i(t)$	sinal de consumo de energia elétrica do dispositivo $i$
$x_m(t)$	sinal de consumo de energia elétrica reconstruído de $m$ componentes SVD
$\hat{x}(t)$	sinal de consumo de energia elétrica total estimado de $x(t)$
$\hat{x}_i(t)$	sinal de consumo de energia elétrica estimado de $x_i(t)$
$P^{(m)}$	vetor de índice $m$
$P^{(m)}(j)$	elemento $j$ do vetor $P^{(m)}$
$\bar{\mathbf{X}}$	matriz de estados estacionários de $\bar{x}(t)$
$\mathbf{X}$	matriz de estados estacionários de $x(t)$
$\mathbf{X}_i$	matriz de estados estacionários de $x_i(t)$
$\bar{\mathbf{B}}$	dicionário de $\bar{x}(t)$
$\mathbf{B}$	dicionário de $x(t)$
$\mathbf{B}_i$	dicionário de $x_i(t)$
$\mathcal{B}$	dicionário composto de $x(t)$ e $x_i(t)$
$\bar{\mathbf{S}}$	matriz de assinaturas de $\bar{x}(t)$

$\mathbf{S}$	matriz de assinaturas de $x(t)$
$\mathbf{S}_i$	matriz de assinaturas de $x_i(t)$
$\mathbf{T}$	matriz de segmentação PCA de $x(t)$
$\mathbf{T}_i$	matriz de segmentação PCA de $x_i(t)$
$w$	dimensão da matriz de segmentação $\mathbf{T}$ e $\mathbf{T}_i$
$\bar{\mathbf{D}}$	matriz de dissimilaridade de $\bar{x}(t)$
$\mathbf{D}$	matriz de dissimilaridade de $x(t)$
$\mathbf{D}_i$	matriz de dissimilaridade de $x_i(t)$
$\mathbf{G}_k$	matriz de dissimilaridade PCA
$\bar{\mathbf{Z}}$	matriz de dissimilaridade normalizada de $\bar{x}(t)$
$\mathbf{Z}$	matriz de dissimilaridade normalizada de $x(t)$
$\mathbf{Z}_i$	matriz de dissimilaridade normalizada de $x_i(t)$
$\mathbf{C}$	matriz de soluções de desagregação
$\mathbf{H}$	matriz de <i>Hankel</i>
$\ell$	dimensão da matriz de <i>Hankel</i>
$\mathbf{H}_m$	matriz de <i>Hankel</i> reconstruída de $m$ componentes SVD
$\mathbf{H}\mathbf{H}^T$	matriz de correlação de $\mathbf{H}$
$\mathcal{H}$	operador da transformação de <i>Hankel</i>
$\mathcal{H}^{-1}$	operador da transformação inversa de <i>Hankel</i>
$\chi$	variável aleatória
$\Sigma_\chi$	matriz de covariância de $\chi$ com média igual a zero
$\Phi$	matriz de autovetores ortogonais de $\Sigma_\chi$
$\Phi^*$	conjugado transposto de $\Phi$
$\phi$	vetor da base ortonormal de $\Phi$
$\Lambda$	matriz diagonal de autovalores de $\Sigma_\chi$
$\lambda$	autovalor da matriz $\Lambda$
$\oplus P^{(m)}$	autovetores das $m$ componentes de maior energia PCA
$\oplus \lambda^{(m)}$	autovalores das $m$ componentes de maior energia PCA
$Y, Q, P$	vetores de indexação da matriz de soluções de desagregação $\mathbf{C}$



# Lista de Abreviaturas

<b>DS3</b>	<i>Dissimilarity-based Sparse Subset Selection</i>
<b>FHMM</b>	<i>Factorial Hidden Markov Model</i>
<b>HMM</b>	<i>Hidden Markov Model</i>
<b>IoT</b>	<i>Internet of Things</i>
<b>KNN</b>	<i>k-Nearest Neighbors</i>
<b>PCA</b>	<i>Principal Component Analysis</i>
<b>REDD</b>	<i>Reference Energy Disaggregation Data Set</i>
<b>SSA</b>	<i>Singular Spectrum Analysis</i>
<b>SSI</b>	<i>Steady-state Identification</i>
<b>SSI-SD</b>	<i>Steady-state Identification Similar Dimension</i>
<b>SSI-SD-PCA</b>	<i>Steady-state Identification - Similar Dimension - Principal Component Analysis</i>
<b>SSI-VD</b>	<i>Steady-state Identification - Variable Dimension</i>
<b>SVD</b>	<i>Singular Value Decomposition</i>
<b>SVM</b>	<i>Support Vector Machine</i>
<b>UTC</b>	<i>Universal Time Coordinated</i>

# Capítulo 1

## Introdução

O monitoramento não intrusivo de cargas elétricas é uma área de constante pesquisa e de grande interesse pela comunidade científica. Com um medidor de energia instalado na entrada de um sistema de potência elétrica, estimamos o consumo individual de energia das cargas que compõem este sistema [2–7]. No âmbito das redes inteligentes (*smart grids*), é possível reduzir significativamente os custos das medições e permitir mais possibilidades de gerenciamento. No âmbito da internet das coisas (*Internet of Things* - IoT), aumenta a viabilidade da conexão entre dispositivos.

O enfoque dos primeiros estudos nesta área foi analisar os eventos de transição do sinal de consumo de energia elétrica total e verificar a correlação entre alguns parâmetros como tensão, corrente, potência ativa e potência reativa [2]. Outras pesquisas analisaram o monitoramento não intrusivo em prédios comerciais, mostrando-se uma abordagem mais complexa, pois o sinal de consumo total de energia, nestes casos, pode ser composto por dezenas ou centenas de dispositivos com diferentes estados de operação [5]. Surgiram outras abordagens com diferentes enfoques, como a identificação dos padrões de operação dos dispositivos no domínio da frequência [8], por transformada *Wavelet* [3], redes neurais [9], representação esparsa [10] e modelos ocultos de Markov [6, 11].

Verificamos, nas pesquisas anteriores, ausência de critérios claros na escolha de valores de alguns parâmetros do procedimento de desagregação, como os usados para identificar estados estacionários nos sinais de consumo de energia, elaborar assinaturas dos dispositivos, extrair dicionários, realizar a desagregação e determinar

o desempenho da desagregação. Isso pode proporcionar resultados de desagregação incoerentes com aspectos práticos do sistema analisado e dificulta a comparação de resultados entre diferentes metodologias de desagregação. Assim, estudamos o procedimento geralmente usado na desagregação e modificamos um conjunto de parâmetros para analisar a influência nos resultados, o que nos permitiu propor uma modificação em uma das etapas do procedimento de desagregação, simplificando o procedimento. Esses resultados são expressos numericamente por métricas de medição de desempenho da desagregação. Uma segunda proposta nesta foi estabelecer uma metodologia de desagregação por análise de componentes principais (do inglês, *principal component analysis* - PCA).

## 1.1 Organização da Dissertação

Esta dissertação apresenta-se dividida em três capítulos. No **Capítulo 2**, apresentamos os fundamentos teóricos do monitoramento não intrusivo de um sinal de consumo de energia elétrica e o procedimento geralmente usado na desagregação de um sinal de consumo de energia elétrica. No **Capítulo 3**, apresentamos o procedimento proposto para monitoramento não intrusivo de consumo de energia elétrica. Modificamos o método geralmente usado para identificar estados estacionários em sinais de consumo de energia elétrica. No **Capítulo 4**, detalhamos os procedimentos experimentais de aquisição de dados de consumo de energia elétrica, as análises dos parâmetros que influenciam no desempenho da desagregação, o planejamento dos experimentos e os resultados. No **Capítulo 5**, apresentamos o procedimento proposto para monitoramento não intrusivo de consumo de energia elétrica usando análise de componentes principais (PCA). No **Capítulo 6**, detalhamos os procedimentos experimentais de desagregação de um sinal de consumo de energia elétrica usando análise de componentes principais, o planejamento dos experimentos e os resultados. Neste caso, comparamos os resultados com técnicas existentes na literatura. O **Capítulo 7** contém conclusões gerais da dissertação.

# Capítulo 2

## Fundamentos Teóricos

Nesta seção, apresentamos os fundamentos teóricos geralmente aplicados ao procedimento de desagregação de um sinal de consumo de energia elétrica. Apresentamos o conceito de monitoramento não intrusivo e os procedimentos geralmente adotados para realizar a desagregação por uma abordagem usando aprendizado supervisionado. Detalhamos as etapas do procedimento, iniciando em como podemos adquirir uma base de dados com informações de consumo de energia; como identificamos eventos de estados estacionários e de transição em um sinal de consumo de energia elétrica e os parâmetros que devem ser considerados; como identificamos as assinaturas dos sinais de consumo de energia, os padrões de operação do sistema; como extraímos os dicionários e os algoritmos que podemos utilizar para isto; e como podemos processar a desagregação. Apresentamos as técnicas denominadas análise de componentes principais (do inglês, *principal component analysis* - PCA) e análise singular espectral (do inglês, *singular spectrum analysis* - SSA), usadas na proposta de um procedimento para desagregação de um sinal de consumo de energia elétrica.

### 2.1 Introdução

Na técnica de decomposição de um sinal de consumo de energia elétrica por identificação, inferimos o consumo dos dispositivos que compõem um sinal de consumo de energia elétrica total (agregado). A desagregação de um sinal de consumo de energia elétrica total pode ser realizada por técnicas de monitoramento não intrusivo, onde estimamos o consumo de energia elétrica dos dispositivos que com-

põem este sinal, conhecendo apenas o sinal de consumo de energia elétrica total. A abordagem pode ser realizada em duas etapas onde, inicialmente, elaboramos um dicionário com representatividades dos modos de operação dos sinais de consumo de energia elétrica total e dos sinais de consumo de energia elétrica dos dispositivos que compõem o sistema e, por fim, decodificamos o sinal de consumo de energia elétrica total, estimando os estados de operação dos sinais de consumo de energia dos dispositivos.

## 2.2 Monitoramento Não Intrusivo de Cargas Elétricas

O monitoramento não intrusivo de cargas elétricas é uma técnica em que são estimados os estados de operação de cargas elétricas que compõem um consumo de energia elétrica total [2]. Esse procedimento é normalmente denominado *desagregação* e pode ser realizado pela análise do consumo de energia elétrica no domínio do tempo [12], domínio da frequência [4,5], transformada *Wavelet* [8], redes neurais [9], representação esparsa [10] ou modelos ocultos de Markov [6,11]. Como vantagem, o monitoramento não intrusivo dispensa instalação de medidores individuais de cargas, permitindo determinar o consumo individual de energia elétrica dos dispositivos com baixo investimento [1]. Do ponto de vista da concessionária de energia, permite entender melhor o consumo e, assim, melhora o gerenciamento dos sistemas de geração e distribuição, permitindo um planejamento mais eficiente.

## 2.3 Procedimentos para Monitoramento Não Intrusivo de Cargas Elétricas

Nesta seção, apresentaremos os procedimentos para realizar a desagregação de um sinal de consumo de energia elétrica total  $x(t)$  utilizando monitoramento não intrusivo. Para tal, é necessário caracterizarmos matematicamente o sinal de consumo de energia elétrica total  $x(t)$ . Uma abordagem pode ser feita supondo que o sinal de consumo de energia elétrica total  $x(t)$ , em um período de tempo

$\{1, 2, \dots, T\}$ , é representado por:

$$x(t) = [x(1), x(2), \dots, x(T)] \quad (2.1)$$

onde, na equação (2.1), o sinal de consumo de energia elétrica total  $x(t)$  é uma combinação linear de  $L$  sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, com  $i = \{1, 2, \dots, L\}$ . Assim, o sinal de consumo de energia elétrica total  $x(t)$  se relaciona com os sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, da seguinte maneira:

$$x(t) = \sum_{i=1}^L x_i(t) \quad (2.2)$$

Combinando as equações (2.1) e (2.2) caracterizamos o problema da desagregação de um sinal de consumo de energia elétrica total. A premissa, neste caso, é que todos os dispositivos estão sempre presentes no sistema. Assim, é necessário utilizarmos alguma abordagem para encontrar a relação que estas equações implicam. Realizamos um procedimento de desagregação em duas etapas. Na primeira, de acordo com a Figura 2.1, adquirimos<sup>①</sup> o sinal de consumo da energia elétrica total  $x(t)$ , também denominado sinal agregado ou geral, e os sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos. A seguir, identificamos<sup>②</sup> os modos de operação do sinal de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, como transições e estados estacionários [13] e os agrupamos<sup>③</sup> em conjuntos organizados denominados *assinaturas*. Por fim, criamos os dicionários<sup>④</sup> que são representatividades dos estados estacionários ou das assinaturas, que correspondem a uma representação sumarizada dos estados de operação do sinal de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos [7].

Na segunda etapa, de acordo com a Figura 2.2, processamos a desagregação do sinal de consumo de energia elétrica total  $x(t)$  com o propósito de estimar os sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, representando-os por  $\hat{x}(t)$  e  $\hat{x}_i(t)$ . Para isso, aplicamos<sup>⑥</sup> algoritmos de correspondência de padrões, buscando similaridades (*matching*) entre o sinal de consumo de energia elétrica total  $x(t)$  e os dicionários. Observe que, nesta etapa, adquirimos<sup>⑤</sup> apenas o sinal de consumo

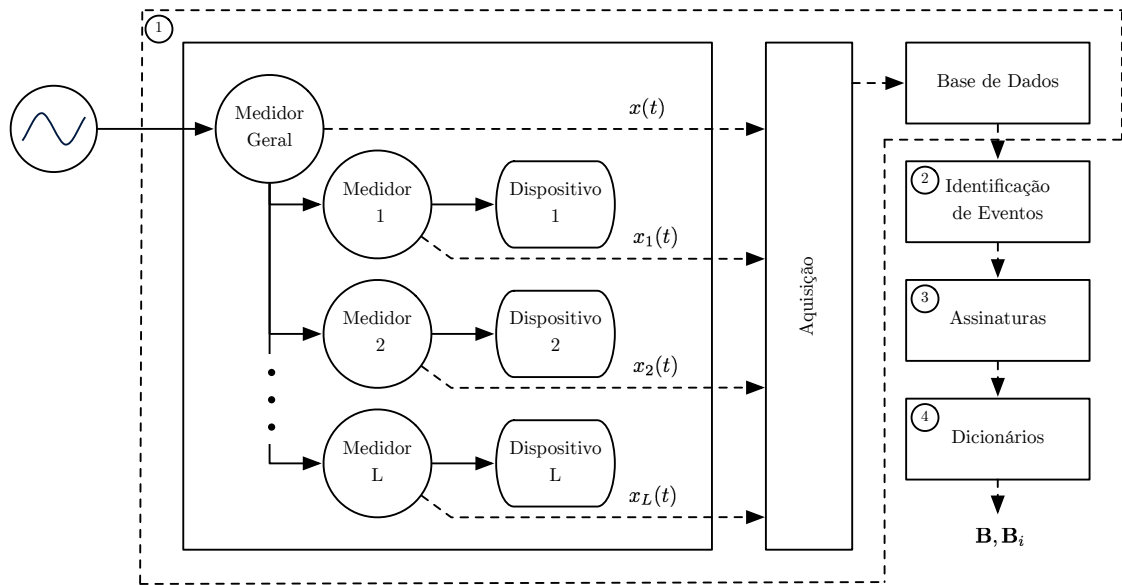


Figura 2.1: Extração de dicionários de sinal de consumo de energia elétrica.

de energia elétrica total  $x(t)$  e usamos<sup>④</sup> os dicionários elaborados na primeira etapa do procedimento. Além disso, podemos usar algumas metodologias para calcular a acurácia (desempenho) da desagregação e verificarmos a precisão entre os sinais de consumo de energia elétrica  $x_i(t)$  e os sinais de consumo de energia elétrica estimados  $\hat{x}_i(t)$  dos dispositivos, [13]. Ilustramos esta situação na Figura 2.2. Nas seções seguintes, apresentaremos os pontos relevantes e particularidades deste procedimento.

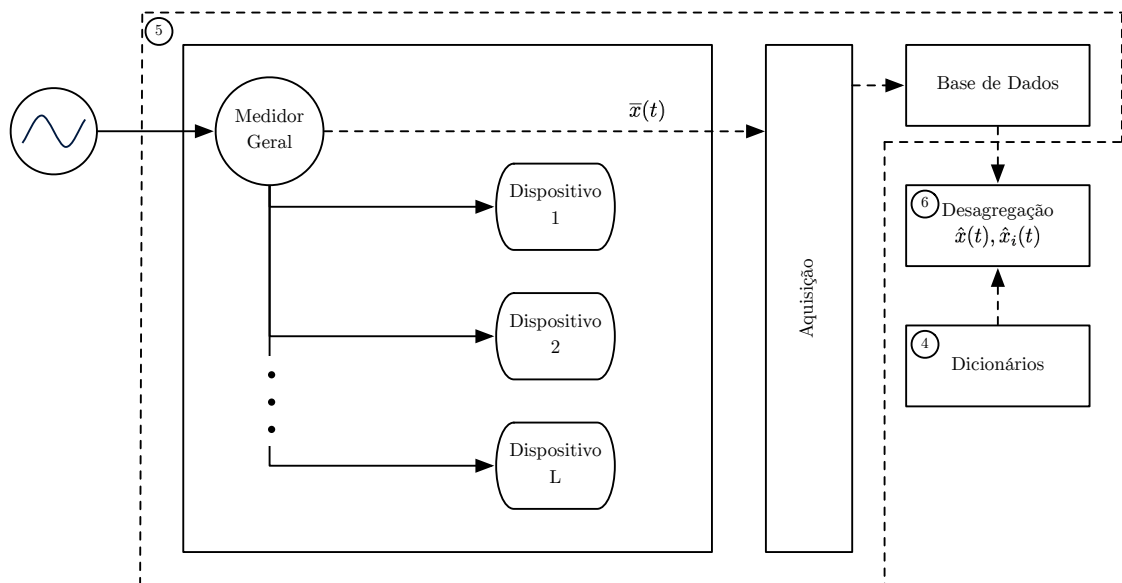


Figura 2.2: Desagregação de um sinal de consumo de energia elétrica.

