

UNIVERSIDADE FEDERAL FLUMINENSE

JULIO CESAR FERREIRA

**UM ESTUDO SOBRE AS TRANSFORMADAS DE
GABOR SINTONIZADAS: APLICAÇÃO A
SISTEMAS ELÉTRICOS DE POTÊNCIA**

NITERÓI

2018

UNIVERSIDADE FEDERAL FLUMINENSE

JULIO CESAR FERREIRA

**UM ESTUDO SOBRE AS TRANSFORMADAS DE
GABOR SINTONIZADAS: APLICAÇÃO A
SISTEMAS ELÉTRICOS DE POTÊNCIA**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Computação da Universidade Federal Fluminense como requisito parcial para a obtenção do Grau de Doutor em Computação. Área de concentração: Computação Visual

Orientador:

Prof. Dr. JOSÉ RICARDO DE ALMEIDA TORREÃO

NITERÓI

2018

Ficha catalográfica automática - SDC/BEE

F383e Ferreira, Julio Cesar
UM ESTUDO SOBRE AS TRANSFORMADAS DE GABOR SINTONIZADAS:
APLICAÇÃO A SISTEMAS ELÉTRICOS DE POTÊNCIA / Julio Cesar
Ferreira ; José Ricardo de Almeida Torreão, orientador.
Niterói, 2018.
175 f. : il.

Tese (doutorado)-Universidade Federal Fluminense, Niterói,
2018.

1. Transformada de Gabor Sintonizada. 2. Análise Tempo-
Frequência. 3. Sistemas Elétricos de Potência. 4.
Classificação de Distúrbios. 5. Produção intelectual. I.
Título II. Torreão, José Ricardo de Almeida , orientador.
III. Universidade Federal Fluminense. Escola de Engenharia.

CDD -

JULIO CESAR FERREIRA

UM ESTUDO SOBRE AS TRANSFORMADAS DE GABOR SINTONIZADAS:
APLICAÇÃO A SISTEMAS ELÉTRICOS DE POTÊNCIA

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Computação da Universidade Federal Fluminense como requisito parcial para a obtenção do Grau de Doutor em Computação. Área de concentração: Computação Visual

Aprovada em Junho de 2018.

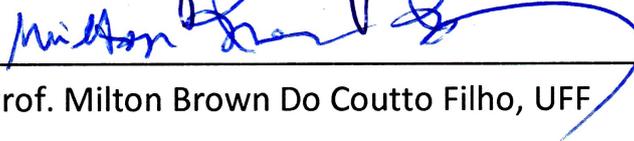
BANCA EXAMINADORA



Prof. José Ricardo de A. Torreão, UFF – Presidente



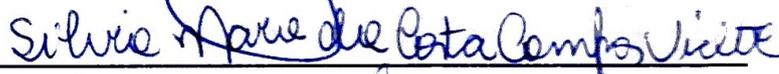
Prof. Julio Cesar Stacchini de Souza, UFF



Prof. Milton Brown Do Coutto Filho, UFF



Prof.^a Tatiana Mariano Lessa de Assis, UFRJ



Prof.^a Silvia Mara da Costa Campos Victer, UERJ



Prof. Roberto Marcondes César Júnior, USP

Niterói

2018

Dedico este trabalho a minha amada esposa Roseli, meus lindos e valentes filhos Atos Dã e Judi Vitória, que nos momentos de ausência em virtude dos estudos sempre me apoiaram com sublime compreensão.

Agradecimentos

Primeiramente a Deus, por ter me proporcionado a satisfação e disponibilidade para a realização desta tese, pelas bênçãos diárias e por Jesus Cristo em minha Vida.

Aos meus pais, Bárbara de Fátima Ferreira e Iraci José Ferreira deixo um agradecimento especial, pelo apoio, incentivo, educação, amor e também por sonhar comigo. Sinto-me privilegiado por ter vocês.

À minha amada esposa Roseli da Costa Teixeira e Ferreira, pelo amor, confiança e motivação, pois abriu mão de seus interesses e sonhos para me apoiar.

À minha sogra Sra. Maria Conceição da Costa Teixeira, pessoa simplesmente admirável.

À todos meus familiares da geração dos meus saudosos avós *Sr. Amador e Sra. Margarida*, que indiretamente contribuíram para esta vitória.

Aos irmãos em Cristo da Igreja Metodista Wesleyana de Uberaba, pelas orações e incentivo.

Ao IFTM e ao IC-UFF pela oportunidade do DINTER. Aos meus colegas do IFTM, companheiros do DINTER pela parceria contante, representando a todos cito: Alexandre Ribeiro, Claiton Luiz, Eduardo Silvestre e Hugo Rufino.

Agradeço aos membros desta banca examinadora, pela disponibilidade de participar e pelas contribuições pessoais acerca da Tese.

À professora Silvia Victor, pelo incentivo, apoio, colaboração, correções e implementações, muito obrigado.

Em especial ao professor, José Ricardo de Almeida Torreão, créditos de confiança pois me acolheu como orientando, pelos desafios propostos e pela orientação segura, orientador impar o qual ficarei eternamente grato, muitíssimo obrigado.

Por fim sou grato a todos que acreditaram e contribuíram de alguma forma para este trabalho.

Resumo

As abordagens *tempo-frequência* são ferramentas fundamentais para a representação e a análise de sinais com conteúdo espectral variável no tempo, as mais tradicionais dentre elas sendo a transformada de Gabor, a transformada de Wigner e a transformada S . As *transformadas de Gabor sintonizadas* (Signal-Tuned Gabor Transforms - STGT) são uma abordagem recente que incorpora aspectos das três anteriores, e que apresenta a característica de analisar cada sinal por meio de funções de representação do próprio sinal. A STGT foi originalmente introduzida em duas versões – uma no domínio temporal, e outra no domínio espectral –, mas extensões e generalizações já foram propostas, permitindo, por exemplo, a análise de um sinal pelas funções de representação das suas derivadas em qualquer ordem. Aqui nós reportamos os resultados de um estudo sobre a abordagem de Gabor sintonizada em suas múltiplas versões, focando numa área de aplicação específica: a análise de distúrbios em sistemas elétricos de potência (SEP). O nosso trabalho investigou o desempenho da abordagem sintonizada em tarefas de identificação e classificação de distúrbios dos SEP, considerando, para efeito comparativo, também as transformadas de Gabor, S e de Wigner. Bancos de sinais sintéticos e reais foram empregados nesse estudo, assim como diferentes estratégias de classificação, entre elas as Redes Neurais Artificiais, as Máquinas de Vetor de Suporte e as Árvores de Decisão. A nossa análise indica que, de modo geral, a abordagem sintonizada fornece representações tempo-frequência de melhor qualidade, e alcança taxas de classificação mais elevadas do que aquelas fornecidas pelas transformadas tradicionais, destacando-se a STGT espectral e as variantes baseadas na representação da primeira derivada do sinal. Uma aproximação da STGT aqui introduzida, a $STGT_{\omega_0}$, também pode se mostrar vantajosa em aplicações a sistemas de potência.

Palavras-chave: Análise Tempo-Frequência. Transformada de Gabor Sintonizada. Sistemas Elétricos de Potência. Classificação de Distúrbios.

Abstract

Time-frequency approaches have become essential tools for the representation and analysis of signals with variable spectral content, the Gabor, Wigner, and S transforms figuring among the most common of them. The signal-tuned Gabor transforms (STGT) constitute a new approach which incorporates aspects of those three transforms, and whose characteristic feature is that of analyzing a given signal by means of its own representation functions. The STGT was originally introduced under two guises – a temporal one, and a spectral one –, but extensions and generalizations of the approach have already been proposed, for instance allowing the analysis of a signal by means of the representation functions of its derivatives of any order. Here we report on the results of a study of the signal-tuned Gabor approach in its several versions, focusing on a specific application domain: the analysis of disturbances in electric power systems (EPS). Our work has investigated the performance of the signal-tuned approach in the identification and classification of EPS disturbances, also considering, for comparative purposes, the Gabor, Wigner, and S transforms. Databases of synthetic and real signals have been employed in this study, as well as different classification strategies, such as Artificial Neural Networks, Support Vector Machines and Decision Trees. Our analysis indicates that, as a rule, the signal-tuned approach yields higher quality time-frequency representations, and reaches better classification rates than the traditional approaches, prominent among its versions appearing the spectral STGT and the variants based on the first-derivative representation functions. An approximation of the STGT which is introduced here – the STGT_{ω_0} – may also prove advantageous for power systems applications.

Keywords: Time-Frequency Analysis. Signal-Tuned Gabor Transform. Electric Power Systems. Disturbance Classification.

Lista de Figuras

1.1	Plano TF para FrFT: rotação dos eixos pelo ângulo $\alpha = a\pi/2$ [91].	6
1.2	Porcentagem de utilização dos tipos de Transformadas TF.	8
1.3	Porcentagem de utilização dos tipos de classificadores.	9
2.1	Ilustrando a Aplicação da STGT $_{\omega_0}$ a um sinal com distúrbio do tipo <i>Spikes</i>	20
2.2	Aplicação da FrSTGT em um sinal de Chirp.	23
2.3	Comparação Espectral Sinal I_1	25
2.4	Comparação Espectral Sinal I_1	26
2.5	Comparação Espectral Sinal I_2	27
2.6	Comparação Espectral Sinal I_2	28
2.7	Comparação Espectral Sinal I_3	29
2.8	Comparação Espectral Sinal I_3	30
2.9	Comparação Espectral Sinal I_4	31
2.10	Comparação Espectral Sinal I_4	32
2.11	Comparação Espectral Sinal I_5	33
2.12	Comparação Espectral Sinal I_5	34
2.13	Comparação Espectral Sinal I_6	35
2.14	Comparação Espectral Sinal I_6	36
3.1	Distúrbios que afetam a amplitude do sinal	40
3.2	Distúrbios que afetam a frequência do sinal	41
3.3	Representação da Metodologia de Classificação utilizada.	44
3.4	Estrutura neurônio biológico - neurônio Artificial.	46
3.5	Estrutura Rede MLP.	46

3.6	Representação do mapeamento para o espaço característico e a separação de dados através de um hiperplano.	47
3.7	Representação de um hiperplano de separação	48
3.8	Representação SVM.	49
3.9	Representação de uma Árvore de Decisão.	51
3.10	Etapas de classificação com WEKA.	55
4.1	Nível de Classificação dos Distúrbios Sintéticos.	61
4.2	Desempenho das Transformadas na Classificação dos Distúrbios Sintéticos .	61
4.3	Aplicação das Transformadas a um Distúrbio Sintético tipo Sag.	64
4.4	Aplicação das Transformadas a um Distúrbio Sintético tipo Swell.	65
4.5	Aplicação das Transformadas a um Distúrbio Sintético tipo Interrupt. . . .	66
4.6	Aplicação das Transformadas a um Distúrbio Sintético tipo Harmônico. . .	67
4.7	Aplicação das Transformadas a um Distúrbio Sintético tipo Transiente. . .	68
4.8	Aplicação das Transformadas a um Distúrbio Sintético tipo Spikes.	69
4.9	Aplicação das Transformadas a um Distúrbio Sintético tipo Notches	70
4.10	Aplicação das Transformadas a um Distúrbio Sintético tipo Sag+Harmônico.	71
4.11	Aplicação das Transformadas a um Distúrbio Sintético tipo Swell+Harmônico.	72
4.12	Aplicação das Transformadas a um Distúrbio Sintético tipo Interrupt + Harmônico.	73
4.13	Nível de Classificação dos Distúrbios Analisados - IEEE e PSCOPE	77
4.14	Desempenho das Transformadas na Classificação dos Distúrbios - IEEE e PSCOPE.	77
4.15	Aplicação das Transformadas a um Distúrbio tipo Sag - IEEE e PSCOPE.	78
4.16	Aplicação das Transformadas a um Distúrbio tipo Sag+Harmônico - IEEE e PSCOPE.	79
4.17	Aplicação das Transformadas em um distúrbio tipo Transiente - IEEE e PSCOPE	80
4.18	Nível de Classificação dos Distúrbios Analisados - Lab. do IFTM.	83