### 2.3.1 Aquisição de Dados

A aquisição de um sinal de consumo de energia elétrica pode ser realizada mediante processamento digital. Isso pode ser feito por sistemas de baixa complexidade, que operam em frequências de aquisição de sinais de consumo de energia elétrica variando de 1 Hz a 15 kHz [7], ou por sistemas complexos, que operam em frequências variando de 200 kHz a 1 MHz [5]. Para compormos o sistema de aquisição, geralmente precisamos instalar sensores, dispositivos de monitoramento, rede de comunicação e armazenamento. Isso pode ser feito de três formas: na primeira, desenvolvemos um sistema próprio de aquisição, contemplando o projeto e instalação de todos os componentes do procedimento [4, 5]. Na segunda, utilizamos soluções disponíveis comercialmente [1, 13] e, por último, utilizamos uma base de dados existente que contém informação de consumo de energia elétrica [11, 12].

### 2.3.2 Identificação de Eventos

Os sinais de consumo de energia elétrica total  $x(t)$  e os sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, possuem estados de operação aproximadamente constantes, denominados estados estacionários  $X$ , e estados de transição caracterizados pela mudança entre os estados de operação, conforme pode ser visualizado na Figura 2.3, onde temos três estados estacionários  $X_1, X_2, X_3$  e dois estados de transição  $t_1, t_2$ . Os estados estacionários do sinal de consumo de energia elétrica total são agrupados na matriz  $\mathbf{X}$ , de forma que  $\mathbf{X} = [X_1, X_2, X_3, \dots]$ , e os estados estacionários dos sinais de consumo de energia  $x_i(t)$  dos dispositivos, são agrupados semelhantemente nas matrizes  $\mathbf{X}_i$ .

Para identificarmos os eventos de estados estacionários e os de transição em um sinal de consumo de energia elétrica, podemos usar o método denominado *steady-state identification* (SSI) [2, 13], onde primeiramente estabelecemos dois parâmetros:  $s_{min}$ , correspondente à quantidade mínima de amostras necessárias para caracterizar um estado estacionário, e  $\epsilon$ , referente à diferença de amplitude máxima entre as amostras do estado estacionário. Em seguida, analisamos cada conjunto de amostras do sinal de consumo de energia elétrica, a partir de  $t = 1$ , procurando identificar estados estacionários de acordo com os parâmetros  $s_{min}$  e  $\epsilon$ . As amostras que não atendem às especificações destes dois parâmetros formam um estado de transição.



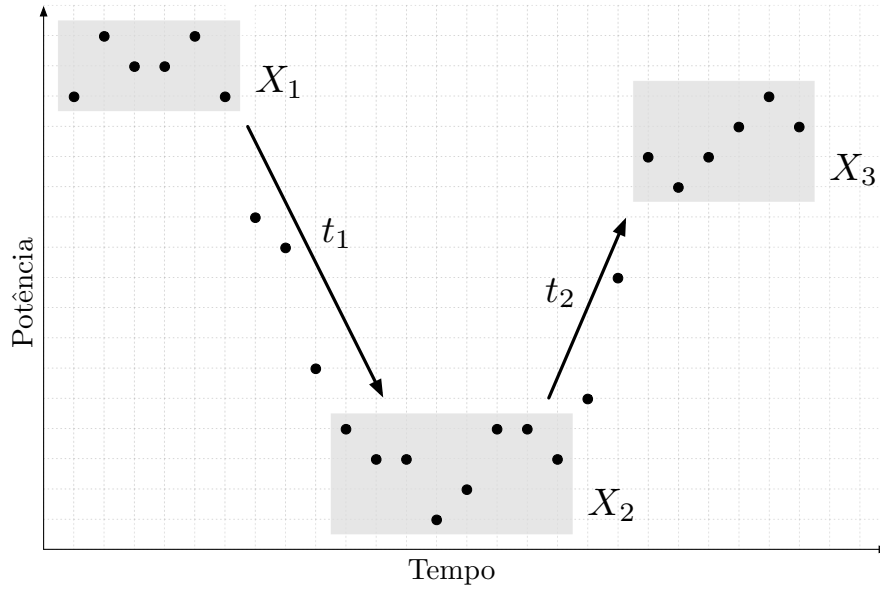


Figura 2.3: Estados estacionários e transições em um sinal de consumo de energia elétrica com  $s_{min} = 3$  e  $\epsilon = 4$ .

Como não estabelecemos limite máximo de quantidade de amostras que podem compor um estado estacionário, geralmente identificamos estados estacionários de diferentes dimensões [13].

Quando variamos os valores de  $s_{min}$  e  $\epsilon$ , modificamos a identificação de estados estacionários e de transição, conforme ilustramos na Figura 2.4. Geralmente, os valores destes dois parâmetros são determinados mediante conhecimento empírico da natureza dos sinais de consumo de energia elétrica [2] e a maioria das pesquisas não explora os critérios usados para suas especificações [1, 2, 13].

### 2.3.3 Assinaturas

Um dispositivo possui modos de operação que podem ocorrer repetidamente ao longo do tempo [2]. Esta é uma característica determinada em seu projeto e corresponde às potências elétricas nominais de operação e às transições que podem ocorrer, geralmente decorrentes da operação. Podemos categorizar os dispositivos em quatro tipos de modo de operação, conforme apresentamos na Figura 2.5. O primeiro, de equipamentos com apenas dois estados de operação, ligado e desligado, como lâmpadas; o segundo, de equipamentos com vários estados de operação, representados por máquinas de estados finitos, como máquina de lavar e microondas; o

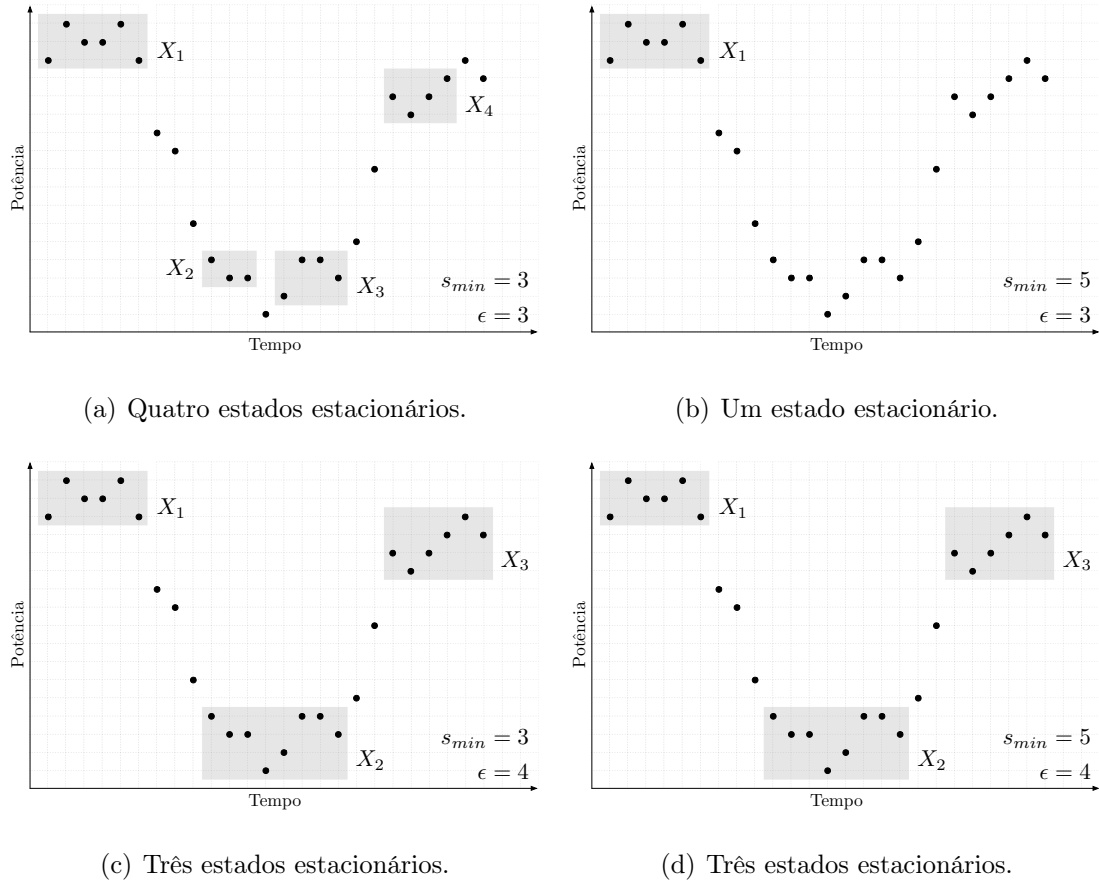


Figura 2.4: Variação dos parâmetros  $s_{min}$  e  $\epsilon$  na identificação de estados estacionários.

terceiro, de equipamentos com infinitos estados de operação, como lâmpadas dimmerizáveis e, o quarto, de equipamentos sempre ligados, como sistemas de segurança.

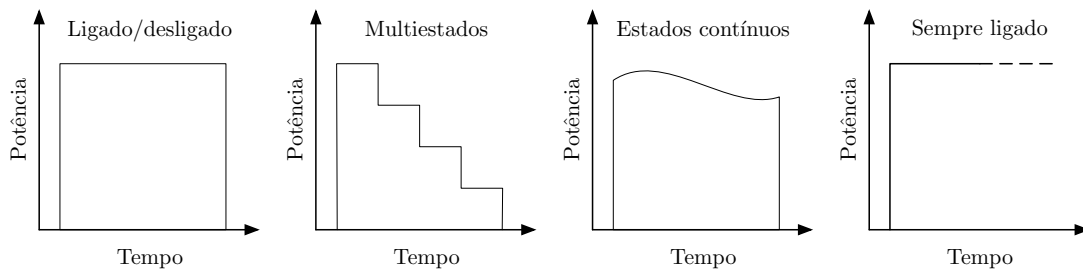


Figura 2.5: Tipos de operação de equipamentos.

Os eventos de estados estacionários e de transição em um sinal de consumo de energia elétrica podem ocorrer em seqüências que se repetem diversas vezes. Quando relacionamos estados estacionários em uma seqüência predeterminada, temos uma

*assinatura* do sinal de consumo de energia elétrica [2]. Note que podemos identificar diversas sequências deste tipo e também diferentes no sinal. Dessa forma, um sinal poderá ter diferentes assinaturas [13]. As formas mais comuns de representar as assinaturas são por gráficos de potência elétrica *versus* tempo, como na Figura 2.5, por modelos de estados finitos, como na Figura 2.6 ou por matrizes [2].

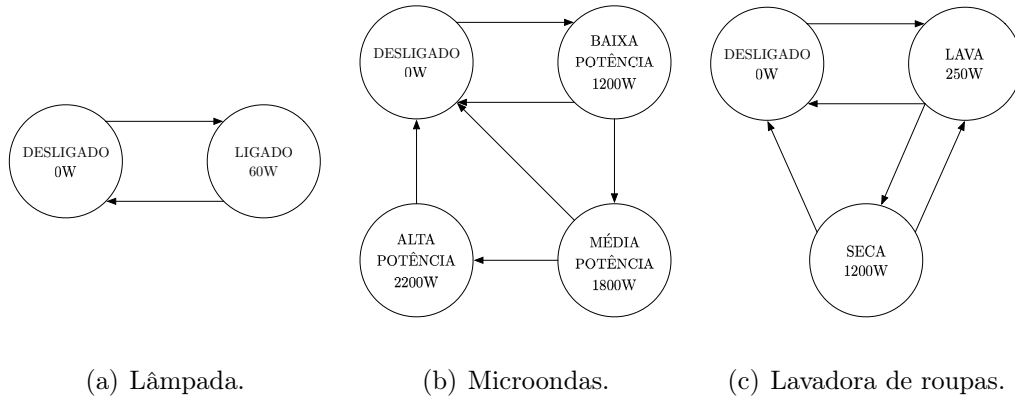


Figura 2.6: Exemplos de assinaturas representadas por diagrama de estados finitos.

### 2.3.4 Dicionários

Em diversas situações, é mais apropriado trabalharmos com representatividades de um determinado conjunto de dados, sendo esta uma condição comum na área de processamento de sinais [14]. Representatividades são subconjuntos de um conjunto de dados, extraídas de forma que as propriedades e características sejam conservadas. No contexto da desagregação de um sinal de consumo de energia elétrica total  $x(t)$ , trabalhar com representatividades do conjunto de estados estacionários ou assinaturas torna a execução da desagregação mais rápida [7, 13]. Assim, é necessário investigarmos abordagens para obtermos as representatividades destes conjuntos. Podemos extrair os dicionários de um sinal de consumo de energia elétrica mediante diversas abordagens. Os métodos mais comuns envolvem análises usando redes neurais [9], representação esparsa [7, 10] e modelos ocultos de Markov [6, 11].

A representatividade das assinaturas de um sinal de consumo de energia elétrica é denominado de *dicionário*. Ao sinal de consumo de energia elétrica total  $x(t)$ , associamos o dicionário  $\mathbf{B}$  e, aos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, associamos os dicionários  $\mathbf{B}_i$ . Elaboramos o dicionário  $\mathbf{B}$  do sinal

de consumo de energia elétrica total  $x(t)$  usando os dicionários  $\mathbf{B}_i$  dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos. Observe que os dicionários  $\mathbf{B}_i$  têm dimensão  $N_i$  e o dicionário  $\mathbf{B}$  terá dimensão  $\sum_{i=1}^L N_i$ .

$$\begin{aligned}\mathbf{B} &= [ \mathbf{B}_1, \mathbf{B}_2, \dots, \mathbf{B}_L ] \\ \mathbf{B}_i &= [ B_i^{(1)}, B_i^{(2)}, \dots, B_i^{(N_i)} ]\end{aligned}\tag{2.3}$$

Elaborados os dicionários, procedemos com o procedimento de desagregação do sinal de consumo de energia elétrica. Esse assunto será abordado na seção seguinte.

### 2.3.5 Procedimento de Desagregação

O procedimento de desagregação de um sinal de consumo de energia elétrica total  $x(t)$  nos permite obter estimativas  $\hat{x}_i(t)$  dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos. Para isso, utilizamos conhecimento prévio sobre os dispositivos que compõem o sinal de consumo de energia elétrica total  $x(t)$ , utilizando os dicionários  $\mathbf{B}$  e  $\mathbf{B}_i$ , não sendo mais necessário adquirirmos medições de consumo de energia elétrica  $x_i(t)$  dos dispositivos. Ilustramos esta situação na Figura 2.2. Em termos gerais, buscamos assinalar simultaneamente um componente de cada dicionário  $\mathbf{B}_i$ , em um determinado intervalo de tempo, que corresponda ao consumo do dispositivo  $i$ . Matematicamente, representamos este cenário por:

$$\hat{x}(t) = \mathbf{B} c(t)\tag{2.4}$$

A solução  $c(t)$  da equação (2.4) pode não ser única. Podemos encontrar diversas instâncias de  $c(t)$  que representem apropriadamente os consumos de energia dos dispositivos  $x_i(t)$  em um intervalo de tempo. Para avaliarmos o desempenho das estimativas do sinal de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, precisamos conhecer os sinais  $x_i(t)$  e compará-los com os sinais de consumo de energia elétrica estimados  $\hat{x}_i(t)$  dos dispositivos, respectivamente. Para aprimorar o procedimento da desagregação, podemos aplicar premissas ou restrições aos dicionários, com o objetivo de apontar a obten-

ção de  $c(t)$  para as soluções mais prováveis [2, 3, 7, 9, 10]. Isso requer conhecimento empírico sobre a natureza do sinal de consumo de energia elétrica.

Podemos estimar o sinal de consumo de energia elétrica total  $\hat{x}(t)$  e os sinais de consumo de energia elétrica  $\hat{x}_i(t)$  dos dispositivos, mediante técnicas de otimização [11] e reconhecimento de padrões [13]. No primeiro caso, podemos usar algoritmos de otimização de funções como as de erro médio quadrático, distância euclidiana, similaridade de cosseno [15], algoritmos genéticos [16] e programação linear inteira [17]. No segundo caso, podemos usar algoritmos de classificação *k-nearest neighbors* (KNN) [5, 18, 19], árvores de decisão [20], *multiclass adaboost* [21], *support vector machine* (SVM) [22] e *hidden Markov models* (HMMs) [23].

## 2.4 Análise de Componentes Principais

A análise de componentes principais (do inglês, *Principal Component Analysis* - PCA), é um método amplamente utilizado em análise multivariada, cujo propósito é transformar um conjunto de dados, com variáveis supostamente correlacionadas, em um conjunto de dados com variáveis não correlacionadas e de dimensionalidade reduzida [24]. Há aplicações em problemas de compressão de dados, extração de características, detecção e reconhecimento de padrões [25]. A PCA pode ser analisada também como um problema de projeção onde um vetor em espaço multidimensional é projetado em um subespaço vetorial de dimensão menor, procurando minimizar o erro médio quadrático ou maximizar a variância do vetor projetado [26]. Podemos determinar a dimensão deste subespaço vetorial através da quantidade de componentes principais [27].

Podemos formular a PCA da seguinte maneira [27]: seja  $\chi$  uma variável aleatória com  $R$  realizações, existe uma base ortogonal  $\Phi = [\phi^{(1)}, \dots, \phi^{(N)}]$  que maximiza a variância e que pode ser obtida pela análise da matriz de autovalores  $\Lambda$ , conforme a expressão:

$$\Lambda = \Phi^* \Sigma_{\chi} \Phi \quad (2.5)$$

A expressão  $\Phi^*$  representa o conjugado transposto de  $\Phi$  e a matriz  $\Sigma_{\chi}$  é a matriz de covariância de  $\chi$  com média igual a zero. Neste caso,  $\Phi$  é a matriz de

autovetores ortogonais de  $\Sigma_x$  e  $\mathbf{\Lambda} = \text{diag}(\lambda(1), \dots, \lambda(N))$  é a matriz diagonal de autovalores de  $\Sigma_x$ , organizada de forma que  $\lambda(1) > \lambda(2) > \dots > \lambda(N)$ . A PCA pode ser realizada por decomposição em valores singulares (SVD) [28]. Seja uma matriz  $\mathbf{Y} \in \mathbb{R}^{R \times N}$ , com  $R \geq N$ . Então a decomposição em valores singulares é dada por:

$$\mathbf{Y} = \mathbf{U}\mathbf{D}\mathbf{V}^*, \quad (2.6)$$

onde  $\mathbf{U} \in \mathbb{R}^{M \times N}$  e  $\mathbf{V} \in \mathbb{R}^{N \times N}$  são matrizes com colunas (autovalores) ortonormais e  $\mathbf{D} \in \mathbb{R}^{N \times N}$  é a matriz diagonal de autovalores de  $\mathbf{Y}$ . Neste caso, a matriz  $\Phi$  de  $\Sigma_x$  equivale a  $\mathbf{V}$  e o quadrado de  $\mathbf{D}$  equivale à matriz de autovalores  $\mathbf{\Lambda}$ , se considerarmos  $\mathbf{Y} = \frac{1}{M-1}\mathbf{X}^*$ .

## 2.5 Análise Singular Espectral

A aplicação do SSA a um sinal unidimensional de variáveis dependentes  $x(t)$  é realizada em duas etapas: uma de decomposição e outra de reconstrução do sinal. Na etapa de decomposição, realizamos inicialmente um procedimento denominado segmentação (do inglês, *embedding*) [24], onde transformamos um sinal de dimensão  $T$  em uma representação multidimensional de dimensão  $\ell$ , ( $1 < \ell < T$ ), equivalente à transformação em matriz de *Hankel* de dimensão  $\ell$ , representada matematicamente por  $\mathcal{H}_\ell\{x(t)\}$ . Assim, temos:

$$\mathbf{H} = \mathcal{H}_\ell\{x(t)\} = \begin{bmatrix} x(1) & x(2) & \cdots & x(T - \ell + 1) \\ x(2) & x(3) & \cdots & x(T - \ell) \\ \vdots & \vdots & \ddots & \vdots \\ x(\ell) & x(\ell + 1) & \cdots & x(T) \end{bmatrix} \quad (2.7)$$

Em seguida, realizamos a *decomposição em valores singulares* (SVD) à matriz  $\mathbf{H}\mathbf{H}^T$ , obtendo a decomposição  $\mathbf{H}\mathbf{H}^T = \mathbf{P}\mathbf{\Lambda}\mathbf{P}^T$ . Neste caso,  $\mathbf{P}$  é a matriz de autovetores ortogonais de  $\mathbf{H}\mathbf{H}^T$  e  $\mathbf{\Lambda}$  é a matriz diagonal de autovalores de  $\mathbf{H}\mathbf{H}^T$ , organizada de forma que  $\lambda(1) \geq \lambda(2) \geq \dots \geq \lambda(\ell) \geq 0$ .

$$\mathbf{P} = [P^{(1)}, P^{(2)}, \dots, P^{(\ell)}] \quad (2.8)$$

Podemos recuperar a matriz  $\mathbf{H}$  considerando o parâmetro  $d = \max\{j, \text{ dado } \lambda_j > 0\}$  da seguinte maneira:

$$\mathbf{H} = \sum_{k=1}^d \mathbf{H}_k = \sum_{k=1}^d \sqrt{\lambda(k)} P^{(k)} V^{(k)T} \quad (2.9)$$

$$V^{(k)} = \mathbf{H}^T \frac{P^{(k)}}{\sqrt{\lambda(k)}}, \quad k = \{1, 2, \dots, d\} \quad (2.10)$$

Na etapa de reconstrução, obtemos um sinal reconstruído  $x_m(t)$  do sinal  $x(t)$  mediante o *agrupamento* de  $m$  componentes SVD da decomposição de  $x(t)$ , tal que  $m \subset \{1, 2, \dots, d\}$ . Para isto, calculamos inicialmente a matriz de *Hankel* reconstruída  $\mathbf{H}_m$ , considerando estas  $m$  componentes:

$$\mathbf{H}_m = \sum_{k=1}^m \mathbf{H}_k = \sum_{k=1}^m \sqrt{\lambda(k)} P^{(k)} V^{(k)T} \quad (2.11)$$

Em seguida, executamos a transformação inversa de *Hankel* de dimensão  $\ell$  da matriz  $\mathbf{H}_m$ , operação representada matematicamente por  $\mathcal{H}_\ell^{-1}\{\mathbf{H}_m\}$  e obtemos o sinal reconstruído  $x_m(t) = [x_m(1), x_m(2), \dots, x_m(T)]$  considerando  $m$  componentes SVD da decomposição do sinal  $x(t)$ . Observe que  $x_m(t)$  é uma aproximação do sinal  $x(t)$  tanto maior quanto mais componentes  $m$  consideramos. O  $j$ -ésimo termo  $x_m(j)$ , com  $j = \{1, 2, \dots, T\}$ , é calculado pela média aritmética dos termos da  $j$ -ésima anti diagonal da matriz  $\mathbf{H}_m$ , conforme expressão a seguir:

$$x_m(j) = \begin{cases} \frac{1}{j} \sum_{k=1}^j \mathbf{H}_m(k, j - k + 1), & 1 \leq j < \ell \\ \frac{1}{\ell} \sum_{k=1}^{\ell} \mathbf{H}_m(k, j - k + 1), & \ell \leq j < T - \ell + 2 \\ \frac{1}{T - j + 1} \sum_{k=(j-T+\ell)}^{\ell} \mathbf{H}_m(k, j - k + 1), & T - \ell + 2 \leq j \leq T \end{cases} \quad (2.12)$$

Observe que, modificando o parâmetro  $\ell$  da dimensão da matriz de *Hankel* e a quantidade  $m$  de componentes SVD usadas para reconstruir o sinal  $x(t)$ , obtemos diferentes instâncias de  $x_m(t)$  [29].

## 2.6 Considerações Finais

Conforme apresentamos, a desagregação de um sinal de consumo de energia elétrica pode ser feito por monitoramento não intrusivo. Esta abordagem requer o uso de menos equipamentos e instalações, sendo assim, uma abordagem de menor custo de instalação e manutenção. Por outro lado, em função da quantidade de dispositivos que compõem um sinal de consumo de energia elétrica total, pode ser inviável realizar a desagregação por esta abordagem. Dispositivos de baixa potência, abaixo de 100 W, dispositivos de modo de operação contínua, como sistemas de segurança, e dispositivos com modos de operação semelhantes, como lâmpadas de mesma potência, são de difícil separação do sinal de consumo de energia elétrica total [2]. Nestes casos, pode ser necessário adotar outras abordagens.

No capítulo seguinte, apresentamos o procedimento proposto para monitoramento não intrusivo de sinais de consumo de energia elétrica.



# Capítulo 3

## Procedimento Proposto para Monitoramento Não Intrusivo de Sinais de Consumo de Energia Elétrica

A desagregação de um sinal de consumo de energia elétrica total  $x(t)$  requer, primeiramente, a elaboração de um dicionário  $\mathbf{B}$  deste sinal que, por sua vez, é composto pelos dicionários  $\mathbf{B}_i$ , dos sinais de consumo de energia elétrica  $x_i(t)$  que compõem o sistema [2, 13], conforme apresentamos na equação (2.3). Para isso, identificamos os estados estacionários do sinal de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, que compõem o sistema e os agrupamos nos conjuntos  $\mathbf{X}$  e  $\mathbf{X}_i$ . Em seguida, aplicamos o Algoritmo DS3 [14], obtendo respectivamente os dicionários  $\mathbf{B}$  e  $\mathbf{B}_i$ , e realizamos a desagregação. Observamos que alguns parâmetros dos algoritmos usados na desagregação influenciam seu desempenho. A seguir, apresentamos a metodologia que utilizamos para identificar os parâmetros que influenciam na desagregação.

### 3.1 Introdução

Nesta seção, apresentamos a metodologia utilizada para análise de parâmetros que influenciam na desagregação de um sinal de consumo de energia elétrica

total  $x(t)$ . Inicialmente, adquirimos um sinal de consumo de energia elétrica total e os sinais de consumo de energia elétrica dos dispositivos que o compõem, dividindo-os em dois grupos: o primeiro, tomado no intervalo de tempo  $t = \{1, 2, \dots, T\}$ , utilizamos para elaborar o dicionário  $\mathbf{B}$  do sinal de consumo de energia elétrica total  $x(t)$  e os dicionários  $\mathbf{B}_i$  dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos. O segundo grupo de amostras, tomado no intervalo de tempo  $t = \{1, 2, \dots, K\}$ , subsequente ao anterior, utilizamos como sinal de consumo de energia elétrica  $\bar{x}(t)$  para executar o procedimento de desagregação.

Em síntese, o procedimento proposto para a desagregação foi realizado em duas etapas: primeiramente, identificamos os estados estacionários dos sinais de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, através de uma variação do método *steady-state identification* (SSI) [2, 13], conforme apresentado no **Algoritmo 1**, que contempla uma normalização e um redimensionamento destes sinais, e os armazenamos nas matrizes de estados estacionários  $\mathbf{X}$  e  $\mathbf{X}_i$ .

$$\begin{aligned}\mathbf{X} &= [X^{(1)}, X^{(2)}, \dots, X^{(M)}] \\ \mathbf{X}_i &= [X_i^{(1)}, X_i^{(2)}, \dots, X_i^{(M_i)}]\end{aligned}\tag{3.1}$$

Em seguida, extraímos as assinaturas do sinal de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia  $x_i(t)$  dos dispositivos, analisando as transições que ocorrem sucessivamente entre os elementos das matrizes de estados estacionários  $\mathbf{X}$  e  $\mathbf{X}_i$  e armazenamos os valores nas matrizes de assinatura  $\mathbf{S}$  e  $\mathbf{S}_i$ . Embora, em nossa metodologia, o dicionário  $\mathbf{B}$  do sinal de consumo de energia elétrica total  $x(t)$  e os dicionários  $\mathbf{B}_i$  dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, são extraídos das respectivas matrizes de estados estacionários  $\mathbf{X}$  e  $\mathbf{X}_i$ , é importante extrairmos as assinaturas destes sinais porque podemos usá-las posteriormente para indexar e organizar a matriz de soluções de desagregação  $\mathbf{C}$ .

$$\begin{aligned}\mathbf{S} &= [\mathbf{S}^{(1)}, \mathbf{S}^{(2)}, \dots, \mathbf{S}^{(W)}] \\ \mathbf{S}_i &= [\mathbf{S}_i^{(1)}, \mathbf{S}_i^{(2)}, \dots, \mathbf{S}_i^{(W_i)}]\end{aligned}\tag{3.2}$$

Em seguida, utilizamos, o algoritmo *dissimilarity-based sparse subset selection* (DS3) para obtermos o dicionário  $\mathbf{B}$  do sinal de consumo de energia elétrica  $x(t)$

e os dicionários  $\mathbf{B}_i$  dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos. Para isso, podemos adotar uma abordagem por extração de representatividades das matrizes de assinaturas ou por extração de representatividades das matrizes de estados estacionários, diretamente [13]. Optamos pelo segundo caso, com enfoque na análise das matrizes dos estados estacionários. Assim, realizamos a extração de representatividades da matriz de estados estacionários  $\mathbf{X}$  do sinal de consumo de energia elétrica total  $x(t)$  e das matrizes de estados estacionários  $\mathbf{X}_i$  dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, obtendo os dicionários  $\mathbf{B}$  e  $\mathbf{B}_i$ , respectivamente. Por fim, realizamos o procedimento final de desagregação do sinal de consumo de energia elétrica total.

$$\begin{aligned}\mathbf{B} &= [\mathbf{B}_1, \mathbf{B}_2, \dots, \mathbf{B}_L] \\ \mathbf{B}_i &= [B_i^{(1)}, B_i^{(2)}, \dots, B_i^{(N_i)}]\end{aligned}\tag{3.3}$$

## 3.2 Método de Identificação de Estados Estacionários

Para elaborarmos as matrizes de estados estacionários  $\mathbf{X}$  e  $\mathbf{X}_i$  dos sinais de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, respectivamente, aplicamos o método *steady-state identification* (SSI) [2, 13]. Esse método, que passamos a denominar de *steady-state identification variable dimension* (SSI-VD), normalmente identifica estados estacionários com dimensões diferentes e é assim aplicado: adquirimos os sinais de consumo de energia elétrica total  $x(t)$  e os sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, e armazenamos os índices dos estados estacionários nas matrizes  $\mathbf{X}$  e  $\mathbf{X}_i$ . Para isso, especificamos os dois ponteiros  $\rho_0$  e  $\rho_1$  aos quais atribuímos os valores 1 e  $s_{min}$ , respectivamente, e verificamos se o parâmetro  $\epsilon$  é atendido em  $\tilde{x} = [x(\rho_0), \dots, x(\rho_1)]$  e  $\tilde{x}_i = [x_i(\rho_0), \dots, x_i(\rho_1)]$ . Em caso positivo, incrementamos o valor de  $\rho_1$ , de forma que  $\rho_1 = \rho_1 + 1$ , e verificamos se o parâmetro  $\epsilon$  é atendido no novo intervalo  $\tilde{x} = [x(\rho_0), \dots, x(\rho_1)]$  e  $\tilde{x}_i = [x_i(\rho_0), \dots, x_i(\rho_1)]$ . Isso é feito recursivamente até que  $\epsilon$  seja atendido. Quando o parâmetro  $\epsilon$  não é mais atendido, armazenamos os valores de  $\rho_0$  e  $\rho_1$  em  $\mathbf{X}$  e  $\mathbf{X}_i$  e atribuímos novos valores a  $\rho_0 = \rho_1$  e  $\rho_1 = \rho_1 + s_{min} - 1$ . Realizamos novamente o procedimento de verificação de  $\epsilon$  e, ao final, temos a matriz  $\mathbf{X}$

e  $\mathbf{X}_i$  contendo os índices dos estados estacionários dos sinais de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, respectivamente. Representamos este procedimento no **Algoritmo 1**.

Exemplificando, suponha o sinal de consumo de energia elétrica a seguir com 15 amostras, onde os elementos destacados em cinza são estados estacionários:

$$x(t) = \left[ \overbrace{x(1) \cdots x(4)}^{X_1} \ x(5) \cdots x(7) \ \overbrace{x(8) \cdots x(11)}^{X_2} \ x(12) \ \overbrace{x(13) \cdots x(15)}^{X_3} \right] \quad (3.4)$$

Neste caso, o **Algoritmo 1** identifica os estados estacionários  $X_1, X_2, X_3$  de dimensão 4, 4, 3, respectivamente, do sinal de consumo de energia elétrica total  $x(t)$  e armazena os índices de início e fim dos estados estacionários na matriz  $\mathbf{X}$ :

$$\mathbf{X} = \begin{bmatrix} 1 & 8 & 13 \\ 4 & 11 & 15 \end{bmatrix}$$

Obviamente, sinais usuais de consumo de energia elétrica contêm uma quantidade de amostras muito superior ao apresentado neste exemplo. Normalmente, um sinal de consumo de energia elétrica total  $x(t)$  contém em torno de 86.400 amostras para 24 h de medições [1].