4.19	Desempenho das Transformadas na Classificação dos Distúrbios - Lab. do IFTM.	83
4.20	Aplicação das Transformadas a um Distúrbio tipo Transiente criado no Laboratório do IFTM.	84
4.21	Aplicação das Transformadas a um Distúrbio tipo Transiente criado no Laboratório do IFTM.	85
4.22	Aplicação das Transformadas a um Distúrbio tipo Spike criado no Laboratório do IFTM.	86
4.23	Desempenho das TF:Classificação Geral	88
4.24	Sistema Híbrido de Geração Distribuída.	89
4.25	VTCD devido a um curto-circuito. Aplicação das Transformadas TF no sinal de Tensão para detecção do distúrbio.	90
4.26	VTCD devido a uma rejeição de carga. Aplicação das Transformadas TF ao sinal de tensão para detecção do distúrbio.	91
5.1	Aplicação da $STGT_{log}$ ao Sinal I_1 da Eq. (2.53).	97
5.2	Aplicação da $STGT_{log}$ a um Sinal Elétrico sob Distúrbio Sintético do Tipo Interrupt+Harmônicos (10 dB).	98
B.1	Aplicação das Transformadas a um Distúrbio tipo Sag - IEEE e PSCOPE.	107
B.2	Aplicação das Transformadas a um Distúrbio tipo Swell - IEEE e PSCOPE.	108
B.3	Aplicação das Transformadas a um Distúrbio tipo Harmônico - IEEE e PSCOPE.	109
B.4	Aplicação das Transformadas a um Distúrbio tipo Spikes - IEEE e PSCOPE.	110
B.5	Aplicação das Transformadas a um Distúrbio tipo Swell+Harmônico - IEEE e PSCOPE.	111
B.6	Aplicação das Transformadas a um Distúrbio tipo Sag+Harmônico - IEEE e PSCOPE.	112
B.7	Aplicação das Transformadas a um Distúrbio tipo Interrupt- IFTM	113
B.8	Aplicação das Transformadas a um Distúrbio tipo Notches - IFTM	114
B.9	Aplicação das Transformadas a um Distúrbio tipo Swell - IFTM	115

B.10	Aplicação das Transformadas a um Distúrbio tipo Transient - IFTM	116
B.11	Aplicação das Transformadas a um Distúrbio tipo Harmônico - IFTM	117
B.12	Aplicação das Transformadas a um Distúrbio tipo Interrupt+Harmônico - IFTM	118
B.13	(a) Sinal sem ruído com distúrbio tipo <i>Sag</i> , (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT ₂ , (e) Espectrograma ST.	122
B.14	(a) Sinal sem ruído com distúrbio tipo <i>Swell</i> , (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT ₂ , (e) Espectrograma ST.	123
B.15	(a) Sinal sem ruído com distúrbio tipo <i>Interrupt</i> , (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT ₂ , (e) Espectrograma ST.	124
B.16	(a) Sinal sem ruído com distúrbio tipo <i>Harmonics</i> , (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT ₂ , (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).	125
B.17	(a) Sinal sem ruído com distúrbio tipo <i>Transient</i> , (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT ₂ , (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).	126
B.18	(a) Sinal sem ruído com distúrbio tipo <i>Notches</i> , (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT ₂ , (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).	127
B.19	(a) Sinal sem ruído com distúrbio tipo <i>Spikes</i> , (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT ₂ , (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).	128
B.20	(a) Sinal com ruído (20db) com distúrbio tipo <i>Sag</i> , (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT ₂ , (e) Espectrograma ST.	129
B.21	(a) Sinal com ruído (20db) com distúrbio tipo <i>Swell</i> , (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT ₂ , (e) Espectro- grama ST.	130

B.22	(a) Sinal com ruído (20db) com distúrbio tipo <i>Interrupt</i> , (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT ₂ , (e) Espectrograma ST.	131
B.23	(a) Sinal com ruído (20db) com distúrbio tipo <i>Harmonics</i> , (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT ₂ , (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).	132
B.24	(a) Sinal com ruído (20db) com distúrbio tipo <i>Transient</i> , (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT ₂ , (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).	133
B.25	(a) Sinal com ruído (20db) com distúrbio tipo <i>Notches</i> , (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT ₂ , (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).	134
B.26	(a) Sinal com ruído (20db) com distúrbio tipo <i>Spikes</i> , (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT ₂ , (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).	135
C.1	Sistema de Geração Distribuída - Área 01	137
C.2	Sistema de Geração Distribuída - Área 02	138
C.3	Sistema de Geração Distribuída - Área 03	139
C.4	Sistema de Geração Distribuída - Área 04	140
C.5	Sistema de Geração Distribuída - Área 05	141

Lista de Tabelas

3.1	Atributos	54
4.1	Desempenho das Transformadas na Classificação dos Distúrbios - 10dB. . .	60
4.2	Classificação de Distúrbios de sinais Sintéticos	62
4.3	Classificação de Distúrbios - IEEE e PSCOPE	76
4.4	Classificação de Distúrbios - Lab. do IFTM.	82
4.5	Métricas estatísticas dos classificadores	88
A.1	Aplicação das Transformadas TF a Sistemas Elétricos	100
A.2	Aplicação das TF em Sistemas Elétricos	101
A.3	Aplicação das TF em Sistemas Elétricos	102
A.4	Aplicação das TF em Sistemas Elétricos	103
A.5	Aplicação das TF em Sistemas Elétricos	104
A.6	Aplicação das TF em Sistemas Elétricos	105
B.1	Classificação - Sinais com 20db	120
B.2	Classificação - Sinais com 30db	120
B.3	Classificação - Sinais com 40db	120
B.4	2 ^a Classificação - Sinais com 20db	121
B.5	2 ^a Classificação - Sinais com 30db	121
B.6	2 ^a Classificação - Sinais com 40db	121

Lista de Abreviaturas e Siglas

AM	: Amplitude Modulation
ANN	: Artificial Neural Network
BFSK	: Binary Frequency-Shift Keying
BPSK	: Binary Phase-Shift Keying
CBQEE	: Conferência Brasileira sobre Qualidade da Energia Elétrica
CI	: Inteligência Computacional
DG	: Geração Distribuída
DSP	: Processamento Digital de Sinais
DT	: Decision Tree
ECG	: Eletrocardiograma
EEG	: Eletroencefalográfico
FM	: Frequency Modulation
AFT	: Fourier Transform
FrFT	: Transformada Fracionária de Fourier
FrSTGT	: Transformada Sintonizada Fracionária
FrWT	: Fractional Wavelet Transform
GT	: Transformada de Gabor
HHT	: Hilbert-Huang Transform
ICHQP	: International Conference on Harmonics and Quality of Power
IC-UFF	: Instituto de Computação da Universidade Federal Fluminense
IEEE	: Instituto de Engenheiros Eletricistas e Eletrônicos
IFTM	: Instituto Federal do Triângulo Mineiro
MLP	: Multi-Layer Perceptron
MST	: Modified <i>S</i> -Transform

PNN	:	Probabilistic Neural Network
PSCOPE	:	Signal Processing Computational Intelligence Systems Power
PWVD	:	Pseudo Wigner-Ville Distribution
QAM	:	Quadrature Amplitude Modulation
QEE	:	Qualidade de Energia Eletrica
QPSK	:	Quadrature Phase Shift Keying
RF	:	Radial Basis Function
SEP	:	Sistemas Elétricos de Potência
SNR	:	Relação Sinal Ruído
SPWVD	:	Smoothed Pseudo Wigner-Ville Distribution
ST	:	Transformada S - Stockwell
STFT	:	Short Time Fourier Transform
STGT	:	Signal-Tuned Gabor Transform
STGT $_{\omega_0}$:	Transformadas Sintonizadas na Frequência ω_0
STGT $_2$:	Segunda forma da Signal-Tuned Gabor Transform
STGT $_2$ -Her	:	Segunda forma da Signal-Tuned Gabor Transform com Funções de Hermite
STGT-Her	:	Signal-Tuned Gabor Transform com Funções de Hermite
SVM	:	Support Vector Machine
TF	:	Tempo-Frequência
TG	:	Transformada de Gabor
TS	:	Transformada de Stockwell
TTT	:	Time-Time Transform
UFJF	:	Universidade Federal de Juiz de Fora
VTCD	:	Variações de Tensão de Curta Duração
WEKA	:	Waikato Environment for Knowledge Analysis
WT	:	Wavelet Transform
WVD	:	Wigner Ville Distribution

Sumário

1	Introdução Geral	1
1.1	Considerações Iniciais	1
1.2	Contribuições	2
1.3	Estrutura da Tese	2
1.4	Revisão Bibliográfica	3
1.4.1	Transformadas Tempo-Frequência	3
1.4.2	Utilização das Transformadas Tempo-Frequência em Sistemas Elé- tricos de Potência	6
1.5	Considerações Finais	9
2	Aspectos Gerais das Transformadas Tempo-Frequência	10
2.1	Considerações Iniciais	10
2.2	Transformadas Tempo-Frequência	10
2.3	Abordagem Sintonizada de Gabor	12
2.3.1	Segunda Forma da Transformada de Gabor Sintonizada	14
2.4	Extensões da Abordagem de Gabor Sintonizada	15
2.4.1	Introduzindo os Polinômios de Hermite	15
2.4.1.1	Funções Sintonizadas da Primeira Forma	15
2.4.1.2	Funções Sintonizadas da Segunda Forma	17
2.4.2	Transformadas Sintonizadas Generalizadas	18
2.4.3	Transformadas Sintonizadas na Frequência ω_0	18
2.4.4	Transformada Sintonizada Fracionária - FrSTGT	20

2.5	Análise Comparativa das Transformadas TF	23
2.6	Considerações Finais	36
3	Sobre os Distúrbios dos SEP e os Classificadores	38
3.1	Considerações Iniciais	38
3.2	Tipos de Distúrbios dos SEP	39
3.2.1	Distúrbios da Amplitude do Sinal: <i>Sags</i> , <i>Swells</i> e <i>Interrupts</i>	39
3.2.2	Distúrbios da Forma de Onda do Sinal: <i>Harmonics</i> , <i>Transients</i> , <i>Spikes</i> e <i>Notches</i>	40
3.2.3	Distúrbios: Causas, Efeitos e Soluções	41
3.3	Classificação dos Distúrbios	43
3.3.1	Classificação por Redes Neurais Artificiais	44
3.3.2	Classificação por <i>Support Vector Machines</i>	46
3.3.3	Classificação por Arvore de Decisão - Decision Tree	51
3.3.4	Seleção dos Atributos para Classificação	53
3.3.5	Software de Classificação - WEKA	54
3.4	Classificação por Similaridade	55
3.5	Considerações Finais	56
4	Aplicação das Transformadas Sintonizadas à Análise de Distúrbios nos SEP	58
4.1	Considerações Iniciais	58
4.2	Sinais Gerados com o MATLAB	58
4.2.1	Análise dos Espectrogramas	63
4.3	Sinais Experimentais IEEE e PSCOPE	75
4.4	Sinais de Laboratório	81
4.5	Classificação Geral	87
4.6	Análise de Variações de Tensão de Curta Duração (VTCD)	88
4.6.1	Simulação 1: VTCD devida a um Curto-Circuito	89

4.6.2	Simulação 2: VTCD devida a uma Rejeição de Carga	90
4.7	Considerações Finais	91
5	Conclusões e Trabalhos Futuros	92
5.1	Conclusões	92
5.1.1	Artigos Publicados	95
5.2	Trabalhos Futuros	95
	Apêndice A - Pesquisa Bibliográfica	99
	Apêndice B - Outros Resultados	106
B.1	Sinais Experimentais IEEE e PSCOPE	107
B.2	Sinais Experimentais Laboratório IFTM	113
B.3	Resultados Experimentais Sintéticos	119
	Apêndice C - Modelo de simulação de um SEP	136
	Referências	142

Capítulo 1

Introdução Geral

1.1 Considerações Iniciais

As abordagens *tempo-frequência* e *tempo-escala* são ferramentas fundamentais para a representação e a análise de sinais com conteúdo em frequência variável no tempo. Entre as primeiras, o exemplo mais conhecido é a *transformada de Gabor*, enquanto as últimas abrangem diversas variantes da transformada *wavelet* [21][153]. Por outro lado, a chamada *transformada S* se distingue por ser uma abordagem que busca aliar vantagens específicas das duas anteriores [9][33], enquanto uma abordagem mais recente, a *transformada de Gabor sintonizada* (Signal-Tuned Gabor Transform - STGT), incorpora aspectos tanto das transformadas *S* e de Gabor, como da *transformada de Wigner* ou *Wigner-Ville*, que comprovadamente apresenta propriedades analíticas ideais para uma análise tempo-frequência [4][39][143]. A STGT foi originalmente introduzida em duas versões – uma para a análise de sinais definidos no domínio temporal, e outra para a análise de sinais definidos no domínio da frequência, cada uma delas apresentando distintas características. Recentemente, uma generalização da STGT foi proposta, incorporando as duas versões originais como casos particulares [162], e uma modificação da STGT, capaz de generalizar todas as versões anteriores, foi também introduzida e apresentada em [7].

O objetivo do trabalho reportado aqui foi o de efetuar um estudo sobre a abordagem de Gabor sintonizada em suas múltiplas versões, focando numa área de aplicação específica: a análise de distúrbios em sistemas elétricos de potência (SEP), uma área que vem recebendo crescente atenção, hoje em dia, devido à sua importância para a manutenção da qualidade da energia elétrica (QEE). Visando contemplar este objetivo geral, os seguintes pontos específicos foram abordados:

- Levantamento bibliográfico, para servir como referencial teórico, buscando-se conteúdo específico sobre transformadas tempo-frequência e classificação de distúrbios em SEP.
- Formulação matemática e implementação computacional da abordagem sintonizada de Gabor, em suas múltiplas versões.
- Geração de um banco de dados com sinais elétricos, sintéticos e reais, corrompidos por diferentes tipos e níveis de distúrbio.
- Aplicação da abordagem sintonizada de Gabor na classificação de distúrbios dos sinais elétricos; comparação com as abordagens tradicionais: Gabor, S , e Wigner.

1.2 Contribuições

O trabalho aqui reportado dá sequência à série de estudos que vêm sendo realizados no Instituto de Computação da Universidade Federal Fluminense (IC-UFF), desde 2012, sobre a abordagem de Gabor sintonizada enquanto ferramenta de uso geral para a análise de sinais. Além do emprego das versões originais da abordagem [51] [52] [172] no campo específico da análise de distúrbios em sistemas de potência, a presente Tese traz, como contribuições inéditas, a primeira avaliação sistemática das generalizações da transformada de Gabor sintonizada recentemente introduzidas em [162] e [7], e a introdução de uma variante da STGT temporal que pode ser vantajosa para análise de sinais elétricos. Resumidamente, é possível destacar aqui que, considerando as suas diversas versões, a abordagem sintonizada foi capaz de demonstrar melhor resolução simultânea tempo-frequência, maior imunidade a ruídos, e maior sensibilidade a variações bruscas nos sinais analisados do que as abordagens tradicionais consideradas (Gabor, S , Wigner).

Além disso, vale mencionar que o levantamento bibliográfico realizado no decorrer da nossa pesquisa (ver abaixo), originando um banco de dados sobre as principais métodos TF e abordagens de classificação empregados na análise de distúrbios em sistemas de potência, pode se tornar uma ferramenta relevante para futuros pesquisadores.

1.3 Estrutura da Tese

Esta Tese está organizada em cinco Capítulos e três Apêndices, sendo este capítulo inicial dedicado a uma introdução teórica sobre o tema da pesquisa realizada, e à apre-

sentação dos seus objetivos e resultados.

O Capítulo 2 abrange a descrição teórica e a formulação matemática da abordagem sintonizada de Gabor, e também das tradicionais transformadas de Gabor, S , e Wigner.

O Capítulo 3 apresenta a descrição dos classificadores utilizados e também a metodologia destes para a classificação de distúrbios nos SEP.

O Capítulo 4 apresenta e discute os resultados da aplicação da abordagem sintonizada de Gabor ao problema da análise e classificação de distúrbios nos SEP.

O Capítulo 5 encerra a Tese com a apresentação das conclusões gerais do nosso trabalho e a sugestão de linhas para o seu desenvolvimento futuro.

O Apêndice A traz os resultados detalhados do levantamento bibliográfico realizado sobre a aplicação das abordagens tempo-frequência a sistemas de potência.

O Apêndice B traz resultados adicionais do nosso estudo, não apresentados no Capítulo 3.

O Apêndice C traz um Modelo de simulação de um Sistema Elétrico de Potência utilizado para geração de alguns dos sinais considerados no Capítulo 4.

1.4 Revisão Bibliográfica

Nesta seção, nós apresentamos uma revisão bibliográfica sobre as principais *transformadas tempo-frequência* (TF) e sua aplicação a *sistemas elétricos de potência* (SEP), em particular no que se refere à análise da *qualidade da energia elétrica* (QEE). Neste momento, nós nos restringimos a uma apresentação meramente discursiva do material, reservando os detalhes matemáticos relevantes para capítulos subsequentes. Um levantamento bibliográfico específico foi realizado com o objetivo de quantificar o emprego das transformadas TF no contexto do tema da Tese.

1.4.1 Transformadas Tempo-Frequência

A análise de Fourier convencional, introduzida por Jean-Baptiste Joseph Fourier em 1807, é uma ferramenta matemática que efetua a decomposição de um sinal temporal em suas componentes de frequência: em termos simplificados, obtêm-se por tal meio os pesos das funções senoidais — i.e., senos e/ou co-senos de diferentes frequências — cuja combinação reconstituiria o sinal. No entanto, uma vez obtidas tais componentes, ditas *spectrais*, do

sinal analisado, o seu comportamento temporal é perdido — ou seja, a chamada *transformada de Fourier* (Fourier Transform - FT) não realiza uma análise tempo-frequência do sinal de interesse [26]. Para sinais estacionários (aqueles cujas propriedades não variam com o tempo) isto não constitui problema, mas muitos sinais reais têm características não-estacionárias (como impulsos, ruídos, choques, curtos, vibrações, eventos esporádicos, transitórios, etc.), cuja análise eficiente requer a leitura simultânea, no plano da transformada, das propriedades temporais e espectrais do sinal. Uma maneira direta de se obter a localização temporal de cada componente espectral é calcular a FT em intervalos específicos de tempo, em vez de processar simultaneamente todo o sinal. Isto foi o que propôs Dennis Gabor em 1946, ao adaptar a FT de forma a analisar apenas uma parte do sinal no tempo, sendo esta a técnica conhecida como *janelamento*, que fornece um espectro de frequências representativo do conteúdo do sinal num dado intervalo de tempo. Mapeando-se desta forma todo o sinal, resulta uma função bidimensional do tempo e da frequência [53] [128]: a *transformada janelada de Fourier*, também conhecida como *transformada de Fourier de curta duração* (Short Time Fourier Transform - STFT).¹ O inconveniente da STFT relaciona-se à escolha do tipo geométrico da janela e à definição da sua largura, que é mantida a mesma para todas as frequências. Desta forma, o emprego de uma janela larga resulta num número maior de amostras e numa boa resolução no domínio da frequência, mas, por outro lado, acarreta uma baixa resolução no domínio do tempo. Por outro lado, o emprego de uma janela estreita tem o efeito oposto,² não sendo portanto possível a obtenção de uma boa resolução simultânea nos dois domínios — um contraponto que encontra a sua formulação matemática no chamado princípio da incerteza de Heisenberg [128]. Na prática, deve-se escolher empiricamente a função de janela (por exemplo, *retangular*, *Hanning*, *Hamming*, *Kaiser-Bessel*, *triangular*, *flattop*, *exponencial*) e ajustar os seus parâmetros, não sendo esta uma tarefa simples, pois cada função de janela tem as suas próprias características, que afetam de maneiras diversas a resolução da transformada [33].

As janelas Gaussianas — características da transformada de Gabor (TG) — são frequentemente utilizadas, pois com elas se obtém o valor mínimo da incerteza de Heisenberg. Na busca por um método de representação TF de excelência, Robert Dean Stockwell

¹Em particular, Gabor introduziu um conjunto de funções compostas por janelas Gaussianas moduladas por funções senoidais — as *funções de Gabor* —, de modo que, para cada janela, é calculada uma FT. Obtém-se assim a chamada *transformada de Gabor* - TG (ver o Cap. 2).

²Extrapolando, se a janela tiver uma largura infinita, isto resulta na máxima resolução em frequência, e possivelmente em nenhuma resolução temporal. Por outro lado, aplicando-se uma janela infinitesimalmente pequena, o resultado seria o máximo de resolução no tempo e nenhuma resolução espectral.

(1996) propôs a *transformada de Stockwell*, ou *transformada S* (TS).³ Esta transformada emprega uma janela Gaussiana cuja largura varia inversamente com a frequência, de modo que as componentes de alta frequência do sinal são exploradas com maior resolução temporal [154][143]. A TS proporcionou um avanço significativo na análise de sinais que requerem a detecção e localização de perturbações, mudanças bruscas, curtos, transientes e outros, o que a tornou uma ferramenta bastante difundida, que permanece objeto de contínuas extensões e aprimoramentos [9] [130].

Uma alternativa à análise TF baseada na função de Gabor baseia-se na *distribuição de Wigner-Ville* (Wigner Ville Distribution - WVD), inicialmente proposta no campo da mecânica quântica, e que posteriormente encontrou aplicação no contexto da análise de sinais [180] [39]. A WVD, também conhecida como *transformada de Wigner-Ville* ou simplesmente *transformada de Wigner*, emprega o próprio sinal como seu núcleo analisador, o que a torna uma transformada bilinear, ou quadrática. Ela apresenta uma série de propriedades significativas para o mapeamento TF, dentre as quais aqui destacamos duas: i) o mapeamento TF obtido com a WVD sempre será real, independentemente do sinal analisado; ii) a WVD apresenta a propriedade de *frequência instantânea*, isto é, a frequência média obtida com a WVD é igual à derivada da fase do sinal temporal.⁴ Contudo, por ser uma transformada quadrática, a WVD apresenta o problema dos *termos cruzados*, que consiste na introdução de frequências espúrias, que prejudicam a discriminação de sinais de múltiplas componentes. A estratégia comum para eliminar ou reduzir estes efeitos indesejáveis envolve a introdução de um filtro de suavização no núcleo da WVD. Este é o caso da PWVD (Pseudo Wigner-Ville Distribution) e da SPWVD (Smoothed Pseudo Wigner-Ville Distribution). Mesmo assim, ainda que obtendo melhores resoluções do que as transformadas lineares acima citadas, estas variantes da WVD continuam apresentando dificuldades para a sua interpretação visual [4][39][143].