Estados estacionários de dimensões diferentes dificultam o procedimento de desagregação [7]. Para obtermos estados estacionários de dimensões iguais, modificamos o método SSI com base no conceito de *powerlets* [7], e originamos o método *steady-state identification similar dimension* (SSI-SD). Neste caso, analisamos conjuntos de amostras do sinal de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, de mesmas dimensões  $w$  iniciando em  $t = \{1, 2, \dots, w\}$  até  $t = \{(T - w + 1), \dots, (T - 1), T\}$ , ao passo de uma amostra, e verificamos o atendimento ao parâmetro  $\epsilon$  em cada passo. Se a verificação for verdadeira, o intervalo é considerado um estado estacionário. Com este procedimento, obtemos estados estacionários de dimensões iguais e a extração dos dicionários por técnicas que usam métricas de dissimilaridade entre conjuntos torna-se simples [7, 14]. No **Algoritmo 2**, implementamos este método. Observe que usamos a transformação de *Hankel* [7] de dimensão  $w$  ao sinal de consumo de energia elétrica total  $x(t)$  e aos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, e

representamos matematicamente esta operação por  $\mathcal{H}_w\{x(t)\}$  e  $\mathcal{H}_w\{x_i(t)\}$ . Assim, temos as matrizes  $\mathbf{H}$  e  $\mathbf{H}_i$  do sinal de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, respectivamente, para processar a verificação de  $\epsilon$ . Exemplificando, suponha novamente o sinal de consumo de energia elétrica da equação (3.4). Neste caso, para  $w = 3$ , o **Algoritmo 2** elabora a matriz  $\mathbf{H}$  a seguir, identifica os estados estacionários e os armazena na matriz  $\mathbf{X}$ :

$$\mathbf{H} = \begin{bmatrix} x(1) & \cdots & x(13) \\ x(2) & \cdots & x(14) \\ x(3) & \cdots & x(15) \end{bmatrix} \quad (3.5)$$

$$\mathbf{X} = \begin{bmatrix} x(1) & x(2) & x(8) & x(9) & x(13) \\ x(2) & x(3) & x(9) & x(10) & x(14) \\ x(3) & x(4) & x(10) & x(11) & x(15) \end{bmatrix} \quad (3.6)$$

### 3.3 Assinaturas

Uma assinatura de um sinal de consumo de energia elétrica pode corresponder a um estado estacionário ou a uma sequência conhecida de diferentes estados estacionários, ao longo do tempo [2]. Para verificarmos esta condição, analisamos as matrizes de estados estacionários  $\mathbf{X}$  e  $\mathbf{X}_i$  do sinal de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, respectivamente. Em seguida, identificamos as duplas de estados estacionários que correspondem a uma assinatura do sinal de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, e os armazenamos nas matrizes  $\mathbf{S}$  e  $\mathbf{S}_i$ , respectivamente, onde cada linha corresponde a uma assinatura, conforme equação (3.2). Elaboramos o **Algoritmo 3** para executar este procedimento. Observe que extraímos a primeira dupla de estados estacionários  $X_1$  e  $X_2$  do sinal de consumo de energia elétrica total  $x(t)$  e os armazenamos como a primeira assinatura da matriz de assinaturas  $\mathbf{S}$ . Realizamos o mesmo procedimento para  $\mathbf{X}_i$ . Em seguida, analisamos subsequentemente as duplas de estados estacionários de  $\mathbf{X}$  e  $\mathbf{X}_i$ , verificando se correspondem a uma assinatura já reconhecida e armazenada

---

**Algoritmo 1** *Steady-state identification variable dimension (SSI-VD)*

---

**Entrada:**  $x = [x(1), x(2), \dots, x(T)]$ ;  $s_{min}$ ;  $\epsilon$

**Saída:** Matriz de estados estacionários  $\mathbf{X}$

```
1:  $\rho_0 \leftarrow 1$ ;  $\rho_1 \leftarrow s_{min}$ ;  $k \leftarrow 1$ 
2: enquanto  $\rho_1 \leq T$  faça
3:    $\tilde{x} \leftarrow [x(\rho_0), \dots, x(\rho_1)]$ 
4:   se  $\max(\tilde{x}) - \min(\tilde{x}) < \epsilon$  então //  $\tilde{x}$  é um estado estacionário
5:      $\rho_1 \leftarrow \rho_1 + 1$ 
6:   senão //  $\tilde{x}$  não é estado estacionário
7:     se  $\rho_1 - \rho_0 = s_{min} - 1$  então
8:        $\rho_0 \leftarrow \rho_0 + 1$ 
9:        $\rho_1 \leftarrow \rho_1 + 1$ 
10:    senão // Fim de estado estacionário. Armazena índices.
11:     $\mathbf{X}_k \leftarrow \begin{bmatrix} \rho_0 \\ \rho_1 - 1 \end{bmatrix}$ 
12:     $k \leftarrow k + 1$ 
13:     $\rho_0 \leftarrow \rho_1$ 
14:     $\rho_1 \leftarrow \rho_1 + s_{min} - 1$ 
```

---

---

**Algoritmo 2** *Steady-state identification similar dimension (SSI-SD)*

---

**Entrada:**  $x = [x(1), x(2), \dots, x(T)]$ ;  $w$ ;  $\epsilon$

**Saída:** Matriz de estados estacionários  $\mathbf{X}$

```
1:  $k \leftarrow 1$ 
2:  $\mathbf{H} \leftarrow \mathcal{H}_w\{x(t)\}$  // Transformação de Hankel
3: para todo coluna  $j$  de  $\mathbf{H}$  faça
4:   se  $\max(\mathbf{H}_j) - \min(\mathbf{H}_j) < \epsilon$  então //  $\mathbf{H}_j$  é estado estacionário.
5:      $\mathbf{X}_k \leftarrow \mathbf{H}_j$ 
6:      $k \leftarrow k + 1$ 
```

---

em  $\mathbf{S}$  e  $\mathbf{S}_i$ , respectivamente. Caso a assinatura ainda não tenha sido reconhecida, ela é armazenada como uma nova assinatura em  $\mathbf{S}$  e  $\mathbf{S}_i$ , respectivamente.

---

**Algoritmo 3** Extração das assinaturas

---

**Entrada:** Matriz de estados estacionários  $\mathbf{X}$

**Saída:** Matriz de assinaturas  $\mathbf{S}$

```

1:  $i \leftarrow 1; q \leftarrow 0$ 
2:  $\mathbf{S}_1 \leftarrow \mathbf{X}(1 \cdots 2)$  // Armazena  $\mathbf{X}(1 \cdots 2)$  como primeira assinatura
3: para  $k = 2 : \dim(\mathbf{X}) - 1$  faça
4:      $\mathbf{X}' \leftarrow \mathbf{X}(k \cdots k + 1)$  // Analisa próximos dois estados estacionários de  $\mathbf{X}$ 
5:     para  $j = 1 : \dim(\mathbf{S})$  faça // Verifica se  $\mathbf{X}'$  é assinatura existente em  $\mathbf{S}$ 
6:         se  $\mathbf{X}' \neq \mathbf{S}(j)$  então // Assinatura não existente
7:              $q \leftarrow 1$ 
8:     se  $q = 1$  então // Se identificou  $\mathbf{X}'$  como assinatura não existente, armazena
9:          $i \leftarrow i + 1$ 
10:         $\mathbf{S}_i \leftarrow \mathbf{X}'$ 
11:         $q \leftarrow 0$ 

```

---

Ao final deste procedimento, obtemos as matrizes de assinatura  $\mathbf{S}$  e  $\mathbf{S}_i$ . Por exemplo, a matriz  $\mathbf{S}$  a seguir, corresponde à assinatura de um sinal de consumo de energia elétrica que possui três estados estacionários  $X_1, X_2, X_3$  e quatro assinaturas  $X_1 \xrightarrow{t_1} X_2, X_1 \xrightarrow{t_2} X_3, X_2 \xrightarrow{t_3} X_1, X_3 \xrightarrow{t_4} X_1$ . A representação em diagrama de estados finitos correspondente é ilustrada ao lado.




Figura 3.1: Representação da matriz de assinaturas  $\mathbf{S}$  em forma matricial e em diagrama de estados finitos.

### 3.4 Dicionários

A próxima etapa no procedimento de desagregação é obtermos os dicionários  $\mathbf{B}$  do sinal de consumo de energia elétrica total  $x(t)$  e os dicionários  $\mathbf{B}_i$  dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, a partir das matrizes de estados estacionários  $\mathbf{X}$  e  $\mathbf{X}_i$ . Um dicionário é um conjunto extraído de uma assinatura ou de um conjunto de estados estacionários e que preserva a sua representatividade, ou seja, o dicionário conserva características relevantes do conjunto. Realizar a desagregação com base nos dicionário normalmente é mais simples do que com base nas assinaturas ou nos conjuntos de estados estacionários [14].

Para obtermos os dicionários  $\mathbf{B}$  e  $\mathbf{B}_i$  dos sinais de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, respectivamente, utilizamos o algoritmo *dissimilarity-based sparse subset selection* (DS3) [7, 14]. Este algoritmo baseia-se no conceito da recuperação de sinais esparsos para encontrar modelos representativos em grandes conjuntos de dados [14, 30]. Em linhas gerais, dada uma matriz de estados estacionários  $\mathbf{X}$  de dimensão  $M$ , conforme apresentado na equação (3.1), calculamos a dissimilaridade entre seus termos  $m$  e  $n$ ,  $d_{mn} = |X_m - X_n|$ , com  $\{m, n\} = \{1, 2, \dots, M\}$ , e elaboramos a matriz de dissimilaridade  $\mathbf{D}$ . Usamos a distância euclidiana como métrica de dissimilaridade, embora outras métricas possam ser utilizadas, como a distância  $\chi^2$  e similaridade de cosseno [14].

$$\mathbf{D} = \begin{bmatrix} d_{11} & d_{12} & \cdots & d_{1M} \\ d_{21} & d_{22} & \cdots & d_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ d_{M1} & d_{M2} & \cdots & d_{MM} \end{bmatrix} \quad (3.7)$$

Elaboramos este procedimento também para as matrizes de estados estacionários  $\mathbf{X}_i$  dos dispositivos e obtemos as matrizes de dissimilaridade  $\mathbf{D}_i$ . Observe que quanto menor for a medida de dissimilaridade entre o termo  $m$  e  $n$  de  $\mathbf{X}$ , maior será a representatividade [14]. Em seguida, procedemos com a normalização da matriz  $\mathbf{D}$  com base em seu valor máximo e obtemos a matriz  $\mathbf{Z}$  [14]. Para os dispositivos,



obtemos as matrizes  $\mathbf{Z}_i$ .

$$\mathbf{Z} = \left( \frac{1}{\max \mathbf{D}} \right) \mathbf{D} \quad (3.8)$$

Implementamos o **Algoritmo 4** para extrair os dicionários  $\mathbf{B}$  do sinal de consumo de energia elétrica total  $x(t)$  e os dicionários  $\mathbf{B}_i$  dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos. Investigamos que o algoritmo DS3 possui dois parâmetros,  $\alpha$  e  $\gamma$ , que podem ser variados para, neste caso, modificar a representatividade dos dicionários.

---

**Algoritmo 4** Extração de dicionários

---

**Entrada:** Matriz de assinaturas  $\mathbf{X}$ ;  $\alpha$ ;  $\gamma$

**Saída:** Dicionário  $\mathbf{B}$

- 1: **para**  $m = 1 : \dim(\mathbf{X})$  **faça** // Elabora matriz de dissimilaridade  $\mathbf{D}$
  - 2:     **para**  $n = 1 : \dim(\mathbf{X})$  **faça**
  - 3:          $\mathbf{D}(m, n) \leftarrow |X_m - X_n|$
  - 4:  $\mathbf{Z} \leftarrow (1/\max \mathbf{D}) \mathbf{D}$  // Elabora matriz de dissimilaridade  $\mathbf{Z}$
  - 5:  $\mathbf{B} \leftarrow \mathbf{DS3}(\mathbf{Z}, \alpha, \gamma)$  // Extrai dicionário  $\mathbf{B}$  executando o algoritmo DS3
- 

### 3.5 Desagregação

Para finalizarmos o procedimento de desagregação, correspondente ao bloco 6 da Figura 2.2, elaboramos inicialmente a matriz de coeficientes  $\mathbf{C}$  onde suas linhas são formadas pela combinação (permuta) dos elementos dos dicionários  $\mathbf{B}_i$  dos dispositivos tomados um a um. Neste caso, não usamos o dicionário  $\mathbf{B}$ . De acordo com a equação (3.3), cada dicionário  $\mathbf{B}_i$  possui dimensão  $N_i$ , assim, a matriz  $\mathbf{C}$  terá  $L$  colunas e  $N_c = \prod_{i=1}^L N_i$  linhas.

$$\mathbf{C} = \begin{bmatrix} P_1(\mathbf{B}_i, L) \\ P_2(\mathbf{B}_i, L) \\ \vdots \\ P_{N_c}(\mathbf{B}_i, L) \end{bmatrix} \quad (3.9)$$

Em seguida, para cada linha de  $\mathbf{C}$ , somamos os valores de seus elementos,

obtendo o vetor de indexação  $Y$  que é agregado à matriz  $\mathbf{C}$  como sua primeira coluna. Assim,  $\mathbf{C}$  passa a ter  $L + 1$  colunas. Observe que o vetor de indexação  $Y$  contém as possíveis estimativas do sinal de consumo de energia elétrica total  $\bar{x}(t)$  que desejamos desagregar, pois é resultante da soma de elementos dos dicionários dos dispositivos. Por fim, indexamos e organizamos as linhas da matriz  $\mathbf{C}$ . Desta forma, estabelecemos critérios para a busca da solução da desagregação sem aplicarmos premissas ou restrições ao conjunto solução [7]. Para elaborarmos o segundo vetor de indexação  $Q$ , verificamos a quantidade de vezes que cada linha de  $\mathbf{C}$  ocorre nas amostras do sinal de consumo de energia elétrica total  $x(t)$  e nos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, usadas na elaboração dos dicionários. Agregamos esse vetor como primeira coluna da matriz  $\mathbf{C}$  agora, que passa a ter  $L + 2$  colunas. A terceira coluna de indexação é o vetor  $P$  que contém a quantidade de elementos nulos de  $\mathbf{C}(3, \dots, L + 2)$ . Agregamos este vetor como a primeira coluna de  $\mathbf{C}$ , agora com  $L + 3$  colunas, passando a ser denominada *matriz de soluções de desagregação*.

$$\mathbf{C} = \left[ \begin{array}{c|c|c|c|c|c|c} p(1) & q(1) & y(1) & y_1(1) & y_2(1) & \cdots & y_L(1) \\ p(2) & q(2) & y(2) & y_1(2) & y_2(2) & \cdots & y_L(2) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ p(N_c) & q(N_c) & y(N_c) & y_1(N_c) & y_2(N_c) & \cdots & y_L(N_c) \end{array} \right] \quad (3.10)$$

---

**Algoritmo 5** Elaboração da matriz de soluções de desagregação

---

**Entrada:** Dicionários  $\mathbf{B}_i$

**Saída:** Matriz de soluções de desagregação  $\mathbf{C}$

- 1:  $\mathbf{C} \leftarrow P(\mathbf{B}_i, L)$  // Combina estados estacionários dos dicionários  $\mathbf{B}_i$
  - 2:  $y_k \leftarrow \{\sum_{k=1}^{N_c} \text{linhas de } \mathbf{C}\}$  // Elabora vetor  $Y$
  - 3:  $Q \leftarrow \{\text{ocorrência das linhas de } \mathbf{C} \text{ em } [x_1, \dots, x_L]\}$  // Elabora vetor  $Q$
  - 4:  $p_k \leftarrow \{\text{quantidade de elementos nulos em } \mathbf{C}(4, \dots, L + 3)\}$  // Elabora vetor  $P$
  - 5:  $\mathbf{C} \leftarrow [ P \mid Q \mid Y \mid \mathbf{C} ]$  // Agrega  $P$ ,  $Q$  e  $Y$  em  $\mathbf{C}$
  - 6:  $\mathbf{C} \leftarrow \mathbf{Organiza}(\mathbf{C}, \text{método})$  // Organiza  $\mathbf{C}$  de conforme método
- 

Por fim, o procedimento final da desagregação consiste em tomarmos o sinal de consumo de energia elétrica total  $\bar{x}(t)$  que se deseja desagregar e elaborar a matriz

de estados estacionários  $\mathbf{X}$  aplicando o **Algoritmo 2**. Por fim, para cada elemento de  $\mathbf{X}$ , realizar a busca do valor mais próximo existente na terceira coluna da matriz de soluções de desagregação  $\mathbf{C}$ . Assim que concluimos a busca, dizemos que encontramos a solução da desagregação. O vetor de índices de desagregação  $c$  é determinado de acordo com respectivos elementos de  $\mathbf{B}_i$ . Elaboramos o **Algoritmo 6** para este procedimento.

---

**Algoritmo 6** Procedimento de desagregação

---

**Entrada:**  $\bar{x}$ ; matriz de soluções de desagregação  $\mathbf{C}$

**Saída:** Índices de desagregação  $c$

- 1:  $\bar{\mathbf{X}} \leftarrow \mathbf{Algoritmo\ 2}(\bar{x})$  // Executa **Algoritmo 2** em  $\bar{x}(t)$
  - 2:  $c \leftarrow \mathbf{Busca}(\bar{\mathbf{X}}, \mathbf{C})$  // Procura estado estacionário  $\bar{\mathbf{X}}$  em  $\mathbf{C}$ , obtendo o vetor  $c$
- 

### 3.6 Considerações Finais

O procedimento proposto para monitoramento não intrusivo de sinais de consumo de energia elétrica foi realizado inicialmente mediante uma variação do método *steady-state identification* (SSI), onde passamos a elaborar conjuntos de estados estacionários de dimensões normalizadas destes sinais. Isto possibilita a aplicação de métodos que utilizam métricas de dissimilaridade entre elementos de um conjunto para a extração de representatividades, como é o caso da elaboração dos dicionário dos sinais de consumo de energia elétrica. No método proposto, elaboramos os dicionários com base nos conjuntos de estados estacionários dos sinais de consumo de energia elétrica para realizar a desagregação. Depois, obtemos os dicionários mediante a aplicação do algoritmo *dissimilarity-based sparse subset selection* (DS3) e identificamos parâmetros deste algoritmo que influenciam a obtenção dos dicionários. A desagregação é proposta com base na elaboração de um conjunto solução composto pelas combinações entre os elementos dos dicionários dos dispositivos, obtendo uma matriz que pode ser organizada de diferentes maneiras, gerando diferentes soluções de desagregação. O diferencial nesta proposta é que, ao identificarmos estados estacionários de dimensões iguais, podemos usar métricas simples de cálculo de dissimilaridade para extrair os dicionários.

Na próxima seção, apresentamos procedimentos experimentais realizados para avaliar a influência da variação de parâmetros na desagregação.

# Capítulo 4

## Procedimentos Experimentais

Nesta seção, apresentamos os procedimentos experimentais realizados para avaliar a influência da variação de parâmetros presentes na metodologia de desagregação proposta. Apresentamos os parâmetros considerados relevantes na influência da desagregação, realizamos sua variação e analisamos os resultados, comparando os resultados obtidos com outros métodos empregados para a mesma finalidade.

### 4.1 *Setup* dos Experimentos

Para a execução dos experimentos, usamos um computador com sistema operacional OS X El Captain versão 10.11.4, processador Intel Core *i5* @ 1.7 GHz e memória de 4 GB. Usamos também um computador com sistema operacional Ubuntu 14.04 LTS, processador Intel Core *i7* @ 3.4 GHz×8 e memória de 16 GB. O software usado foi o MATLAB [31], versão 2016a. Usamos uma abordagem denominada *validação cruzada* para avaliar a generalização do nosso modelo de desagregação. Isto consiste em particionamos o sinal de consumo de energia elétrica total  $\bar{x}(t)$  em subconjuntos mutuamente exclusivos de dimensões iguais. Utilizamos subconjuntos para estimar os parâmetros do modelo, denominados conjuntos de treinamento, e o restante para validar o modelo, denominados conjuntos de teste ou validação. Os métodos mais comuns de validação cruzada são três [32]: o primeiro, *hold out*, geralmente dividimos o conjunto total de dados na proporção de 2/3 para treinamento e 1/3 para teste, podendo usar outras proporções. O segundo, denominado *k-fold*, dividimos o conjunto total de dados em  $k$  subconjuntos de mesma dimensão. Então,

um subconjunto é usado para teste e os  $k - 1$  restantes para treinamento. Realizamos o procedimento  $k$  vezes alternando de forma circular o subconjunto de teste. O terceiro, *leave-one-out*, é um caso específico do *k-fold*, em que  $k$  é igual à dimensão do conjunto total de dados. Em nosso caso, decidimos usar o método *k-fold* com  $k = 3$ .