Ainda no contexto das abordagens TF, deve-se mencionar a *transformada fracionária de Fourier* (FrFT), que é uma generalização da transformada de Fourier tradicional. A FrFT permite levar um sinal temporal para qualquer domínio intermediário entre o tempo e a frequência. Ela foi descoberta e redescoberta por vários autores, como Wiener (1929) [176] e Condon (1937) [40]. Em 1993, Mendlovic implementou a FrFT para aplicações em óptica, e Ozaktas [124] a utilizou para desenvolver o conceito de filtragem em domínios fracionários [91] [176]. Em 1994, Almeida [5] demonstrou que a FrFT pode ser interpretada

³A TS é tida como um método híbrido de análise de sinais, por combinar as vantagens da transformada de Gabor e da *transformada wavelet contínua* - TWC [33][9].

⁴Sob o ponto de vista da identificação de sinais, esta é a propriedade mais atraente da WVD [39].

como uma operação de rotação no plano TF, a ela se associando um parâmetro α , que define o ângulo de rotação naquele plano. Assim (vide Fig.1.1), o cálculo da FrFT de um sinal no domínio do tempo pode ser visto como uma rotação, no sentido anti-horário, por um ângulo $\alpha = a\pi/2$, sendo $a \in \mathfrak{R}$. Isso significa que, se o parâmetro a for não inteiro, o sinal é levado para um domínio intermediário que, do ponto de vista físico, representa algo entre o tempo e a frequência. Quando $a = 1$, por exemplo, a FrFT corresponde à transformada de Fourier tradicional. A presença deste parâmetro adicional dá grande flexibilidade à FrFT, ampliando significativamente o campo de aplicações da análise de Fourier [91].

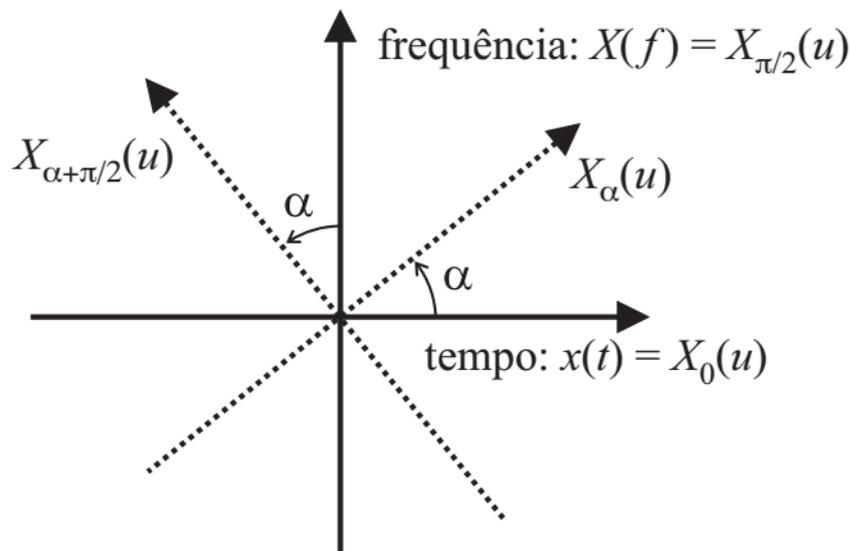


Figura 1.1: Plano TF para FrFT: rotação dos eixos pelo ângulo $\alpha = a\pi/2$ [91].

1.4.2 Utilização das Transformadas Tempo-Frequência em Sistemas Elétricos de Potência

A expressão *qualidade da energia elétrica* (QEE) se refere a uma ampla variedade de fenômenos eletromagnéticos que caracterizam a tensão e a corrente em um dado instante e em uma dada posição de um sistema elétrico. Diversas razões podem ser apontadas para o grande aumento no volume das pesquisas em QEE, por exemplo, equipamentos microprocessados utilizados nos SEP tendem a ser mais sensíveis aos distúrbios, e os processos por eles empregados são portanto menos tolerantes a falhas de operação. Assim, com a rápida disseminação de aplicações industriais que dependem de dispositivos eletrônicos sofisticados, a demanda por QEE e por confiabilidade tornou-se uma preocupação constante, já que mesmo uma redução momentânea na QEE pode acarretar falhas em equipamentos

e perda de dados, com o conseqüente comprometimento de receitas [72] [129]. Por outro lado, fatores diversos, como o advento de fontes renováveis de energia, e de sistemas geradores distribuídos, e mesmo o maior nível de conscientização dos consumidores, levaram a uma busca por meios mais eficientes de avaliação e controle da qualidade da energia.

Dentre a grande variedade de ferramentas disponíveis para o monitoramento da qualidade da energia elétrica, aquelas baseadas em técnicas de processamento e análise de sinais se têm mostrado particularmente bem-sucedidas, as abordagens TF (bem como as *tempo-escala*, ou *wavelets*) caracterizando-se como eminentemente adequadas para a análise de QEE, já que qualquer sistema de potência, em qualquer parte do mundo, fornece uma tensão senoidal padrão, cuja magnitude e frequência devem ser estritamente mantidas [120][156].

Visando contextualizar a aplicação das transformadas TF em sistemas elétricos de potência, e na área de qualidade da energia elétrica em particular, realizou-se um levantamento bibliográfico com base nos seguintes critérios para a seleção dos textos: i) Foram considerados apenas trabalhos publicados nos últimos dez anos; ii) A busca foi guiada pelas seguintes palavras-chave: *análise tempo-frequência*, *sistema elétrico de potência*, *distúrbios na qualidade da energia*; iii) Empregou-se uma base de dados consistente com o foco do estudo – especificamente, a "IEEE Explore Digital Library", do Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE), <http://ieeexplore.ieee.org>. As Tabelas A.1 a A.6, do Apêndice A, apresentam os resultados da pesquisa, destacando-se o tipo de transformada TF e também a técnica de classificação, e/ou exposição, dos dados obtidos.⁵ Para facilitar a apresentação, as seguintes abreviações são empregadas: Wavelet Transform (WT), Hilbert-Huang Transform (HHT), Modified S-Transform (MST), Fractional Fourier Transform (FrFT), Fractional Wavelet Transform (FrWT), Time-Time Transform (TTT); Artificial Neural Network (ANN), Support Vector Machine (SVM), Radial Basis Function (RF), Decision Tree (DT), Probabilistic Neural Network (PNN), Base Chupakhina base (Chupakhina). Os artigos que utilizaram as transformadas TF visando representação ou análise visual constam nas Tabelas na categoria Análise/Gráfico.

Com base na análise dos 162 artigos retornados por nossa busca, foram formatados os gráficos de barras nas Figs. 1.2 e 1.3, que nos permitem chegar às seguintes conclusões principais: i) As transformadas *S* e as *wavelets* (WT), seja separadamente ou em conjunto, aparecem em mais de 80% dos trabalhos levantados; ii) As abordagens de Support Vector

⁵As técnicas e/ou algoritmos de classificação são ferramentas que utilizam os dados fornecidos pelas transformadas TF visando diferenciar, de forma classificatória, os possíveis distúrbios nas formas de onda. O objetivo seria, então, o de combinar o melhor classificador com a transformada TF de melhor resolução tempo-frequência, visando à classificação mais precisa dos dados.

Machine e Artificial Neural Networks são as favoritas para a classificação de distúrbios, sendo contempladas em mais de 30% dos casos; iii) A maior parte dos artigos pesquisados (46,30%) utilizou a visualização do domínio TF para análise direta ou para a extração das características a serem utilizadas para efeito de classificação.

Além disso, é interessante observar que variantes das abordagens de *wavelets*, Gabor, *S* e Fourier fracionária são frequentemente contempladas nas referências levantadas. Por exemplo, a Modified *S*-Transform estende a transformada *S* pela introdução, na janela Gaussiana, de um parâmetro que permite controlar a resolução espectro-temporal, enquanto a Time-Time Transform pode ser obtida a partir da transformada de Fourier inversa da *S*. Por outro lado, a Fractional Wavelet Transform (FrWT) e também a transformada Curvelet combinam *wavelets* e Fourier fracionária, enquanto a Hilbert-Huang Transform é uma técnica tempo-escala semelhante à WT.

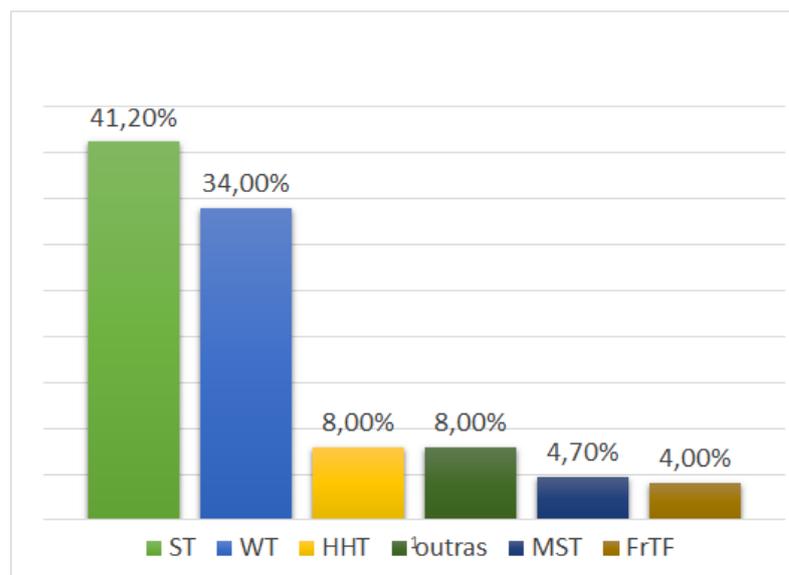


Figura 1.2: Percentagem de utilização dos tipos de Transformadas TF.

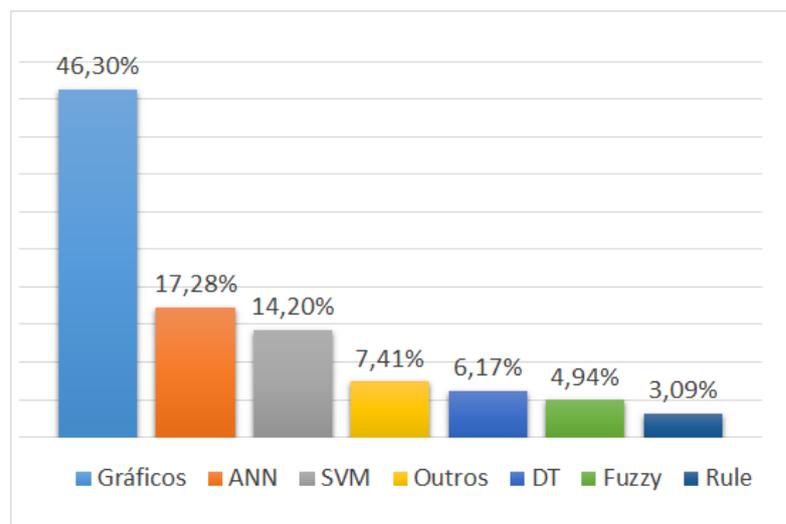


Figura 1.3: Percentagem de utilização dos tipos de classificadores.

1.5 Considerações Finais

Neste Capítulo, nós apresentamos uma descrição teórica das principais abordagens tempo-frequência empregadas na análise da qualidade da energia elétrica, em particular para a classificação de distúrbios na forma de onda do sinal de potência. O resultado de um levantamento bibliográfico das principais publicações aparecidas recentemente nesta área – em que ganham destaque as transformadas S , *wavelets*, de Gabor e Fourier Fracionária –, foi também apresentado. Na sequência, nós iremos tratar de uma abordagem alternativa para a análise tempo-frequência que, em suas várias versões, guarda semelhanças com as abordagens mencionadas, e que já se provou mais efetiva do que estas em contextos específicos da análise de sinais: a abordagem de Gabor sintonizada. Conforme veremos, também na aplicação à análise de distúrbios em sistemas elétricos, a STGT se mostra uma abordagem competitiva e muitas vezes vantajosa.

A nossa apresentação prossegue, no Capítulo 2, com a descrição teórica e a formulação matemática da abordagem sintonizada, e também das tradicionais transformadas tempo-frequência consideradas aqui.

Capítulo 2

Aspectos Gerais das Transformadas Tempo-Frequência

2.1 Considerações Iniciais

Neste Capítulo, nós apresentamos a formulação matemática de três abordagens tempo-frequência tradicionais – as transformadas de Gabor, S , e de Wigner –, e também da abordagem sintonizada de Gabor em suas versões temporal e espectral – a STGT e a STGT₂. Serão consideradas ainda duas propostas de extensão da abordagem sintonizada, uma baseada na incorporação dos polinômios de Hermite às funções analisadoras, e uma baseada na transformada de Fourier fracionária como generalização da transformada de Fourier tradicional. Uma variante da STGT que pode ser útil em aplicações a sistemas de potência será também introduzida.

Visando salientar as características principais da abordagem sintonizada, comparativamente às das abordagens tradicionais, a análise visual das diversas representações tempo-frequência (espectrogramas) obtidas para diferentes classes de sinais será apresentada.

2.2 Transformadas Tempo-Frequência

As abordagens tempo-frequência (TF) são uma ferramenta padrão para a análise de sinais cujas componentes em frequência variam com o tempo, sendo a transformada de Gabor (GT), a transformada S (ST) e a transformada de Wigner (WVD) algumas das técnicas TF mais comumente empregadas. No que se segue, nós apresentaremos uma descrição matemática de tais transformadas.

A transformada de Gabor é um caso particular da transformada janelada de Fourier – ou transformada de Fourier de tempo curto (STFT, do inglês *short-time Fourier transform*) –, em que a janela é uma Gaussiana. Dado um sinal $x(t)$, a sua GT é obtida como

$$G(t, \omega) = \int_{-\infty}^{+\infty} e^{-i\omega\tau} e^{-\frac{(\tau-t)^2}{2\sigma^2}} x(\tau) d\tau \quad (2.1)$$

onde σ , a largura da Gaussiana, é um parâmetro fixo, a ser escolhido empiricamente. Devido ao princípio da incerteza, há sempre uma relação inversa entre a resolução temporal e a resolução espectral obtidas com um dado valor de σ : quanto menor o σ , maior será a resolução temporal e pior a espectral, e vice-versa.

Stockwell e seus colaboradores propuseram escolher o valor de σ de modo a combinar as características positivas da GT e da transformada *wavelet* [153], introduzindo a Transformada S , sob a forma

$$S(t, \omega) = \frac{|\omega|}{(2\pi)^{3/2}} \int_{-\infty}^{+\infty} e^{-i\omega\tau} e^{-\frac{(\tau-t)^2\omega^2}{2(2\pi)^2}} x(\tau) d\tau \quad (2.2)$$

o que equivale a uma transformada de Fourier de tempo curto sob uma janela Gaussiana cuja largura varia inversamente com a frequência, de modo que as componentes de alta frequência do sinal são analisadas com maior resolução temporal. Assim, de forma semelhante à transformada *wavelet* [153], a ST foca (*'zooms in'*) nos detalhes temporais finos do sinal analisado, mas ao custo de uma perda de resolução nas altas frequências do espectro.

Uma alternativa à análise tempo-frequência baseada na função de Gabor é dada pela transformada de Wigner, ou Wigner-Ville, que emprega o próprio sinal como seu núcleo analisador. Originalmente introduzida na mecânica quântica [180], a transformada de Wigner é definida como

$$W(t, \omega) = \int_{-\infty}^{+\infty} e^{-i\omega\tau} x(t + \tau/2) x^*(t - \tau/2) d\tau \quad (2.3)$$

onde o asterisco indica conjugação complexa. A transformada de Wigner não tem parâmetros livres, e exibe várias propriedades analíticas desejáveis, mas, sendo uma transformada bilinear, ela possui a desvantagem de introduzir termos espúrios no espectro de frequência de sinais multi-componentes, o que se conhece como o “problema dos termos cruzados” [39]. Esse problema pode ser reduzido com o uso de janelas de filtragem, como nas duas

abordagens descritas a seguir, cuja desvantagem se encontra na degradação das resoluções espectral e temporal da transformada original [156].

A distribuição Pseudo Wigner-Ville (PWVD) é uma distribuição de Wigner-Ville à qual se sobrepõe uma janela temporal. Ela é dada por

$$PWVD(t, \omega) = \int_{-\infty}^{+\infty} e^{-i\omega\tau} x^*(t - \frac{\tau}{2}) x(t + \frac{\tau}{2}) h^*(\frac{-\tau}{2}) h(\frac{\tau}{2}) d\tau \quad (2.4)$$

onde $h(t)$ é uma janela com a qual se busca atenuar termos cruzados no tempo.

Visando reduzir termos cruzados na frequência, os resultados da PWVD podem ser atenuados por filtragem passa-baixa, dando origem à distribuição Pseudo Wigner-Ville Suavizada (SPWVD), que fica definida como

$$SPWVD(t, \omega) = \int_{-\infty}^{+\infty} g(t - t') PWVD(t', \omega) dt' = \int_{-\infty}^{+\infty} h^*(\frac{-\tau}{2}) h(\frac{\tau}{2}) \int_{-\infty}^{+\infty} g(t - t') x^*(t' - \frac{\tau}{2}) x(t' + \frac{\tau}{2}) e^{-i\omega\tau} d\tau dt' \quad (2.5)$$

onde $h(t)$ e $g(t)$ são as janelas que visam atenuar termos cruzados nos domínios do tempo e da frequência, respectivamente.

As transformadas de Gabor Sintonizadas, que nós apresentaremos a seguir, são variantes da transformada de Gabor que mantêm certa semelhança tanto com a ST como com a transformada de Wigner, mas que apresentam vantagens sobre ambas, não dando origem, por exemplo, a termos cruzados.

2.3 Abordagem Sintonizada de Gabor

A transformada de Gabor sintonizada foi originalmente proposta em [163] como uma variante da GT em que o núcleo analisador fica determinado pela magnitude e pela fase da transformada de Fourier do sinal analisado – a primeira definindo a largura do núcleo de Gabor, e a segunda, a sua fase. A versão original da STGT toma, portanto, a forma

$$T(t, \omega) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} e^{-i[\omega\tau + \varphi(\omega)]} e^{-\frac{(\tau-t)^2}{2|X(\omega)|^2}} x(\tau) d\tau \quad (2.6)$$

com $|X(\omega)|$ e $\varphi(\omega)$ representando, respectivamente, a magnitude e a fase da transformada de Fourier do sinal analisado – i.e., $\mathcal{F}_{t \rightarrow \omega}\{x(t)\} = |X(\omega)|e^{i\varphi(\omega)}$ –, onde $\mathcal{F}_{t \rightarrow \omega}\{x(t)\} = X(\omega)$ é a transformada de Fourier de $x(t)$.¹

O conjunto dos núcleos de Gabor da STGT,

$$\psi_{\omega}(t) = \frac{1}{\sqrt{2\pi}} e^{i[\omega t + \varphi(\omega)]} e^{-\frac{t^2}{2|X(\omega)|^2}} \quad (2.7)$$

para todos os possíveis valores de ω , gera uma representação exata do sinal $x(t)$, sob a forma

$$x(t) = \int_{-\infty}^{+\infty} e^{i\omega t} \langle \psi_{\omega}(t), e^{i\omega t} \rangle d\omega \quad (2.8)$$

onde a operação entre colchetes é um produto interno temporal – i.e., $\langle f(t), g(t) \rangle = \int_{-\infty}^{+\infty} f(\tau)g^*(\tau)d\tau$. Esta propriedade, formalmente demonstrada mais adiante, na Seção 2.4.1, pode ser facilmente verificada tomando-se a transformada de Fourier de ambos os lados da Eq. (2.8). A partir daí, conclui-se que, no que concerne à frequência ω , o núcleo $\psi_{\omega}(t)$ é equivalente ao sinal $x(t)$, sendo portanto referido como uma função de codificação de $x(t)$. A STGT, então, analisa o sinal dado por meio das suas próprias funções de codificação, o que empresta a esta transformada algumas das propriedades analíticas ideais da transformada de Wigner [65], como a propriedade de projeção ao longo da direção t , que fornece o espectro de potência do sinal:

$$|X(\omega)|^2 = \int_{-\infty}^{+\infty} T(t, \omega) dt \quad (2.9)$$

Além disso, a STGT adapta-se à análise de cada sinal de entrada, exibindo uma propriedade de “*zoom-in*” semelhante à da transformada *wavelet*, mas específica para cada sinal analisado, uma vez que ela rastreia as componentes transitórias do sinal – normalmente associadas a magnitudes de Fourier menores – utilizando núcleos de Gabor mais estreitos no domínio temporal (e portanto mais largos no domínio da frequência), enquanto usa núcleos temporalmente mais largos (e portanto espectralmente mais estreitos), para analisar as componentes estacionárias do sinal, geralmente associadas a magnitudes de Fourier maiores. Conforme ilustrado na referência [163] por meio da análise de traços eletroencefalográficos de pacientes epiléticos, isto permite uma detecção precisa dos eventos espectro-temporais do sinal, mesmo em situações em que a GT e a ST tendem a falhar.

¹Aqui nós usamos definições simétricas para as transformadas direta e inversa de Fourier: $X(\omega) = \int e^{-i\omega t} x(t) dt$ e $x(t) = \int e^{i\omega t} X(\omega) d\omega$.

2.3.1 Segunda Forma da Transformada de Gabor Sintonizada

Uma segunda versão da transformada sintonizada de Gabor, que será referida neste trabalho como a STGT₂, foi também proposta – embora não desenvolvida – em [163], com base em funções analisadoras definidas no domínio da frequência,

$$\psi_t(\omega) = \frac{1}{\sqrt{2\pi}} e^{-i[\omega t - \phi(t)]} e^{-\frac{\omega^2}{2|x(t)|^2}} \quad (2.10)$$

onde $x(t) = |x(t)|e^{i\phi(t)}$ é o sinal temporal, em princípio complexo, cuja transformada de Fourier é $X(\omega)$ – i.e., $\mathcal{F}_{\omega \rightarrow t}^{-1}\{X(\omega)\} = |x(t)|e^{i\phi(t)}$. Utilizando as funções $\psi_t(\omega)$, é possível definir uma transformada sintonizada de Gabor para a análise de sinais no domínio da frequência, sob a forma

$$T_2(t, \omega) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} e^{i[\Omega t - \phi(t)]} e^{-\frac{(\Omega - \omega)^2}{2|x(t)|^2}} X(\Omega) d\Omega \quad (2.11)$$

O conjunto das funções $\psi_t(\omega)$ para todos os valores possíveis de t fornece uma representação exata do sinal espectral $X(\omega)$, conforme

$$X(\omega) = \int_{-\infty}^{+\infty} e^{-i\omega t} \langle \psi_t(\omega), e^{-i\omega t} \rangle dt \quad (2.12)$$

onde a expressão entre colchetes agora representa um produto interno espectral, ou seja, $\langle F(\omega), G(\omega) \rangle = \int_{-\infty}^{+\infty} F(\Omega) G^*(\Omega) d\Omega$. Esta propriedade, formalmente demonstrada mais adiante, na Seção 2.4.1, pode ser facilmente verificada tomando-se a transformada de Fourier inversa de ambos os lados da Eq. (2.12). Conclui-se que, em um dado instante t , o núcleo $\psi_t(\omega)$ é equivalente a $X(\omega)$, e pode assim ser referido como uma função de codificação de $X(\omega)$. A STGT₂ utiliza, portanto, para a análise de um sinal espectral, as próprias funções de codificação do sinal, o que lhe confere algumas das propriedades da transformada de Wigner que não são compartilhadas pela STGT, como a de permitir a recuperação do espectro de potência do sinal por meio de uma projeção ao longo da frequência:

$$|X(t)|^2 = \int_{-\infty}^{+\infty} T_2(t, \omega) d\omega \quad (2.13)$$

Do mesmo modo que a STGT, a STGT₂ se adapta a cada sinal de entrada, analisando os seus trechos de alta amplitude com núcleos de Gabor estreitos temporalmente (e portanto largos no domínio da frequência), e usando núcleos mais largos temporalmente (e portanto

mais estreitos espectralmente) para a análise dos trechos de baixa amplitude.