## 4.2 Base de Dados

Utilizamos uma base pública para adquirir dados de consumo de energia elétrica, o *reference energy disaggregation data set* (REDD) [1], elaborada especificamente para pesquisas de desagregação de consumo de energia elétrica. Esta base contém medições de energia elétrica residencial de dois tipos: medições de corrente e tensão elétrica das duas fases de entrada da residência, adquiridas a 15 kHz, e medições de energia ativa da entrada da residência e dos dispositivos que compõem o sistema, amostrados a 1 Hz. A base de dados em baixa frequência é organizada em diretórios, cada um contendo medições de uma residência diferente e organizado de acordo com a seguinte estrutura:

```

REDD
├── low_freq
│   ├── house_{1 ... n}
│   │   ├── labels.dat
│   │   └── channel_{1 ... k}.dat

```

Cada arquivo `channel_i.dat` é organizado com o instante de tempo em que a medição de consumo de energia elétrica foi adquirida, no formato *Universal Time Coordinated* (UTC) em valores inteiros, e o respectivo valor da medição de potência elétrica, conforme exemplo a seguir:

1306541834	102.964
1306541835	103.125
1306541836	104.001
1306541837	102.994
1306541838	102.361
1306541839	102.589

Usamos a base de dados da casa nº 2 por conter menor quantidade de dispositivos. A complexidade de executar a desagregação é proporcional à quantidade de dispositivos que compõem o sinal de consumo de energia elétrica total [2]. Esta casa contém nove dispositivos, cada um com 318.759 amostras adquiridas em períodos que variam entre de 3 e 4s, identificados conforme tabela a seguir.

Tabela 4.1: Identificação dos dispositivos da casa nº 2 do REDD [1].

<b>Identificação</b>	<b>Descrição</b>
1	Dispositivos da cozinha
2	Iluminação
3	Fogão
4	Microondas
5	Lavadora de roupas
6	Dispositivos da cozinha
7	Geladeira
8	Lava-louças
9	Sem uso

### 4.3 Parâmetros que Influenciam na Desagregação

Os algoritmos e técnicas usadas para realizarmos a desagregação de um sinal de consumo de energia elétrica total possuem parâmetros que, ao serem modificados, afetam os resultados. Geralmente, os valores destes parâmetros são atribuídos com base em conhecimento empírico sobre o sistema [1–3, 7, 10, 13].

Ao elaborarmos as matrizes de estados estacionários  $\mathbf{X}$  e  $\mathbf{X}_i$  do sinal de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica dos dispositivos  $x_i(t)$  dos dispositivos, respectivamente, aplicamos a técnica SSI-SD e verificamos que dois parâmetros,  $s_{min}$  e  $\epsilon$ , influenciam na identificação da quantidade de estados estacionários de  $\mathbf{X}$  e  $\mathbf{X}_i$ , conforme pode ser visualizado na Figura 2.4. O parâmetro  $s_{min}$  corresponde à quantidade mínima de amostras necessárias para formar um estado estacionário e o parâmetro  $\epsilon$  corresponde à amplitude máxima entre amostras permitida para formar um estado estacionário. Estes dois parâmetros

são aplicados simultaneamente no SSI-SD.

No procedimento de extração de dicionários  $\mathbf{B}$  e  $\mathbf{B}_i$  do sinal de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica dos dispositivos  $x_i(t)$  dos dispositivos, respectivamente, aplicamos o algoritmo DS3 [7] e verificamos que dois parâmetros,  $\gamma$  e  $\alpha$ , influenciam na representatividade dos dicionários extraídos. O parâmetro  $\gamma$ , definido como parâmetro de regularização do DS3, e o parâmetro  $\alpha$ , definido como parâmetro de correção do DS3, são inversamente proporcionais à representatividade dos dicionários extraídos.

## 4.4 Planejamento dos Experimentos

Variamos os parâmetros  $\{s_{min}; \epsilon; \gamma; \alpha\}$  conforme valores apresentados na Tabela 4.2.

Tabela 4.2: Combinações dos parâmetros que influenciam a desagregação.

Parâmetro	Variação
$s_{min}$	$(2n + 1)$ , com $n = \{1, 2, \dots, 12\}$
$\epsilon$	$(3m)$ , com $m = \{1, 2, \dots, 12\}$
$\gamma$	$(0, 10; 0, 05)$
$\alpha$	$(0, 010; 0, 005; 0, 001)$

Aplicamos também quatro métodos de organização da matriz de soluções de desagregação  $\mathbf{C}$ , onde cada uma delas proporciona diferentes resultados de desagregação. Isso foi realizado porque um sinal de consumo de energia elétrica pode possuir diversas soluções de desagregação. Cada método aponta para a solução a ser escolhida, de acordo com um critério. No *método de organização 1*, organizamos a matriz de soluções de desagregação  $\mathbf{C}$  em função da frequência de ocorrência de estados estacionários dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos. No *método de organização 2*, organizamos a matriz de soluções de desagregação  $\mathbf{C}$  em função da ordem decrescente dos valores de potência elétrica estimada  $\hat{x}$ , ou seja, as soluções compostas por menores quantidades de dispositivos ligados. O *método de organização 3* é semelhante ao método de organização 2, com a diferença de que a ordem de organização é crescente. No *método de organização 4*, organizamos a



matriz de soluções de desagregação  $\mathbf{C}$  com base na ordem crescente do conjunto com soluções que possuem mais valores nulos, ou seja, em função da ordem crescente das soluções de desagregação com maior quantidade de dispositivos desligados. Elaboramos o **Algoritmo 5** para este procedimento.

Tabela 4.3: Métodos de organização da matriz de soluções de desagregação  $\mathbf{C}$ .

Método	Descrição
1	Frequência de ocorrência de estados estacionário (Q) em ordem crescente
2	Potência elétrica da estimativa (Y) da desagregação em ordem decrescente
3	Potência elétrica da estimativa (Y) da desagregação em ordem crescente
4	Dispositivos de menor consumo (P)

## 4.5 Descrição das Métricas

Existem diversas abordagens para avaliar o desempenho da desagregação de um sinal de consumo de energia elétrica total  $\bar{x}(t)$ , e os critérios para definir a métrica a ser usada não são padronizados [13, 15]. As métricas mais utilizadas são duas, uma que avalia o desempenho da desagregação do sinal de consumo de energia elétrica total  $\bar{x}(t)$  com relação à sua estimativa  $\hat{x}(t)$ , denominada *acurácia*, dada pela relação entre o consumo de energia elétrica total  $\bar{x}(t)$  e o somatório dos sinais de consumo de energia elétrica estimados  $\hat{x}_i(t)$  dos dispositivos, em um intervalo de tempo  $t = \{1, 2, \dots, T\}$  [1, 2, 13], representado pela equação:

$$Acurácia = 1 - \frac{\sum_{t=1}^T \sum_{i=1}^L |x_i(t) - \hat{x}_i(t)|}{2 \sum_{t=1}^T \bar{x}(t)} \quad (4.1)$$

A segunda métrica avalia o desempenho da desagregação dos sinais de consumo de energia elétrica dos dispositivos  $x_i(t)$  com os respectivos sinais de consumo de energia elétrica estimados  $\hat{x}_i(t)$ , denominado *erro médio quadrático* da desagregação do dispositivo  $i$ , dada pela diferença entre o consumo de energia elétrica medido

$x_i(t)$  e estimado  $\hat{x}_i(t)$  do dispositivo  $i$ , [10], representado pela equação:

$$e_i = \left[ \frac{1}{T} \sum_{i=1}^L [x_i(t) - \hat{x}_i(t)]^2 \right]^{1/2} \quad (4.2)$$

Outras métricas para avaliar o desempenho da desagregação podem ser usadas [13], como a acurácia definida como a relação entre as estimativas corretamente assinaladas e as estimativas totais analisadas [9], uma abordagem por matriz de confusão [13] e o erro normalizado de desagregação para avaliar o desempenho da desagregação dos dispositivos [10].

## 4.6 Resultados

Apresentamos nesta seção os resultados obtidos com a execução da metodologia proposta. Realizamos a comparação com resultados de trabalhos que também usaram o REDD [7]. Modificamos os valores dos parâmetros  $\{s_{min}; \epsilon; \gamma; \alpha\}$ , de acordo com a Tabela 4.2, e obtivemos 864 resultados de medição do desempenho de desagregação, para o *método de organização 1* da matriz de soluções de desagregação  $\mathbf{C}$ , para o sinal de consumo de energia elétrica total  $\bar{x}(t)$  e para o sinal de consumo de energia elétrica  $x_i(t)$  dos dispositivos. Observe que nesta etapa, não dispomos dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, o que nos impossibilita calcular o desempenho da desagregação dos sinais de consumo de energia elétrica total  $\bar{x}(t)$  e  $x_i(t)$  dos dispositivos, porém, a base de dados que adquirimos, o REDD [7], possui estas informações para o conjunto de dados usados para teste, permitindo calcularmos as métricas de desempenho apresentadas. Realizamos a comparação dos resultados obtidos com os de outras metodologias, e avaliamos o resultado da variação do conjunto de parâmetros  $\{s_{min}; \epsilon; \gamma; \alpha\}$ . Os valores adotados na variação dos parâmetros são apresentados na Tabela 4.2.

### 4.6.1 Acurácia da Desagregação

Apresentamos a acurácia da desagregação em função da variação dos valores do conjunto de parâmetro  $\{s_{min}; \epsilon; \gamma; \alpha\}$ . Na Figura 4.1, apresentamos os resultados da acurácia dos conjuntos de treino, validação e teste, organizados em ordem de

crecente de acurácia do conjunto de dados de validação. Consideramos o intervalo inicial do gráfico, com as primeiras 36 combinações de parâmetros, para análise da acurácia da desagregação. Ampliamos este intervalo e o apresentamos na Figura 4.2, detalhando as combinações dos parâmetros na Tabela 4.4.

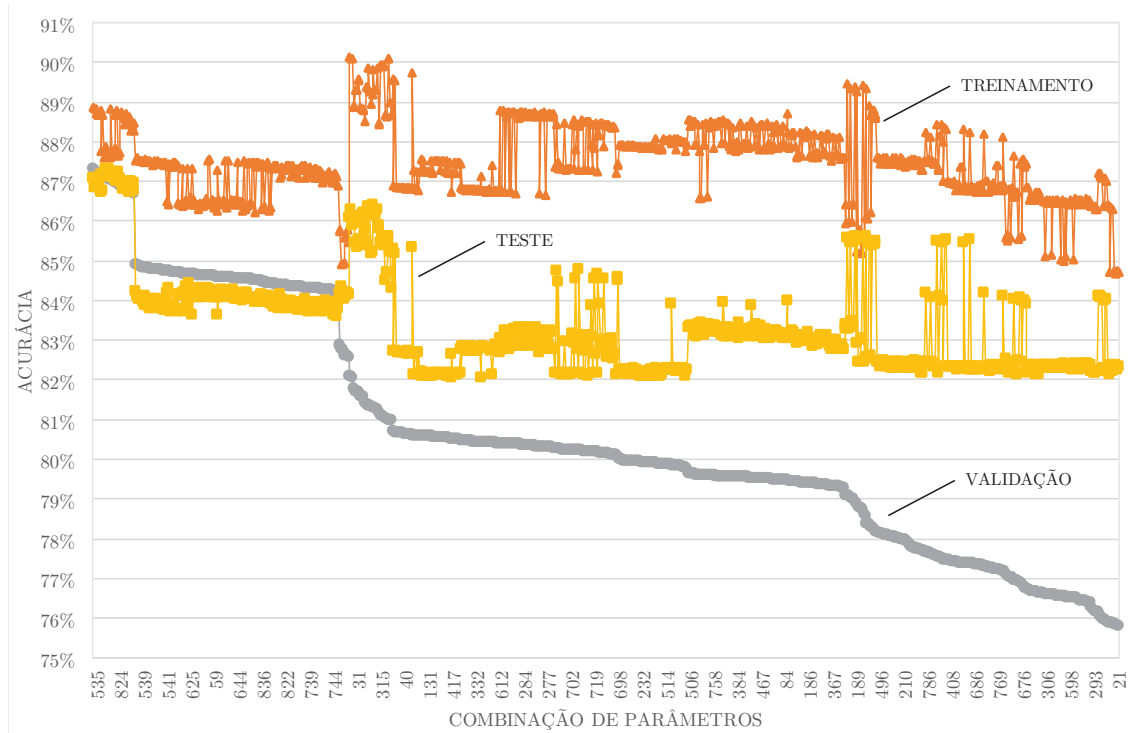


Figura 4.1: Acurácia da desagregação.

Tabela 4.4: Combinações dos parâmetros que influenciam a desagregação.

Índice	Combinação de parâmetros $\{s_{min}; \epsilon; \gamma; \alpha\}$	Treino (%)	Validação (%)	Teste (%)
535	{7; 9; 0,10; 0,010}	88,86	87,33	87,09
247	{9; 9; 0,10; 0,010}	88,82	87,27	86,85
531	{5; 9; 0,10; 0,010}	88,71	87,26	87,08
536	{7; 12; 0,10; 0,010}	88,82	87,24	86,97
243	{5; 6; 0,10; 0,010}	88,67	87,20	86,83
532	{5; 12; 0,10; 0,010}	88,69	87,19	87,01
248	{7; 15; 0,10; 0,010}	88,78	87,18	86,73
343	{7; 6; 0,10; 0,010}	87,76	87,16	87,18
244	{5; 15; 0,10; 0,010}	88,65	87,13	86,77

... continuação

Índice	Combinação de parâmetros $\{s_{min}; \epsilon; \gamma; \alpha\}$	Treino (%)	Validação (%)	Teste (%)
339	{3; 9; 0,10; 0,010}	87,60	87,11	87,19
631	{9; 6; 0,10; 0,010}	87,79	87,10	87,32
55	{9; 12; 0,10; 0,010}	87,88	87,08	87,13
344	{9; 15; 0,10; 0,010}	87,71	87,08	87,11
627	{5; 18; 0,10; 0,010}	87,63	87,04	87,31
340	{7; 18; 0,10; 0,010}	87,59	87,03	87,14
823	{11; 9; 0,10; 0,010}	88,82	87,03	87,13
51	{11; 6; 0,10; 0,010}	87,71	87,03	87,14
632	{7; 21; 0,10; 0,010}	87,75	87,01	87,23
56	{7; 3; 0,10; 0,010}	87,83	87,01	87,06
819	{5; 3; 0,10; 0,010}	88,68	86,97	87,11
824	{11; 12; 0,10; 0,010}	88,78	86,97	87,00
628	{3; 12; 0,10; 0,010}	87,62	86,97	87,26
52	{5; 21; 0,10; 0,010}	87,71	86,96	87,09
820	{3; 15; 0,10; 0,010}	88,66	86,90	87,05
439	{3; 6; 0,10; 0,010}	88,74	86,85	86,97
151	{9; 18; 0,10; 0,010}	88,65	86,84	86,82
435	{11; 15; 0,10; 0,010}	88,59	86,80	86,97
727	{13; 9; 0,10; 0,010}	88,43	86,79	86,99
440	{13; 12; 0,10; 0,010}	88,70	86,78	86,87
147	{15; 9; 0,10; 0,010}	88,50	86,78	86,81
152	{15; 12; 0,10; 0,010}	88,62	86,76	86,73
436	{15; 9; 0,10; 0,010}	88,57	86,74	86,92
723	{15; 6; 0,10; 0,010}	88,28	86,74	86,99
728	{13; 15; 0,10; 0,010}	88,40	86,73	86,90
148	{13; 18; 0,10; 0,010}	88,48	86,72	86,77
724	{11; 18; 0,10; 0,010}	88,27	86,68	86,95




Figura 4.2: Acurácia da desagregação.

#### 4.6.2 Comparação da Acurácia de Desagregação com Outras Metodologias

Apresentamos a acurácia da desagregação de outras metodologias que usam o REDD como base de dados na Tabela 4.5 e a nossa metodologia na Tabela 4.6. Conforme visualizado na linha 1 da Tabela 4.4, consideramos a maior acurácia observada no conjunto de dados de validação, ou seja, 87,3%. O algoritmo *Simple Mean* calcula a porcentagem de consumo total de cada dispositivo e estima a decomposição do sinal de consumo de energia elétrica total de acordo com esta porcentagem a cada instante de tempo [7]. O algoritmo *Factorial Hidden Markov Model* (FHMM), usado na desagregação do consumo de energia elétrica, considera que cada dispositivo pode ser descrito usando um modelo oculto de markov - *Hidden Markov Model* (HMM). Neste caso, a desagregação é tomada como um problema de inferência onde, dada uma sequência de amostras de consumo de energia elétrica total, calculamos a probabilidade do consumo de energia elétrica dos dispositivos que compõem este sinal [1]. O algoritmo *Powerlets* utiliza um conjunto de dados de consumo de energia elétrica de diferentes dispositivos para treino e identifica padrões de consumo de energia. Em seguida, elaboramos um dicionário com os padrões identificados e

executamos a desagregação [7].

Tabela 4.5: Acurácia de metodologias aplicadas à casa nº 2 da base de dados REDD [1].

Método	Acurácia (%)
<i>Simple Mean</i>	39,0
FHMM	59,6
<i>Powerlets</i>	79,0

Tabela 4.6: Acurácia da metodologia SSI-SD (proposta) de acordo com o método de organização da matriz de soluções de desagregação  $\mathbf{C}$ , usando a casa nº 2 da base de dados REDD [1].