Em [164], as transformadas sintonizadas de Gabor demonstraram ser capazes de proporcionar um modelo plausível para certos tipos de células do córtex visual primário, no sentido de replicar as suas respostas a estímulos padrão, e também de descrever a variação dos campos receptivos dessas células de acordo com o estímulo. Ainda que tais resultados dêem algum suporte biológico para ambas as abordagens sintonizadas, a relevância da STGT₂ como uma técnica específica para a análise de sinais ainda carecia de uma demonstração concreta. Mais adiante nós iremos mostrar que, devido à sua característica de distinguir as assinaturas espectro-temporais dos trechos de alta amplitude no sinal de entrada daquelas dos seus trechos de baixa amplitude, a STGT₂ fornece uma ferramenta particularmente adequada para a análise de distúrbios dos sinais elétricos.

2.4 Extensões da Abordagem de Gabor Sintonizada

2.4.1 Introduzindo os Polinômios de Hermite

No que se segue, nós apresentamos a abordagem sintonizada expandida, conforme proposta em [7].

2.4.1.1 Funções Sintonizadas da Primeira Forma

Os núcleos de Gabor da STGT, dados pela Eq. (2.7),

$$\psi_{\omega}(t) = \frac{1}{\sqrt{2\pi}} e^{i[\omega t + \varphi(\omega)]} e^{-\frac{t^2}{2|X(\omega)|^2}} \quad (2.14)$$

podem ser obtidos como caso particular, para $n = 0$, das funções

$$\psi_{\omega}^{(n)}(t) = \frac{1}{\sqrt{2\pi}} \frac{(-1)^n}{|X(\omega)|^n} e^{i[\omega t + \varphi(\omega)]} He_n \left[\frac{t - i\omega |X(\omega)|^2}{|X(\omega)|} \right] e^{-\frac{t^2}{2|X(\omega)|^2}} \quad (2.15)$$

que também podem ser escritas como

$$\psi_{\omega}^{(n)}(t) = \frac{1}{\sqrt{2\pi}} \frac{(-1)^n}{|X(\omega)|^n} e^{i\varphi(\omega)} e^{-\frac{\omega^2}{2}|X(\omega)|^2} He_n \left[\frac{t - i\omega |X(\omega)|^2}{|X(\omega)|} \right] e^{-\frac{[t - i\omega |X(\omega)|^2]^2}{2|X(\omega)|^2}} \quad (2.16)$$

onde os $He_n(t)$, para n inteiro não-negativo, são os polinômios de Hermite na forma “dos probabilistas”, ou seja,

$$He_n(t) = 2^{-n/2} H_n(t/\sqrt{2}) \quad (2.17)$$

com $H_n(t)$ denotando os polinômios de Hermite “dos físicos”, mais comumente encontrados.

Os polinômios $He_n(t)$ são explicitamente dados por

$$He_n(t) = (-1)^n e^{\frac{t^2}{2}} \frac{d^n}{dt^n} e^{-\frac{t^2}{2}} \quad (2.18)$$

os primeiros deles assumindo a forma

$$\begin{cases} He_0(t) = 1 \\ He_1(t) = t \\ He_2(t) = t^2 - 1 \\ He_3(t) = t^3 - 3t \end{cases} \quad (2.19)$$

O seguinte resultado vale para a transformada de Fourier dos $He_n(t)$,

$$\mathcal{F}_{t \rightarrow \omega'} \{e^{-t^2/2} He_n(t)\} = \sqrt{2\pi} (-i\omega')^n e^{-\omega'^2/2} \quad (2.20)$$

ou, lembrando as propriedades de escala e translação dessa transformada,

$$\mathcal{F}_{t \rightarrow \omega'} \left\{ e^{-\frac{(t-i\beta)^2}{2\alpha^2}} He_n \left(\frac{t-i\beta}{\alpha} \right) \right\} = \sqrt{2\pi} \alpha^{n+1} (-i\omega')^n e^{-\frac{\omega'^2 \alpha^2}{2}} e^{\omega' \beta} \quad (2.21)$$

Usando isto, é possível demonstrar que as funções $\psi_\omega^{(n)}(t)$ fornecem uma representação exata da derivada de ordem n do sinal de sintonia, sob a forma

$$x^{(n)}(t) \equiv \frac{d^n}{dt^n} x(t) = \int_{-\infty}^{\infty} e^{i\omega t} \langle \psi_\omega^{(n)}(t), e^{i\omega t} \rangle d\omega \equiv \int e^{i\omega t} * \psi_\omega^{(n)}(t) d\omega \quad (2.22)$$

onde o asterisco denota uma convolução temporal. Especificamente, tomando a transformada de Fourier dos dois lados da equação acima, nós obtemos

$$\begin{aligned} \mathcal{F}_{t \rightarrow \omega'} \{x^{(n)}(t)\} &= (-1)^n \times \\ &\times \int \frac{e^{i\varphi(\omega)}}{|X(\omega)|^n} e^{-\frac{\omega^2}{2}|X(\omega)|^2} \delta(\omega - \omega') |X(\omega)|^{n+1} (-i\omega')^n e^{-\frac{\omega'^2 |X(\omega)|^2}{2}} e^{\omega'^2 |X(\omega)|^2} d\omega \end{aligned} \quad (2.23)$$

e portanto,

$$\mathcal{F}_{t \rightarrow \omega'} \{x^{(n)}(t)\} = (i\omega')^n |X(\omega')| e^{i\varphi(\omega')} = \mathcal{F}_{t \rightarrow \omega'} \left\{ \frac{d^n}{dt^n} x(t) \right\} \quad (2.24)$$

o que demonstra a propriedade.

2.4.1.2 Funções Sintonizadas da Segunda Forma

Os resultados acima podem ser facilmente estendidos para os núcleos de Gabor da STGT₂, dados pela Eq. (2.10), ou seja,

$$\psi_t(\omega) = \frac{1}{\sqrt{2\pi}} e^{-i[\omega t - \phi(t)]} e^{-\frac{\omega^2}{2|x(t)|^2}} \quad (2.25)$$

Estes podem ser obtidos como caso particular, para $n = 0$, das funções

$$\psi_t^{(n)}(\omega) = \frac{1}{\sqrt{2\pi}} \frac{(-1)^n}{|x(t)|^n} e^{-i[\omega t - \phi(t)]} He_n \left[\frac{\omega + it|x(t)|^2}{|x(t)|} \right] e^{-\frac{\omega^2}{2|x(t)|^2}} \quad (2.26)$$

que também podem ser escritas como

$$\psi_t^{(n)}(\omega) = \frac{1}{\sqrt{2\pi}} \frac{(-1)^n}{|x(t)|^n} e^{i\phi(t)} e^{-\frac{t^2}{2}|x(t)|^2} He_n \left[\frac{\omega + it|x(t)|^2}{|x(t)|} \right] e^{-\frac{[\omega + it|x(t)|^2]^2}{2|x(t)|^2}} \quad (2.27)$$

Estas funções sintonizadas generalizadas fornecem uma representação exata das derivadas da transformada de Fourier do sinal de sintonia, sob a forma

$$X^{(n)}(\omega) \equiv \frac{d^n}{d\omega^n} X(\omega) = \int e^{-i\omega t} * \psi_t^{(n)}(\omega) dt \quad (2.28)$$

onde o asterisco agora denota uma convolução espectral. Isto se verifica tomando-se a transformada inversa de Fourier dos dois lados da equação acima, para obter

$$\begin{aligned} \mathcal{F}_{\omega \rightarrow t'}^{-1} \{X^{(n)}(\omega)\} &= (-1)^n \times \\ &\times \int \frac{e^{i\phi(t)}}{|x(t)|^n} e^{-\frac{t^2}{2}|x(t)|^2} \delta(t - t') |x(t)|^{n+1} (it)^n e^{-\frac{t'^2|x(t)|^2}{2}} e^{t'^2|x(t)|^2} dt \end{aligned} \quad (2.29)$$

o que fornece

$$\mathcal{F}_{\omega \rightarrow t'}^{-1} \{X^{(n)}(\omega)\} = (-it')^n |x(t')| e^{i\phi(t')} = \mathcal{F}_{\omega \rightarrow t'}^{-1} \left\{ \frac{d^n}{d\omega^n} X(\omega) \right\} \quad (2.30)$$

e portanto,

$$X^{(n)}(\omega) = \frac{d^n}{d\omega^n} X(\omega) \quad (2.31)$$

onde nós usamos

$$\mathcal{F}_{\omega \rightarrow t'}^{-1} \left\{ e^{-\frac{(\omega + i\beta)^2}{2\alpha^2}} He_n \left(\frac{\omega + i\beta}{\alpha} \right) \right\} = \sqrt{2\pi} \alpha^{n+1} (it')^n e^{-\frac{t'^2 \alpha^2}{2}} e^{t'\beta} \quad (2.32)$$

2.4.2 Transformadas Sintonizadas Generalizadas

Com base nas funções sintonizadas $\psi_\omega^{(n)}(t)$, nós podemos definir uma transformada sintonizada temporal generalizada, sob a forma

$$T^{(n)}(t, \omega) = \int He_n^* \left[\frac{t - \tau - i\omega |X(\omega)|^2}{|X(\omega)|} \right] G(\tau, t, \omega) x(\tau) d\tau \quad (2.33)$$

o que equivale a

$$T^{(n)}(t, \omega) = \int He_n \left[\frac{t - \tau + i\omega |X(\omega)|^2}{|X(\omega)|} \right] G(\tau, t, \omega) x(\tau) d\tau \quad (2.34)$$

onde

$$G(\tau, t, \omega) = \frac{1}{\sqrt{2\pi}} \frac{(-1)^n}{|X(\omega)|^n} e^{-i[\omega\tau + \varphi(\omega)]} e^{-\frac{(\tau-t)^2}{2|X(\omega)|^2}} \quad (2.35)$$

A transformada $T^{(n)}(t, \omega)$ corresponde portanto à análise do sinal temporal $x(t)$ pelas funções de representação da sua enésima derivada, e tem a transformada de Gabor sintonizada $T(t, \omega)$, da Eq. (2.6), como seu caso particular para $n = 0$.