Método (proposto)		Acurácia (%)
SSI-SD	método de organização 1	87,3
	método de organização 2	56,1
	método de organização 3	56,0
	método de organização 4	72,6

### 4.6.3 Erro Médio Quadrático de Desagregação dos Dispositivos

Apresentamos o erro médio quadrático da desagregação dos dispositivos  $e_i$  nas Figuras 4.3 a 4.11, e seguimos a mesma organização da combinação dos parâmetros usados na Seção 4.6.1.

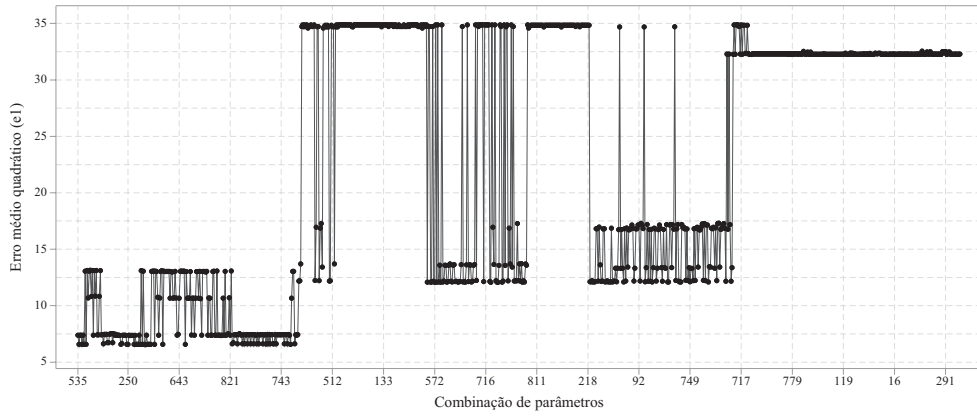


Figura 4.3: Erro médio quadrático da desagregação do dispositivo 1.




Figura 4.4: Erro médio quadrático da desagregação do dispositivo 2.




Figura 4.5: Erro médio quadrático da desagregação do dispositivo 3.




Figura 4.6: Erro médio quadrático da desagregação do dispositivo 4.

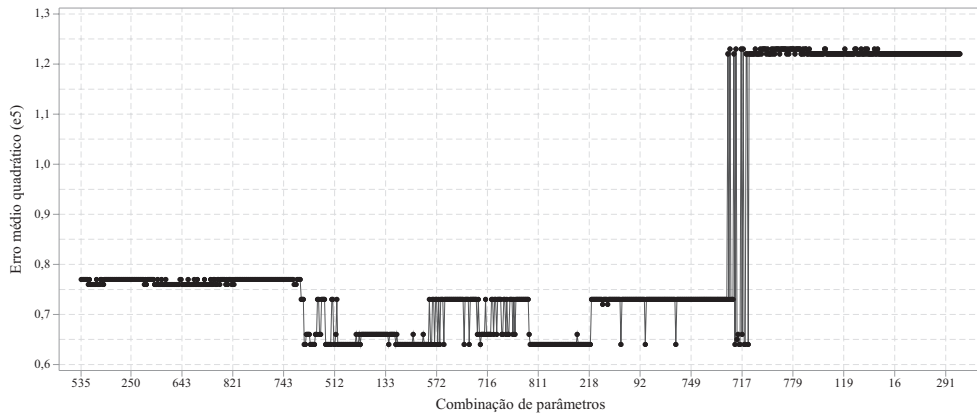


Figura 4.7: Erro médio quadrático da desagregação do dispositivo 5.

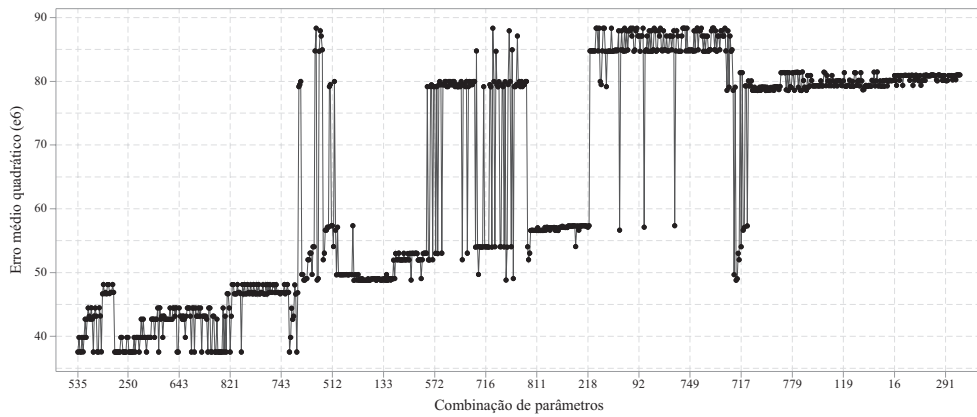


Figura 4.8: Erro médio quadrático da desagregação do dispositivo 6.



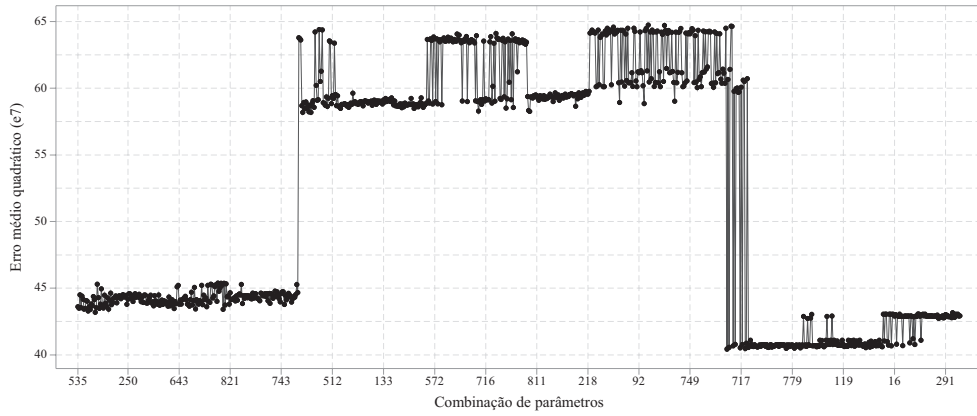


Figura 4.9: Erro médio quadrático da desagregação do dispositivo 7.




Figura 4.10: Erro médio quadrático da desagregação do dispositivo 8.




Figura 4.11: Erro médio quadrático da desagregação do dispositivo 9.

## 4.7 Análises dos Resultados

### 4.7.1 Acurácia da Desagregação

Ao analisarmos a Tabela 4.4, verificamos que a acurácia da desagregação é maior para valores de  $s_{min} = \{5; 7; 9\}$ . Geralmente, considera-se que não sejam utilizados valores menores do que  $s_{min} = 3$  [2,13]. Ainda analisando a Tabela 4.4, com relação a  $\epsilon$ , a acurácia da desagregação é maior para os valores de  $\epsilon = \{6; 9; 12; 15\}$ . Observe que valores menores de  $\epsilon$  resultam em dicionários com maior representatividade. Os valores dos parâmetros  $\gamma$  e  $\alpha$  do algoritmo DS3 iguais a 0,10 e 0,010, respectivamente, corresponderam à melhor acurácia de desagregação.

### 4.7.2 Método de Organização da Matriz de Soluções de Desagregação C

Observamos que o método de organização 1 resultou em maior acurácia de desagregação. Isto acontece porque na etapa de elaboração dos dicionários, identificamos as soluções com maior probabilidade de ocorrência. Os outros métodos apresentaram menor acurácia de desagregação porque consideram premissas e restrições na identificação das soluções, o que nem sempre corresponde aos aspectos práticos de operação do sistema.

### 4.7.3 Erro Médio Quadrático de Desagregação dos Sinais de Consumo de Energia Elétrica dos Dispositivos

O erro médio quadrático de desagregação dos sinais de consumo de energia elétrica dos dispositivos é maior nos casos em que a potência elétrica do dispositivo é baixa, neste caso, valores menores que 15 W. Este resultado é esperado [2] e indica que equipamentos de baixa potência são de difícil identificação.

## 4.8 Considerações Finais

Nesta seção, apresentamos a configuração dos experimentos, detalhando o *setup*, a base de dados utilizada, as análises aplicadas para identificar os parâmetros

que influenciam na desagregação, o planejamento dos experimentos e os resultados. Ao final, comparamos os resultados obtidos com os de algumas outras metodologias. Na próxima seção, apresentamos o procedimento proposto para a desagregação usando análise de componentes principais, detalhando a metodologia de extração de dicionários e o procedimento de desagregação.

Na próxima seção, apresentamos o procedimento proposto para monitoramento não intrusivo de consumo de energia elétrica usando uma abordagem por análise de componentes principais.

# Capítulo 5

## Procedimento Proposto para Monitoramento Não Intrusivo de Sinais de Consumo de Energia Elétrica Usando Análise de Componentes Principais

Neste capítulo, investigamos a desagregação de um sinal de consumo de energia utilizando a técnica denominada análise de componentes principais (do inglês, *principal component analysis* - PCA) aplicada a sinais temporais ou, simplesmente, análise singular espectral (do inglês, *singular spectrum analysis* - SSA). No caso desta pesquisa, formamos um dicionário com as características de consumo dos dispositivos para realizar a desagregação e incrementamos sua representatividade.

### 5.1 Introdução

Nesta seção, apresentamos a metodologia utilizada na desagregação de um sinal de consumo de energia elétrica total  $x(t)$  por uma abordagem usando PCA [33]. Inferimos que a componente principal de maior energia do sinal de consumo de energia elétrica total  $x(t)$  corresponde ao padrão temporal do sinal de consumo de energia elétrica. Desta forma, podemos propor uma abordagem para desagregar um

sinal de consumo de energia elétrica mediante análise de componentes principais. A metodologia pode ser dividida em duas etapas. Na primeira, conforme ilustrado na Figura 5.1<sup>①</sup>, adquirimos o sinal de consumo de energia elétrica total  $x(t)$  e os sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos. Em seguida<sup>②</sup>, com a aplicação da PCA a estes sinais de consumo de energia elétrica, elaboramos um dicionário  $\mathcal{B}$  composto pelo dicionário  $\mathbf{B}$  do sinal de consumo de energia elétrica total  $x(t)$  e pelos dicionários  $\mathbf{B}_i$  dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos. Na segunda etapa<sup>③</sup>, adquirimos o sinal de consumo de energia elétrica total  $\bar{x}(t)$  que desejamos desagregar e<sup>④</sup>, com base no dicionário  $\mathcal{B}$ , obtemos estimativas do sinal de consumo de energia elétrica total  $\bar{x}(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, representando-os por  $\hat{x}(t)$  e  $\hat{x}_i(t)$ .

## 5.2 Dicionário

Conforme ilustrado na Figura 5.2, primeiramente<sup>②</sup>, consideramos que o dicionário  $\mathcal{B}$  é formado por dicionários  $\mathbf{B}$  e  $\mathbf{B}_i$  sendo, respectivamente, do sinal de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos. Para concebê-los<sup>②a</sup>, inicialmente decomparamos os sinais de consumo de energia elétrica total  $x(t)$  e os sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, usando análise singular espectral (ver Seção 2.5). Obtemos, deste procedimento, matrizes características de autovetores  $\mathbf{P}$  e autovalores  $\mathbf{\Lambda}$  para  $x(t)$  e matrizes características de autovetores  $\mathbf{P}_i$  e autovalores  $\mathbf{\Lambda}_i$  para  $x_i(t)$ . Em seguida<sup>②b</sup>, compomos o dicionário  $\mathcal{B}$  selecionando  $m$  componentes principais de maior energia destas matrizes, cujos autovetores representamos por  $\oplus P^{(m)}$  e cujos autovalores representamos por  $\oplus \lambda^{(m)}$ , e elaboramos os dicionários  $\mathbf{B}$  e  $\mathbf{B}_i$ . Ilustramos esta situação na Figura 5.1.

No **Algoritmo 7**, detalhamos o procedimento para obtermos o dicionário  $\mathcal{B}$ . A aplicação do SSA aos sinais de consumo de energia elétrica total  $x(t)$  e os sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, consiste inicialmente em dividirmos estes sinais em  $M = T/w$  segmentos de dimensão  $w$  e elaborarmos suas

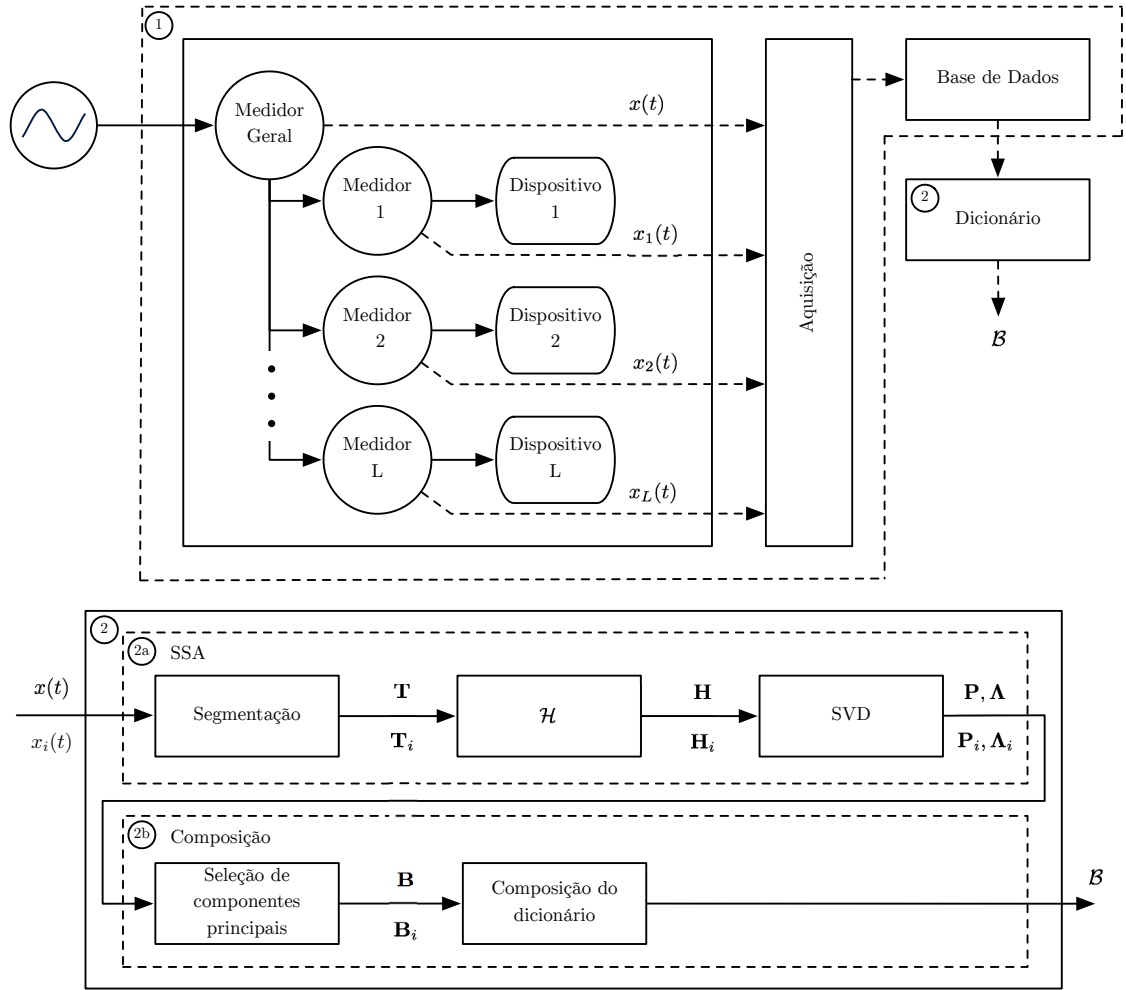


Figura 5.1: Extração de dicionários usando SSA.

correspondentes matrizes  $\mathbf{T}$  e  $\mathbf{T}_i$  [34].

$$\mathbf{T} = \begin{bmatrix} x(1) & x(w+1) & \cdots & x(Mw+1) \\ x(2) & x(w+2) & \cdots & x(Mw+2) \\ \vdots & \vdots & \ddots & \vdots \\ x(w) & x(2w) & \cdots & x(T) \end{bmatrix} \quad (5.1)$$

$$\mathbf{T}_i = \begin{bmatrix} x_i(1) & x_i(w+1) & \cdots & x_i(Mw+1) \\ x_i(2) & x_i(w+2) & \cdots & x_i(Mw+2) \\ \vdots & \vdots & \ddots & \vdots \\ x_i(w) & x_i(2w) & \cdots & x_i(T) \end{bmatrix} \quad (5.2)$$

Em seguida, para cada coluna  $j$  das matrizes  $\mathbf{T}$  e  $\mathbf{T}_i$ , aplicamos a transfor-

mação de *Hankel* de dimensão  $\ell$ , representada pela expressão  $\mathcal{H}_\ell\{\mathbf{T}^{(j)T}\}$ , e obtemos as matrizes  $\mathbf{H}$  e  $\mathbf{H}_i$ . Aplicamos a decomposição em valores singulares (SVD) (veja Seção 2.4) em  $\mathbf{H}\mathbf{H}^T$  e obtemos as matrizes de autovetores  $\mathbf{P} = [P^{(1)}, P^{(2)}, \dots, P^{(\ell)}]$  e de autovalores  $\mathbf{\Lambda} = \mathbf{diag}(\lambda(1), \lambda(2), \dots, \lambda(\ell))$ . Para  $\mathbf{H}_i\mathbf{H}_i^T$ , realizamos o mesmo procedimento e obtemos as matrizes de autovetores  $\mathbf{P}_i = [P_i^{(1)}, P_i^{(2)}, \dots, P_i^{(\ell)}]$  e de autovalores  $\mathbf{\Lambda}_i = \mathbf{diag}(\lambda_i(1), \lambda_i(2), \dots, \lambda_i(\ell))$ . Por fim, selecionamos  $m$  componentes principais de maior energia para formar o dicionário  $\mathbf{B}$ , de dimensão  $M$ , e  $m$  componentes principais de maior energia para formar os dicionários  $\mathbf{B}_i$ , de dimensão  $M$ . O dicionário  $\mathbf{B}$  será usado como indexador na busca pela solução de desagregação. Compomos então o dicionário  $\mathcal{B}$  a partir dos dicionários  $\mathbf{B}$  e  $\mathbf{B}_i$ .

$$\mathcal{B} = \left[ \begin{array}{c|ccc} \mathbf{B} & \mathbf{B}_1 & \mathbf{B}_2 & \dots & \mathbf{B}_L \end{array} \right] \quad (5.3)$$

$$\mathbf{B} = \left[ \begin{array}{c|ccc} \oplus P|_{j=1} & \oplus P|_{j=2} & \dots & \oplus P|_{j=M} \\ \oplus \lambda|_{j=1} & \oplus \lambda|_{j=2} & \dots & \oplus \lambda|_{j=M} \end{array} \right] \quad (5.4)$$

$$\mathbf{B}_i = \left[ \begin{array}{c|ccc} \oplus P_i|_{j=1} & \oplus P_i|_{j=2} & \dots & \oplus P_i|_{j=M} \\ \oplus \lambda_i|_{j=1} & \oplus \lambda_i|_{j=2} & \dots & \oplus \lambda_i|_{j=M} \end{array} \right] \quad (5.5)$$

---

**Algoritmo 7** Elaboração do dicionário usando SSA

---

**Entrada:**  $\ell; w; x$

**Saída:** Dicionário  $\mathcal{B}$

- 1: **para todo** coluna  $j$  de  $\mathbf{T}$  **faça** // Obtém a matriz  $\mathbf{T}$  conforme equação (5.1)
  - 2:      $\mathbf{H} \leftarrow \mathcal{H}_\ell\{\mathbf{T}^{(j)T}\}$  // Transformação de *Hankel*
  - 3:      $[\mathbf{P}, \mathbf{\Lambda}] \leftarrow \mathbf{SVD}(\mathbf{H}\mathbf{H}^T)$  // SVD em  $\mathbf{H}\mathbf{H}^T$  e obtém as matrizes  $\mathbf{P}$  e  $\mathbf{\Lambda}$
  - 4:      $\mathbf{B}^{(j)} \leftarrow [\oplus P \quad \oplus \lambda]^T$  // Elabora o dicionário  $\mathbf{B}$
  - 5:  $\mathcal{B} \leftarrow \left[ \begin{array}{c|ccc} \mathbf{B} & \mathbf{B}_1 & \dots & \mathbf{B}_L \end{array} \right]$  // Elabora o dicionário  $\mathcal{B}$
- 

### 5.3 Procedimento de Desagregação

Na segunda etapa do procedimento de desagregação, detalhada nesta seção<sup>③</sup>, adquirimos o sinal de consumo de energia elétrica total  $\bar{x}(t)$  que desejamos desagregar<sup>④</sup>,

elaboramos um dicionário  $\overline{\mathbf{B}}$  deste sinal, aplicando o **Algoritmo 7**<sup>5</sup>, e estimamos o sinal de consumo de energia elétrica total  $\hat{x}(t)$  e os sinais de consumo de energia elétrica  $\hat{x}_i(t)$  dos dispositivos. Nesta etapa, conhecemos apenas o sinal de consumo de energia elétrica total  $\overline{x}(t)$  e o dicionário  $\mathcal{B}$ . Ilustramos esta situação na Figura 5.2.

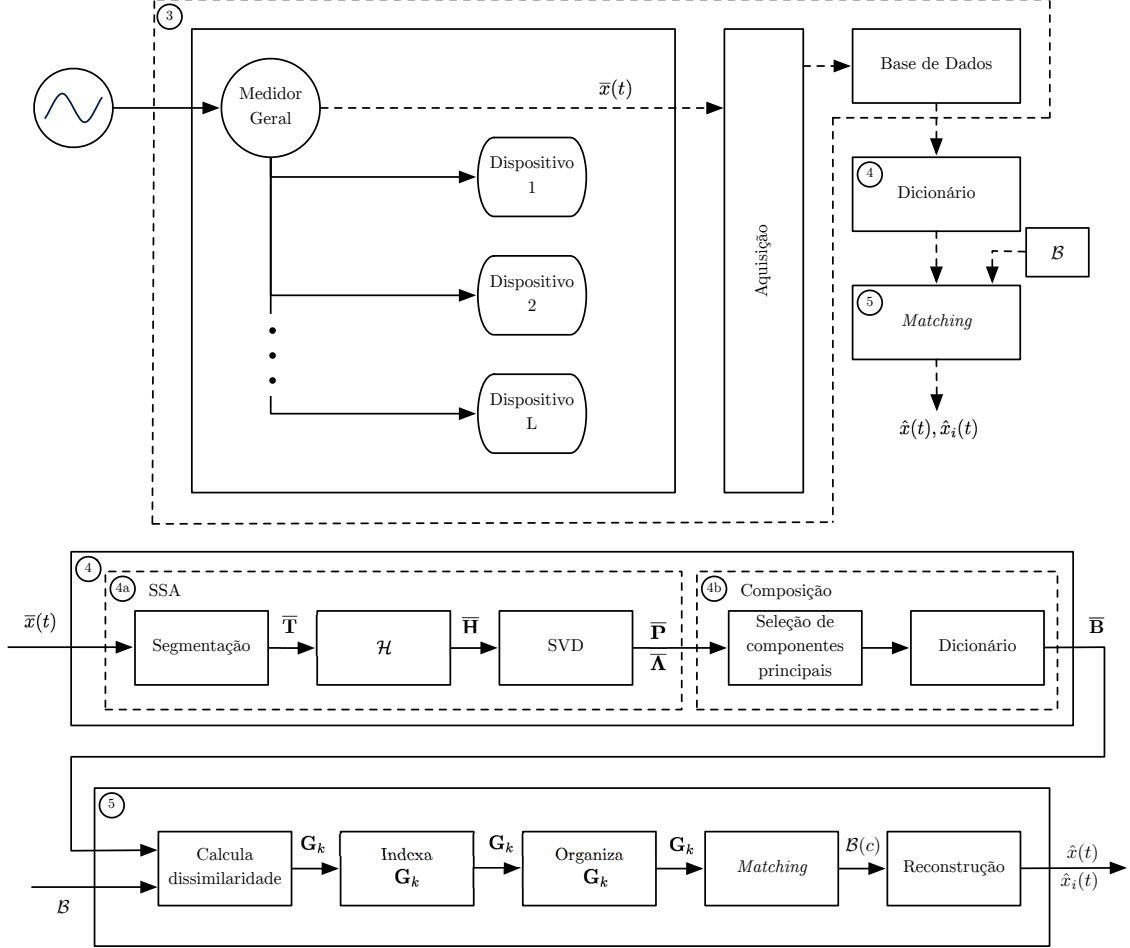


Figura 5.2: Desagregação de um sinal de consumo de energia elétrica usando SSA.

No **Algoritmo 8**, detalhamos o procedimento de desagregação. Inicialmente, segmentamos o sinal de consumo de energia elétrica total  $\overline{x}(t)$  que desejamos desagregar em  $M^* = T/w$  segmentos de dimensão  $w$  e aplicamos o mesmo procedimento usado para obter o dicionário  $\mathcal{B}$  na primeira etapa da desagregação. Assim, obtemos o dicionário  $\overline{\mathbf{B}}$ .

$$\overline{\mathbf{B}} = \begin{bmatrix} \oplus \overline{\mathbf{P}}|_{k=1} & \oplus \overline{\mathbf{P}}|_{k=2} & \cdots & \oplus \overline{\mathbf{P}}|_{k=M^*} \\ \oplus \overline{\boldsymbol{\lambda}}|_{k=1} & \oplus \overline{\boldsymbol{\lambda}}|_{k=2} & \cdots & \oplus \overline{\boldsymbol{\lambda}}|_{k=M^*} \end{bmatrix} \quad (5.6)$$



Em seguida, para cada coluna  $k$  de  $\overline{\mathbf{B}}$ , com  $k = \{1, 2, \dots, M^*\}$ , calculamos a dissimilaridade  $d_{kj}$  entre o autovetor  ${}^{\oplus}\overline{P}|_k$  de  $\mathbf{B}$  e os autovetores  ${}^{\oplus}P|_{j=1\dots M}$  de  $\mathcal{B}$  e obtemos a matriz de dissimilaridade  $\mathbf{G}_k$ , de dimensão  $M^*$ . Calculamos a dissimilaridade  $d_{kj}$  por métrica de similaridade de cosseno.

$$d_{kj} = \frac{({}^{\oplus}\overline{P}|_k) \cdot ({}^{\oplus}P|_j)}{\|({}^{\oplus}\overline{P}|_k)\| \|({}^{\oplus}P|_j)\|}, \quad k = \{1, \dots, M^*\}, j = \{1, \dots, M\} \quad (5.7)$$

$$\mathbf{G}_k = \begin{bmatrix} d_{k1} & d_{k2} & \dots & d_{kM} \end{bmatrix}^T \quad (5.8)$$

Depois, indexamos  $\mathbf{G}_k$ , inserindo uma primeira coluna com os índices de suas linhas  $Q = [1, 2, \dots, M]^T$ , e uma última coluna com o vetor  ${}^{\oplus}\mathbf{\Lambda} = [{}^{\oplus}\lambda|_{j=1}, \dots, {}^{\oplus}\lambda|_{j=M}]^T$  do dicionário  $\mathcal{B}$ .

$$\mathbf{G}_k \leftarrow \left[ Q \mid \mathbf{G}_k \mid {}^{\oplus}\mathbf{\Lambda} \right] \quad (5.9)$$

Organizamos então a matriz  $\mathbf{G}_k$  em ordem crescente de valores de dissimilaridade, com base na segunda coluna. Para cada coluna  $k$  de  $\overline{\mathbf{B}}$ , buscamos na terceira coluna de  $\mathbf{G}_k$ , em ordem crescente de organização, o elemento mais similar a  ${}^{\oplus}\overline{\lambda}|_k$  de  $\overline{\mathbf{B}}$  e verificamos o respectivo índice  $c$  na primeira coluna de  $\mathbf{G}_k$ . Com este índice, retornamos o vetor  $\mathcal{B}(c)$ .

$$\mathcal{B}(c) = \left[ {}^{\oplus}P(c) \quad {}^{\oplus}\lambda(c) \mid {}^{\oplus}P_1(c) \quad {}^{\oplus}\lambda_1(c) \mid \dots \mid {}^{\oplus}P_L(c) \quad {}^{\oplus}\lambda_L(c) \right]^T \quad (5.10)$$

Por fim, com base no vetor  $\mathcal{B}(c)$ , executamos o procedimento de reconstrução dos sinais de consumo de energia elétrica total  $\overline{x}(t)$  e das estimativas dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, usando a metodologia SSA, obtendo a solução da desagregação. O resultado são as estimativas dos sinais de consumo de energia elétrica total  $\hat{x}(t)$  e dos dispositivos  $\hat{x}_i(t)$ .

## 5.4 Considerações Finais

Conforme apresentamos, a desagregação de um sinal de consumo de energia elétrica pode ser realizada mediante uma abordagem por análise de componentes

---

**Algoritmo 8** Execução da desagregação usando SSA

---

**Entrada:**  $\ell; w; \bar{x}(t); \mathcal{B}$

**Saída:** Estimativas de desagregação  $\hat{x}(t)$  e  $\hat{x}_i(t)$

- 1:  $\bar{\mathbf{B}} \leftarrow \{\mathbf{Algoritmo 7}(\bar{x})\}$  // Aplicamos o **Algoritmo 7** em  $\bar{x}$ , obtendo  $\bar{\mathbf{B}}$
  - 2: **para todo** coluna  $k$  de  $\bar{\mathbf{B}}$  **faça**
  - 3:      $\mathbf{d}_{kj} \leftarrow \mathbf{dissimilaridade}(\oplus \bar{P}|_k; \oplus P|_j)$  // Calcula a dissimilaridade
  - 4:      $\mathbf{G}_k = [ d_{k1} d_{k2} \cdots d_{kM} ]^T$
  - 5:      $Q \leftarrow$  índice das linhas de  $\mathbf{G}_k$
  - 6:      $\mathbf{G}_k \leftarrow [ Q \mid \mathbf{G}_k \mid \oplus \mathbf{\Lambda} ]$  // Insere  $Q$  e  $\oplus \mathbf{\Lambda}$  de índices em  $\mathbf{G}_k$
  - 7:      $\mathbf{G}_k \leftarrow \mathbf{Organiza}(\mathbf{G}_k; 2)$  // Organiza  $\mathbf{G}_k$  com base na segunda coluna
  - 8:      $c \leftarrow \mathbf{Busca}(\mathbf{G}_k; \oplus \bar{\lambda}|_k)$  // Busca em  $\mathbf{G}_k$  valor mais similar a  $\oplus \bar{\lambda}|_k$
  - 9:      $\{\hat{x}(t), \hat{x}_1(t), \hat{x}_2(t), \dots, \hat{x}_L(t)\} \leftarrow \mathbf{Reconstrução}(\mathcal{B}(c))$  // Desagregação
- 

principais. Usamos uma variante desta técnica, a análise singular espectral para poder aplicá-la a um sinal unidimensional com variáveis dependentes, neste caso, o próprio sinal de consumo de energia elétrica. Elaboramos um dicionário de amostras de treino do sinal de consumo de energia elétrica total  $x(t)$  e dos sinais de consumo de energia elétrica  $x_i(t)$  dos dispositivos, e, através de um método de busca de similaridade entre vetores, encontramos o índice da solução da desagregação, possibilitando estimar os sinais de consumo de energia elétrica total  $\hat{x}(t)$  e dos dispositivos  $\hat{x}_i(t)$ . Com esta proposta, aumentamos a representatividade do dicionário e incrementamos o desempenho da desagregação.

Na próxima seção, apresentamos os procedimentos experimentais realizados para desagregar um sinal de consumo de energia elétrica usando a metodologia apresentada neste capítulo.

# Capítulo 6

## Procedimentos Experimentais

Nesta seção, apresentamos os procedimentos experimentais realizados para desagregar um sinal de consumo de energia elétrica usando análise de componentes principais (PCA). Os experimentos são executados de acordo com a metodologia apresentada na Seção 5. Ao final, apresentamos os resultados e as análises.

### 6.1 *Setup* dos Experimentos, Base de Dados e Métricas

O *setup* dos experimentos que usamos para desagregar um sinal de consumo de energia elétrica usando PCA encontra-se descrito na Seção 4.1. Para os experimentos, usamos a base de dados pública de consumo de energia elétrica *reference energy disaggregation data set* (REDD) [1], descrita na Seção 4.2. As métricas usadas para analisar o desempenho o procedimento de desagregação são as mesmas descritas na Seção 4.5.

### 6.2 Planejamento dos Experimentos

Nesta seção, detalhamos os procedimentos as variáveis adotadas nos experimentos. Para avaliar a generalização de nosso modelo de desagregação, usamos a abordagem de validação cruzada *hold out*, descrita na Seção 4.1, onde dividimos o conjunto total de dados na proporção de 1/2 para treinamento e 1/2 para teste. Na primeira etapa da desagregação, que consiste na elaboração do dicionário  $\mathcal{B}$ , usamos

$T = 150\,000$  amostras do sinal de consumo de energia elétrica  $x(t)$  e o mesmo valor para cada sinal de consumo de energia elétrica  $x_i(t)$  dos dispositivos. Cada sinal foi dividido em  $M = 15\,000$  segmentos (janelas) de dimensão  $w = 10$  amostras. Elaboramos as matrizes  $\mathbf{T}$  e  $\mathbf{T}_i$  e, para cada coluna  $j$  destas matrizes, aplicamos a transformação de *Hankel* de dimensão  $\ell = 5$  e obtemos as matrizes  $\mathbf{H} \in \mathbb{R}^{6 \times 5}$  e  $\mathbf{H}_i \in \mathbb{R}^{6 \times 5}$ . As matrizes de covariância são representadas por  $\mathbf{H}\mathbf{H}^T \in \mathbb{R}^{6 \times 6}$  e  $\mathbf{H}_i\mathbf{H}_i^T \in \mathbb{R}^{6 \times 6}$ . Em seguida, aplicamos a decomposição em valores singulares (SVD) a estas matrizes e obtemos as matrizes de autovetores  $\mathbf{P} \in \mathbb{R}^{6 \times 6}$  e  $\mathbf{P}_i \in \mathbb{R}^{6 \times 6}$  e de autovalores  $\mathbf{\Lambda} \in \mathbb{R}^{6 \times 6}$  e  $\mathbf{\Lambda}_i \in \mathbb{R}^{6 \times 6}$ . Isso significa que obtemos seis componentes principais para cada coluna  $j$  das matrizes  $\mathbf{T}$  e  $\mathbf{T}_i$ . Observe que a dimensão das matrizes de autovetores  $\mathbf{P}$  e  $\mathbf{P}_i$  e de autovalores  $\mathbf{\Lambda}$  e  $\mathbf{\Lambda}_i$ , se relacionam com a dimensão dos segmentos (janelas) de amostras de dimensão  $w$  que tomamos dos sinais de consumo de energia elétrica e com a dimensão  $\ell$  da transformação de *Hankel* da seguinte maneira:

$$\dim \mathbf{P} = \dim \mathbf{\Lambda} = w - \ell + 1 \quad (6.1)$$

Em seguida, para cada segmento dos sinais de consumo de energia, selecionamos a primeira componente principal, o que corresponde, neste caso, aos autovetores  $^{(1)}P$  e  $^{(1)}P_i$  das matrizes de autovetores  $\mathbf{P}$  e  $\mathbf{P}_i$ , respectivamente, e aos autovalores  $^{(1)}\lambda$  e  $^{(1)}\lambda_i$  das matrizes de autovalores  $\mathbf{\Lambda}$  e  $\mathbf{\Lambda}_i$ . Elaboramos, respectivamente, os dicionários  $\mathbf{B}$  do sinal de consumo de energia elétrica  $x(t)$ , conforme equação (5.4) e  $\mathbf{B}_i$  do sinal de consumo de energia elétrica  $x_i(t)$  dos dispositivos, conforme equação (5.5). Por fim, formamos o dicionário  $\mathcal{B}$ , conforme equação (5.3).