Similarmente, com base nas funções sintonizadas $\psi_t^{(n)}(\omega)$, nós podemos definir uma transformada sintonizada de Gabor espectral generalizada, sob a forma

$$T_2^{(n)}(t, \omega) = \int He_n^* \left[\frac{\omega - \Omega + it|x(t)|^2}{|x(t)|} \right] G(\Omega, \omega, t) X(\Omega) d\Omega \quad (2.36)$$

que equivale a

$$T_2^{(n)}(t, \omega) = \int He_n \left[\frac{\omega - \Omega - it|x(t)|^2}{|x(t)|} \right] G(\Omega, \omega, t) X(\Omega) d\Omega \quad (2.37)$$

para

$$G(\Omega, \omega, t) = \frac{1}{\sqrt{2\pi}} \frac{(-1)^n}{|x(t)|^n} e^{i[\Omega t - \phi(t)]} e^{-\frac{(\Omega-\omega)^2}{2|x(t)|^2}} \quad (2.38)$$

A transformada $T_2^{(n)}(t, \omega)$ corresponde portanto à análise do sinal espectral $X(\omega)$ pelas funções de representação da sua enésima derivada, e tem a transformada de Gabor sintonizada $T_2(t, \omega)$, da Eq. (2.11), como seu caso particular para $n = 0$.

2.4.3 Transformadas Sintonizadas na Frequência ω_0

A STGT na frequência ω_0 , $STGT_{\omega_0}$, é dada por

$$T(t, \omega_0) = \int e^{-i[\omega_0\tau + \varphi(\omega_0)]} e^{-\frac{(\tau-t)^2}{2|X(\omega_0)|^2}} x(\tau) d\tau \quad (2.39)$$

e corresponde à análise do sinal $x(t)$ pela sua função de representação na frequência ω_0 . Como os sinais elétricos ideais devem manter uma frequência constante, esta variante da STGT se mostra vantajosa para a análise de distúrbios nos SEP, como veremos.

A Eq. (2.39) pode ser generalizada como

$$T(t, \Omega; \omega_0) = \int e^{-i[\Omega\tau + \varphi(\omega_0)]} e^{-\frac{(\tau-t)^2}{2|X(\omega_0)|^2}} x(\tau) d\tau \quad (2.40)$$

onde Ω é uma frequência qualquer.² É interessante observar que a transformada $T(t, \Omega; \omega_0)$ pode ser expressa em termos de uma Wigner cruzada. Vamos considerar

$$T(2t, \Omega; \omega_0) = \int e^{-i[\Omega\tau + \varphi(\omega_0)]} e^{-\frac{(\tau-2t)^2}{2|X(\omega_0)|^2}} x(\tau) d\tau \quad (2.41)$$

e fazendo uma mudança da variável de integração para τ' , onde $\tau = \tau'/2 + t$,

$$T(2t, \Omega; \omega_0) = \frac{1}{2} \int e^{-i[\Omega(\frac{\tau'}{2} + t) + \varphi(\omega_0)]} e^{-\frac{(\frac{\tau'}{2} + t - 2t)^2}{2|X(\omega_0)|^2}} x(t + \tau'/2) d\tau' \quad (2.42)$$

Portanto,

$$T(2t, \Omega; \omega_0) = \frac{1}{2} \int e^{-i[\Omega(\frac{\tau'}{2} + t) + \varphi(\omega_0)]} e^{-\frac{(\frac{\tau'}{2} - t)^2}{2|X(\omega_0)|^2}} x(t + \tau'/2) d\tau' \quad (2.43)$$

ou seja,

$$T(2t, \Omega; \omega_0) = \frac{1}{2} \int e^{-i\Omega\tau'} e^{-i[\Omega(t - \frac{\tau'}{2}) + \varphi(\omega_0)]} e^{-\frac{(\frac{\tau'}{2} - t)^2}{2|X(\omega_0)|^2}} x(t + \tau'/2) d\tau' \quad (2.44)$$

o que corresponde a

$$T(2t, \Omega; \omega_0) = \frac{1}{2} \int e^{-i\Omega\tau'} x(t + \tau'/2) y^*(t - \tau'/2) d\tau' \quad (2.45)$$

onde a integral pode ser identificada como a transformada de Wigner cruzada entre os sinais $x(t)$ e $y(t)$, para

$$y(t) = e^{i[\Omega t + \varphi(\omega_0)]} e^{-\frac{t^2}{2|X(\omega_0)|^2}} \quad (2.46)$$

Para exemplificar a aplicação da $STGT_{\omega_0}$, a Fig. 2.1 apresenta um sinal corrompido por um distúrbio do tipo *Spikes*. Conforme veremos mais adiante, no Capítulo 3, este tipo de distúrbio tem a característica de introduzir, na forma de onda fundamental do sinal, *frequências espúrias*, modelando o efeito de pulsos repetitivos de amplo espectro que acometem a rede elétrica continuamente. Observa-se, pela Fig. 2.1 (c) que a STGT é incapaz de detectar as componentes espectrais de baixa energia, enquanto que a transformada S (Fig. 2.1 (d)) tampouco identifica de forma correta o distúrbio, por borrar as frequências espúrias. Já a $STGT_{\omega_0}$, quando ω_0 corresponde à frequência da forma de

²Destá forma, a STGT tradicional corresponderia a $T(t, \omega; \omega)$.

onda fundamental – neste caso, 50 Hz –, informa corretamente todas as frequências do distúrbio (Fig. 2.1 (e)), como se vê pelo espectro de Fourier do sinal (Fig. 2.1 (b)).

A característica de que, na $STGT_{\omega_0}$, a janela Gaussiana é calculada para uma frequência fixa também facilita a implementação e o processamento computacional da transformada, que se reduz a uma versão particular da transformada de Gabor tradicional.

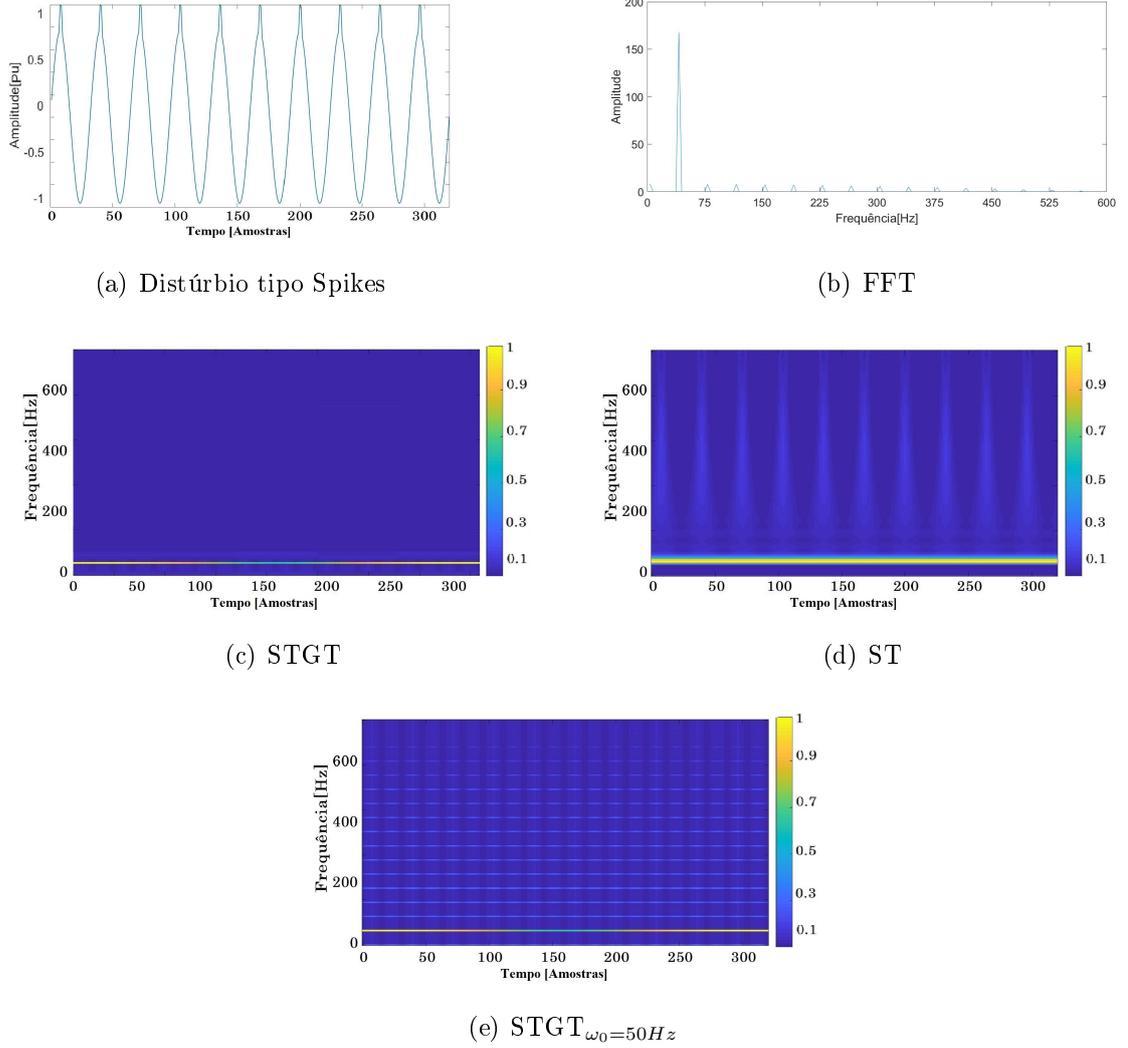


Figura 2.1: Ilustrando a Aplicação da $STGT_{\omega_0}$ a um sinal com distúrbio do tipo *Spikes*.

2.4.4 Transformada Sintonizada Fracionária - FrSTGT

A transformada fracionária de Fourier (FrFT) é definida como

$$\begin{aligned}
 X_{\alpha}(u) &\equiv \text{FrFT}_{\alpha}\{x(t)\}(u) = \\
 &= \sqrt{\frac{1 - i \cot \alpha}{2\pi}} \int e^{i \left[\frac{(t^2 + u^2)}{2} \cot \alpha - ut \csc \alpha \right]} x(t) dt
 \end{aligned} \tag{2.47}$$

onde t e u são considerados como variáveis adimensionais, e onde α é um parâmetro angular, expresso em radianos, referido como a ordem da transformada.

Para $\alpha = 2k\pi$, onde k é um inteiro, nós obtemos $X_\alpha(u) = x(u)$, e a FrFT fornece o sinal original. Por outro lado, para $\alpha = (2k + 1)\pi$, nós obtemos $X_\alpha(u) = x(-u)$, e para $\alpha = \pi/2$ nós recuperamos a transformada de Fourier tradicional,

$$X_{\frac{\pi}{2}}(u) \equiv \frac{1}{\sqrt{2\pi}} X(u) = \frac{1}{\sqrt{2\pi}} \int e^{-iut} x(t) dt \quad (2.48)$$

Aplicar duas FrFTs consecutivas de ângulos α e β equivale a aplicar uma única transformada de ângulo $\alpha + \beta$, e a inversa de uma FrFT de ângulo α é uma FrFT de ângulo $-\alpha$. Estas e outras propriedades permitem interpretar a FrFT como uma rotação da representação do sinal no plano tempo-frequência [5].

Em [162] uma generalização das transformadas sintonizadas de Gabor foi proposta, sob a forma

$$T_\alpha^\beta(t, u) = \frac{|\csc \alpha|}{\sqrt{2\pi}} \sqrt{1 - i \cot \alpha} \times \\ \times \int e^{i\left[\left(\frac{\tau^2+u^2}{2}\right) \cot \alpha - u\tau \csc \alpha - \varphi_{\alpha+\beta}(u)\right]} e^{-\frac{(\tau-t-u \cos \alpha)^2}{2[\sin \alpha |X_{\alpha+\beta}(u)|]^2}} X_\beta(\tau) d\tau \quad (2.49)$$

A transformada $T_\alpha^\beta(t, u)$ portanto analisa $X_\beta(t)$ – a FrFT de ordem β de um dado sinal – por meio de núcleos analisadores que são as funções de codificação do próprio $X_\beta(t)$, com os parâmetros de fase e de largura das funções de codificação sendo determinados pela FrFT do sinal na ordem $\alpha + \beta$ (ver [162] para maiores detalhes).