Para a segunda etapa da desagregação, usamos  $T = 150\,000$  amostras de um sinal de consumo de energia elétrica total  $\bar{x}(t)$ , dividido em  $M^* = 15\,000$  segmentos (janelas) de dimensão  $w = 10$  amostras, e extraímos o dicionário  $\bar{\mathbf{B}}$ . Em seguida, para cada autovetor  $^{(1)}\bar{P}|_k$  do dicionário  $\bar{\mathbf{B}}$ , procuramos um conjunto de autovetores  $^{(1)}P|_j$  similares no dicionário  $\mathcal{B}$ . Isso é feito pelo cálculo da similaridade do cosseno, conforme equação (5.7), entre o autovetor  $^{(1)}\bar{P}|_k$  de  $\bar{\mathbf{B}}$  e todos os autovetores  $^{(1)}P|_j$  de  $\mathcal{B}$ , com  $j = \{1, 2, \dots, M\}$ . Identificamos o conjunto de autovalores de  $\mathcal{B}$  com similaridade maior que 99,9% e identificamos o que possui autovalor mais similar ao autovalor  $^{(1)}\bar{\lambda}$  de  $\bar{\mathbf{B}}$ . Identificamos o índice  $c$  do dicionário  $\mathcal{B}$  e reconstruímos os

sinais de consumo de energia elétrica, obtendo as estimativas  $\hat{x}(t)$  e  $\hat{x}_i(t)$ .

## 6.3 Resultados

Apresentamos nesta seção os resultados obtidos com a execução da metodologia proposta. Executamos a desagregação de acordo com os valores e parâmetros declarados na Seção 6.2, apresentados na Tabela 6.1.

Tabela 6.1: Valores dos parâmetros usados na desagregação

Parâmetro	Valor
Amostras de treino	150.000
Amostras de teste	150.000
Dimensão da segmentação dos sinais de consumo de energia	10
Dimensão da transformação de <i>Hankel</i>	5
Componente principal de maior energia considerada	1 <sup>a</sup> componente

### 6.3.1 Apresentação da Acurácia de Desagregação de Outras Metodologias e da Metodologia Proposta

Apresentamos a acurácia da desagregação de outras metodologias que usaram o REDD como base de dados na Tabela 6.2. Apresentamos a acurácia da desagregação da metodologia proposta, a SSI-SD e SSI-SD-PCA, na Tabela 6.3. Os algoritmos que usamos para comparação, apresentados na Seção 4.6.2, são os seguintes:

- *Simple Mean*: calcula a média do quadrado dos erros entre o consumo de energia estimado de cada dispositivo e o consumo medido a cada instante de tempo [7];
- *Factorial Hidden Markov Model* (FHMM): considera que cada dispositivo  $i$  pode ser descrito usando um modelo oculto de markov - *Hidden Markov Model* (HMM). Neste caso, a desagregação é tomada como um problema de inferência onde, dada uma sequência de amostras de consumo de energia elétrica total, calculamos a probabilidade do consumo de energia elétrica dos dispositivos que compõem este sinal [1];

- *Powerlets*: utiliza um conjunto de dados de consumo de energia elétrica de diferentes dispositivos para treino e identifica padrões de consumo de energia. Em seguida, elaboramos um dicionário com os padrões identificados e executamos a desagregação [7];
- SSI-SD: método proposto nesta dissertação na Seção 3.

Tabela 6.2: Acurácia de metodologias aplicadas à casa nº 2 da base de dados REDD [1].

Método	Acurácia (%)
<i>Simple Mean</i>	39,0
FHMM	59,6
<i>Powerlets</i>	79,0

Tabela 6.3: Acurácia das metodologias SSI-SD e SSI-SD-PCA (propostas), usando a casa nº 2 da base de dados REDD [1].

Método (proposto)	Acurácia (%)
SSI-SD	87,3
SSI-SD-PCA	97,2

### 6.3.2 Erro Médio Quadrático de Desagregação dos Dispositivos

Apresentamos o erro médio quadrático de desagregação, usando a metodologia proposta SSI-SD-PCA, dos dispositivos  $e_i$  na Tabela 6.4.

## 6.4 Análise dos Resultados

### 6.4.1 Acurácia da Desagregação

A acurácia da desagregação foi maior para o método SSI-SD-PCA proposto. O erro médio quadrático de desagregação dos sinais de consumo de energia elétrica

Tabela 6.4: Erro médio quadrático de desagregação dos dispositivos

Dispositivo		Erro médio quadrático $e_i$ (SSI-SD-PCA)	
Identificação	Descrição	Treino	Teste
1	Dispositivos de cozinha	4,3	30,0
2	Iluminação	1,4	44,5
3	Fogão	2,8	21,2
4	Microondas	20,8	56,7
5	Lavadora de roupas	0,3	0,9
6	Dispositivos de cozinha	37,4	73,1
7	Geladeira	11,7	59,0
8	Lava-louças	7,4	65,4
9	Sem uso	1,7	3,2

dos dispositivos foi maior nos dispositivos 6, 8 e 4, na etapa de teste. Na Tabela 6.4 verificamos que os erros médios quadráticos dos conjuntos de teste são maiores que os do conjunto de treino. Isso acontece porque no conjunto de teste, existem estados de operação que não foram observados no conjunto de treino. O classificador, neste caso, procura no conjunto de teste a estimativa mais próxima observada no conjunto de treino, ocasionando um erro maior. Este resultado é esperado [2] e indica que equipamentos de estados de operação diversos são de difícil identificação.

# Capítulo 7

## Conclusões

### 7.1 Considerações Finais

Abordamos o problema de desagregação de sinais de energia elétrica e duas contribuições foram propostas: na primeira, modificamos o algoritmo *steady-state identification* (SSI) para contemplar sinais com dimensões variáveis e realizamos uma análise de parâmetros que influenciam na formação dos dicionários. Os experimentos, realizados utilizando a base de dados REDD [1], demonstram que a proposta produz resultados de desagregação de maior acurácia, quando comparado com outras técnicas e que estes resultados possuem correlação com os parâmetros analisados. A segunda contribuição mostra que podemos aplicar a análise de componentes principais ao problema de desagregação de um sinal de consumo de energia elétrica. Verificamos que, através da metodologia proposta, a acurácia da desagregação apresenta resultados de maior acurácia, quando comparado com outras técnicas.

### 7.2 Propostas para Trabalhos Futuros

Apresentamos algumas propostas para pesquisas futuras relacionadas aos métodos apresentados nesta dissertação. As propostas são:

- Nesta dissertação, usamos a base de dados REDD [1] para o procedimento de desagregação. Outras bases de dados de consumo de energia elétrica podem ser investigadas quanto à possibilidade de aplicação das metodologias apresentadas.



- A identificação de eventos de estados estacionários e de transição nos sinais de consumo de energia elétrica foi realizada mediante um conjunto de parâmetros. A investigação de outros parâmetros pode influenciar nos resultados da desagregação.
- Na metodologia proposta SSI-SD, os dicionários dos sinais de consumo de energia elétrica foram obtidos usando o algoritmo DS3 [14]. Podem ser investigadas a aplicação de outras técnicas de extração de representatividades de conjuntos para obtenção dos dicionários.
- A extração de representatividades para a obtenção dos dicionários envolveu o uso de medida de dissimilaridade de cosseno. A aplicação de outras técnicas de medida de dissimilaridade podem resultar em diferentes dicionários, especialmente as que não necessitem que os conjuntos de dados sejam de mesma dimensão.
- Não foi possível verificar os procedimentos usados para o cálculo da acurácia de desagregação das técnicas existentes. Nesta dissertação, realizamos o procedimento de duas maneiras, usando validação cruzada, uma usando o método *k-fold* e outra usando o *hold out*. Pode ser elaborado um procedimento com a proposta de padronizar o cálculo da acurácia de desagregação, o que possibilitaria comparar o desempenho das técnicas dentro das mesmas métricas.

# Referências Bibliográficas

- [1] KOLTER, J. Z., JOHNSON, M. J., “REDD: A Public Data Set for Energy Disaggregation Research”, *In proceedings of the SustKDD Workshop on Data Mining Applications in Sustainability*, v. 25, pp. 59–62, 2011.
- [2] HART, G. W., “Nonintrusive Appliance Load Monitoring”, *Proceedings of the IEEE*, v. 80, n. 12, pp. 1870–1891, 1992.
- [3] NORFORD, L. K., LEEB, S. B., “Non-intrusive Electrical Load Monitoring in Commercial Buildings Based on Steady-state and Transient Load-detection Algorithms”, *Energy and Buildings*, v. 24, n. 1, pp. 51–64, 1996.
- [4] PATEL, S. N., ROBERTSON, T., KIENZT, J. A., et al., “At the Flick of a Switch: Detecting and Classifying Unique Electrical Events on the Residential Power Line”. In: *Proceedings of the International Conference on Ubiquitous Computing, UbiComp*, pp. 271–288, Springer-Verlag, 2007.
- [5] GUPTA, S., REYNOLDS, M. S., PATEL, S. N., “ElectriSense: Single-point Sensing Using EMI for Electrical Event Detection and Classification in the Home”. In: *Proceedings of the ACM International Conference on Ubiquitous Computing*, pp. 139–148, New York, NY, USA, 2010.
- [6] PARSON, O., GHOSH, S., WEAL, M., et al., “Non-intrusive Load Monitoring Using Prior Models of General Appliance Types”. In: *Proceedings of the National Conference on Artificial Intelligence*, pp. 356–362, AAAI, 2012.
- [7] ELHAMIFAR, E., SASTRY, S., “Energy Disaggregation via Learning ‘Powerlets’ and Sparse Coding”. In: *Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence, AAAI’15*, pp. 629–635, AAAI Press, 2015.

- [8] CHAN, W., SO, A. T., LAI, L., “Harmonics Load Signature Recognition by Wavelets Transforms”. In: *Proceedings of the International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*, pp. 666–671, 2000.
- [9] SRINIVASAN, D., NG, W. S., LIEW, A. C., “Neural-network-based Signature Recognition for Harmonic Source Identification”, *IEEE Transactions on Power Delivery*, v. 21, n. 1, pp. 398–405, 2006.
- [10] KOLTER, J. Z., BATRA, S., NG, A. Y., “Energy Disaggregation via Discriminative Sparse Coding”, In: LAFFERTY, J., WILLIAMS, C., SHAWETAYLOR, J., et al. (eds), *Advances in Neural Information Processing Systems 23*, pp. 1153–1161, 2010.
- [11] KOLTER, J. Z., JAAKKOLA, T., “Approximate Inference in Additive Factorial HMMs with Application to Energy Disaggregation”. In: *Proceedings of the International Conference on Artificial Intelligence and Statistics (AISTATS)*, v. 22, pp. 1472–1482, 2012.
- [12] SHAO, H., MARWAH, M., RAMAKRISHNAN, N., “A Temporal Motif Mining Approach to Unsupervised Energy Disaggregation: Applications to Residential and Commercial Buildings”, *AAAI Conference on Artificial Intelligence*, 2013.
- [13] FIGUEIREDO, M. B., *Contributions to Electrical Energy Disaggregation in a Smart Home*, Ph.D. Thesis, 2013.
- [14] ELHAMIFAR, E., SAPIRO, G., SASTRY, S. S., “Dissimilarity-based Sparse Subset Selection”, *CoRR*, v. abs/1407.6810, 2014.
- [15] ZOHA, A., GLUHAK, A., IMRAN, M. A., et al., “Non-Intrusive Load Monitoring Approaches for Disaggregated Energy Sensing: A Survey”, *Sensors*, v. 12, n. 12, pp. 16838–16866, 2012.
- [16] BARANSKI, M., VOSS, J., “Genetic Algorithm for Pattern Detection in NI-ALM Systems”. In: *Systems, Man and Cybernetics, 2004 IEEE International Conference on*, v. 4, pp. 3462–3468, 2004.

- [17] SUZUKI, K., INAGAKI, S., SUZUKI, T., et al., “Nonintrusive appliance load monitoring based on integer programming”. In: *SICE Annual Conference, 2008*, pp. 2742–2747, 2008.
- [18] BERGES, M., GOLDMAN, E., MATTHEWS, H. S., et al., “Learning systems for electric consumption of buildings”. In: *ASCI international workshop on computing in civil engineering*, v. 38, 2009.
- [19] BERGES, M. E., GOLDMAN, E., MATTHEWS, H. S., et al., “Enhancing electricity audits in residential buildings with nonintrusive load monitoring”, *Journal of industrial ecology*, v. 14, n. 5, pp. 844–858, 2010.
- [20] MURPHY, K. P., *Machine learning: a probabilistic perspective*. MIT press, 2012.
- [21] WEBB, G. I., “Multiboosting: A technique for combining boosting and wagging”, *Machine learning*, v. 40, n. 2, pp. 159–196, 2000.
- [22] LAI, Y.-X., LAI, C.-F., HUANG, Y.-M., et al., “Multi-appliance recognition system with hybrid SVM/GMM classifier in ubiquitous smart home”, *Information Sciences*, v. 230, pp. 39–55, 2013.
- [23] ZIA, T., BRUCKNER, D., ZAIDI, A., “A hidden markov model based procedure for identifying household electric loads”. In: *IECON 2011-37th Annual Conference on IEEE Industrial Electronics Society*, pp. 3218–3223, 2011.
- [24] RODRIGUES, P. C., “Principal Component Analysis of Dependent Data”, 2007.
- [25] HARRIS, T., YUAN, H., “Filtering and Frequency Interpretations of Singular Spectrum Analysis”, *Physica D: Nonlinear Phenomena*, v. 239, n. 20, pp. 1958–1967, 2010.
- [26] BISHOP, C. M., “Pattern Recognition”, *Machine Learning*, 2006.
- [27] DA SILVA JÚNIOR, W. S., *Reconhecimento de Padrões Utilizando Filtros de Correlação com Análise de Componentes Principais*, Ph.D. Thesis, Universidade Federal do Rio de Janeiro, 2010.

- [28] SHLENS, J., “A tutorial on principal component analysis”, *arXiv preprint arXiv:1404.1100*, 2014.
- [29] ALEXANDROV, T., “A Method of Trend Extraction Using Singular Spectrum Analysis”, *arXiv preprint arXiv:0804.3367*, 2008.
- [30] SILVA, C. R. D. S., *Recuperação de sinais esparsos. Investigação numérica sobre a quantidade de medidas necessárias para recuperar um sinal esperso*, Master’s Thesis, 2012.
- [31] MATLAB, *version 7.10.0 (R2010a)*. The MathWorks Inc.: Natick, Massachusetts, 2010.
- [32] KOHAVI, R., OTHERS, “A study of cross-validation and bootstrap for accuracy estimation and model selection”. In: *International Joint Conference on Artificial Intelligence (IJCAI)*, v. 14, n. 2, pp. 1137–1145, 1995.
- [33] LIMA DE MENEZES, M., CASTRO SOUZA, R., MOREIRA PESSANHA, J. F., “Electricity consumption forecasting using singular spectrum analysis”, *Dyna*, v. 82, n. 190, pp. 138–146, 2015.
- [34] HASSANI, H., “A Brief Introduction to Singular Spectrum Analysis”, 2010.

# Apêndice A

## Algoritmo Dissimilarity-based Sparse Subset Selection (DS3)

A seguir, apresentamos o algoritmo Dissimilarity-based Sparse Subset Selection (DS3) [14].

---

**Algoritmo 9** *Algoritmo* Dissimilarity-based Sparse Subset Selection (*DS3*)

---

**Entrada:**  $\alpha = 10^{-1}$ ,  $\epsilon = 10^{-7}$ ,  $\text{maxIter} = 10^5$

**Saída:** Solução ótima  $\mathbf{Z}^* = \mathbf{Z}^{(k)}$

- 1:  $k \leftarrow 0$ ,  $\mathbf{Z}^{(0)} \leftarrow \mathbf{I}$ ,  $\mathbf{C}^{(0)} \leftarrow \mathbf{I}$ ,  $\mathbf{\Gamma}^{(0)} \leftarrow \mathbf{0}$ ,  $\text{error1} = 2\epsilon$ ,  $\text{error2} = 2\epsilon$
  - 2: **enquanto** ( $\text{error1} > \epsilon$  **ou**  $\text{error2} > \epsilon$ ) **e** ( $k < \text{maxIter}$ ) **faça**
  - 3:  $\mathbf{Z}^{(k+1)} = \underset{\mathbf{Z}}{\text{argmin}} \frac{\gamma}{\alpha} \|\mathbf{Z}\|_{1,p} + \frac{1}{2} \|\mathbf{Z} - \left( \mathbf{C}^{(k)} - \frac{\mathbf{\Gamma}^{(k)}}{\alpha} \right)\|_F^2$
  - 4:  $\mathbf{C}^{(k+1)} = \underset{\mathbf{C}}{\text{argmin}} \|\mathbf{C} - \left( \mathbf{Z}^{(k+1)} + \frac{\mathbf{\Gamma}^{(k)} + \mathbf{D}}{\alpha} \right)\|_F^2$
  - 5: **dado** :  $\mathbf{1}^T \mathbf{C} = \mathbf{1}^T$ ,  $\mathbf{C} \geq \mathbf{0}$
  - 6:  $\mathbf{\Gamma}^{(k+1)} = \mathbf{\Gamma}^{(k)} + \alpha(\mathbf{Z}^{(k+1)} - \mathbf{C}^{(k+1)})$
  - 7:  $\text{error1} = \|\mathbf{Z}^{(k+1)} - \mathbf{C}^{(k+1)}\|_\infty$
  - 8:  $\text{error2} = \|\mathbf{Z}^{(k+1)} - \mathbf{Z}^{(k)}\|_\infty$
  - 9:  $k \leftarrow k + 1$
-