É fácil verificar que as transformadas $T_{\frac{\pi}{2}}^0(t, u)$ e $T_{-\frac{\pi}{2}}^{\frac{\pi}{2}}(t, u)$ correspondem, respectivamente, às transformadas sintonizadas de Gabor temporal e espectral, $T(t, \omega)$ e $T_2(t, \omega)$. Por outro lado, para um β qualquer, nós também obtemos

$$T_0^\beta(t, u) = \int \delta(\tau - u) X_\beta^*(\tau - t) \delta(\tau - t - u) X_\beta(\tau) d\tau = \\ = \delta(t) X_\beta^*(u) X_\beta(u) \quad (2.50)$$

Integrado sobre todo t , este resultado fornece a densidade de potência de $X_\beta(t)$,³

$$\int T_0^\beta(t, u) dt = |X_\beta(u)|^2 \quad (2.51)$$

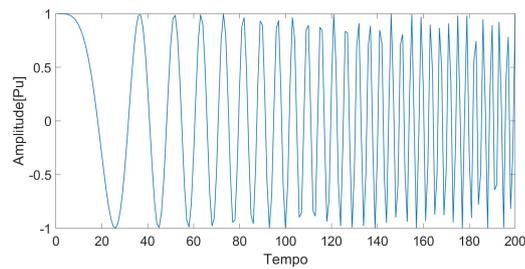
³Uma propriedade de projeção que vale para qualquer transformada $T_\alpha^\beta(t, u)$, sob a forma

$$\int T_\alpha^\beta(t, u) dt = |X_{\alpha+\beta}(u)|^2$$

A Fig. 2.2 apresenta o resultado da aplicação da transformada sintonizada fracionária a um *chirp linear*, sinal cuja frequência cresce linearmente com o tempo, conforme equação:

$$I_{chirp}(t) = \cos[(2\pi(10 + (1/7)t))t/200] \quad (2.52)$$

Dada a forma do sinal, nós fixamos o valor de β no arco cuja tangente é $(\frac{1}{7})$, e consideramos diversos valores para o parâmetro α , com o objetivo de ilustrar o efeito de rotação no plano tempo-frequência. Note-se que à medida em que o parâmetro α se aproxima de 1, a resolução da transformada melhora, mas mesmo nesse caso a interpretação do espectrograma não é imediata, já que a transformada fracionária mistura os domínios da frequência e do tempo. Por essa razão, a transformada sintonizada fracionária não será empregada aqui para a identificação visual de sinais a partir das suas assinaturas tempo-frequência, mas como a classificação dos distúrbios em sinais elétricos depende apenas da semelhança dessas assinaturas nos espectrogramas dos sinais ideais e dos perturbados (ver Capítulo 3), a FrSTGT será incluída em nosso estudo dessa aplicação.



(a) Sinal Chirp

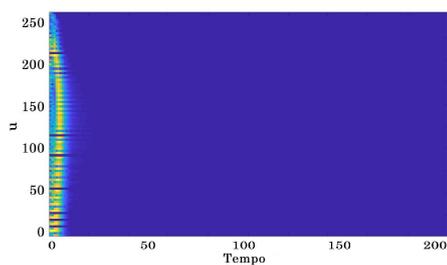
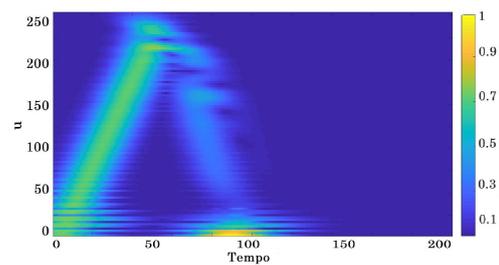
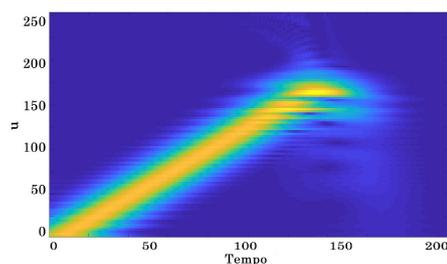
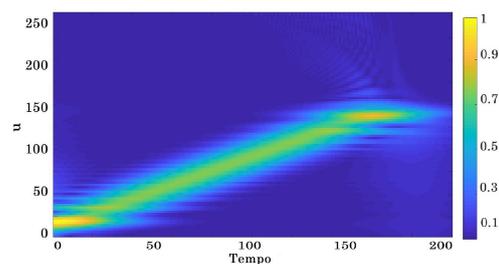
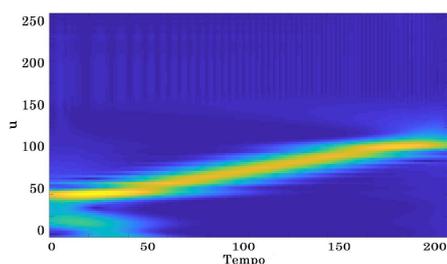
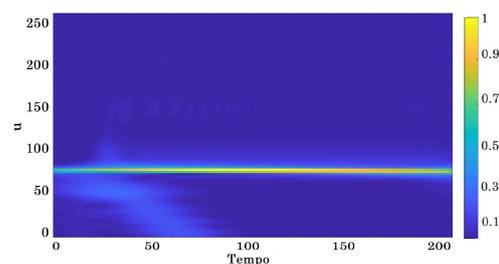
(b) FrSTGT $_{\alpha=0,055}$ (c) FrSTGT $_{\alpha=0,5}$ (d) FrSTGT $_{\alpha=0,8}$ (e) FrSTGT $_{\alpha=0,9}$ (f) FrSTGT $_{\alpha=1}$ (g) FrSTGT $_{\alpha=1,1}$

Figura 2.2: Aplicação da FrSTGT em um sinal de Chirp.

2.5 Análise Comparativa das Transformadas TF

Esta seção destina-se a uma análise visual dos espectrogramas (representações gráficas das transformadas TF, apresentando o seu módulo sobre o plano tempo-frequência) gerados pelas abordagens tradicionais (GT, ST e WVD), comparativamente àqueles produzidos

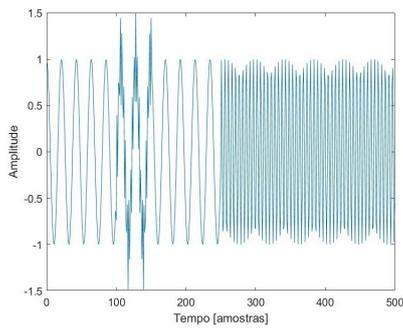
pela abordagem sintonizada, em suas diversas versões. Com isto, nós pretendemos avaliar a capacidade de representação das abordagens TF, sobretudo no que se refere à fidelidade às características dos sinais analisados, e à resolução conjunta espectro-temporal. Como a interpretação visual da FrSTGT é dificultada pela mistura dos domínios temporal e espectral, e como a aplicabilidade da $STGT_{\omega_0}$ depende da presença, no sinal, de uma frequência padrão, estas duas abordagens estão excluídas da análise que se segue, sendo empregadas apenas para a classificação de distúrbios de sinais elétricos, no Capítulo 4.

Nos experimentos reportados aqui, ressalta-se que a ST foi mantida na sua forma tradicional; com a WVD não se utilizou qualquer método para eliminação dos termos cruzados, enquanto para a GT a largura da janela analisadora foi escolhida empiricamente, por meio de testes específicos para cada sinal analisado, sendo que uma mesma largura de janela em geral não se mostra adequada para diferentes tipos de sinais.

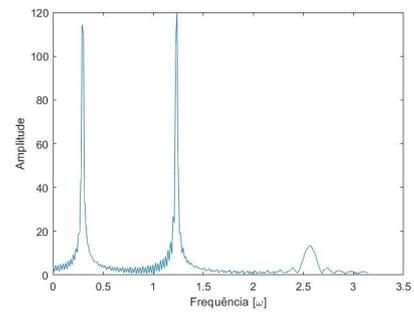
Inicialmente (Figs. 2.3 e 2.4) nós consideramos os espectrogramas associados ao sinal dado pela Eq. (2.53), e representado na Fig. 2.3(a), que corresponde à superposição de três componentes: duas ondas senoidais de frequências diferentes, no início e no fim do sinal, e um transitório de alta frequência na sua região intermediária.

$$\begin{cases} I_1(t) = \cos[2\pi(t5/128)], \text{ para } t \in [0, 250] \\ I_1(t) = I_1(t) + 0,5 \cos[2\pi(t50/128)], \text{ para } t \in [100, 150] \\ I_1(t) = I_1(t) + \cos[2\pi(t25/128)], \text{ para } t \in [250, 500] \end{cases} \quad (2.53)$$

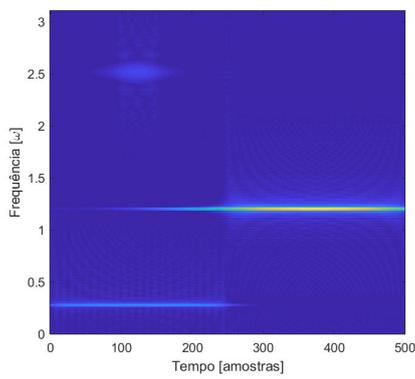
As seguintes observações podem ser feitas sobre os espectrogramas das Figs. 2.3 e 2.4: Guiando-nos pela transformada de Fourier do sinal analisado (FFT na Fig. 2.3 (b)), nós vemos que as componentes senoidais e o transiente são facilmente identificados por todas as abordagens, mas a ST e a WVD são imprecisas na definição dos valores de frequência: o espalhamento espectral com o aumento da frequência fica evidente na ST, enquanto a WVD, devido à inconveniência dos termos cruzados, não apresenta com clareza os componentes reais do sinal. Já as STGTs mostram precisão na identificação de todas as componentes de frequência do sinal analisado.



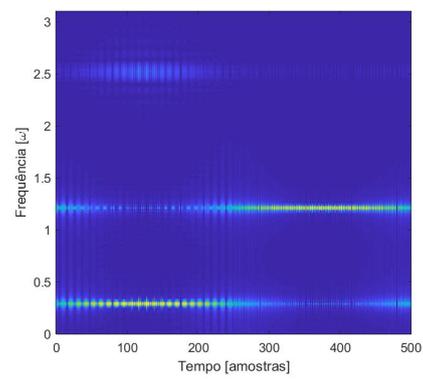
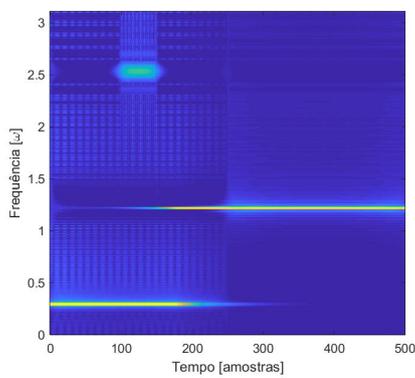
(a) Sinal01



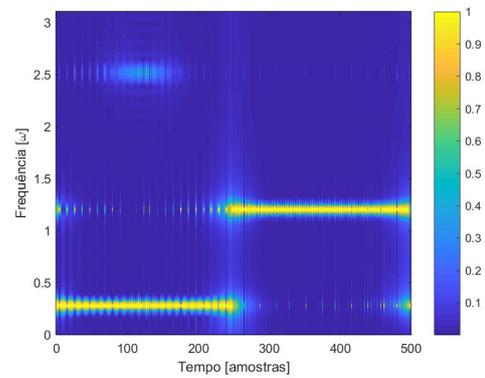
(b) FFT

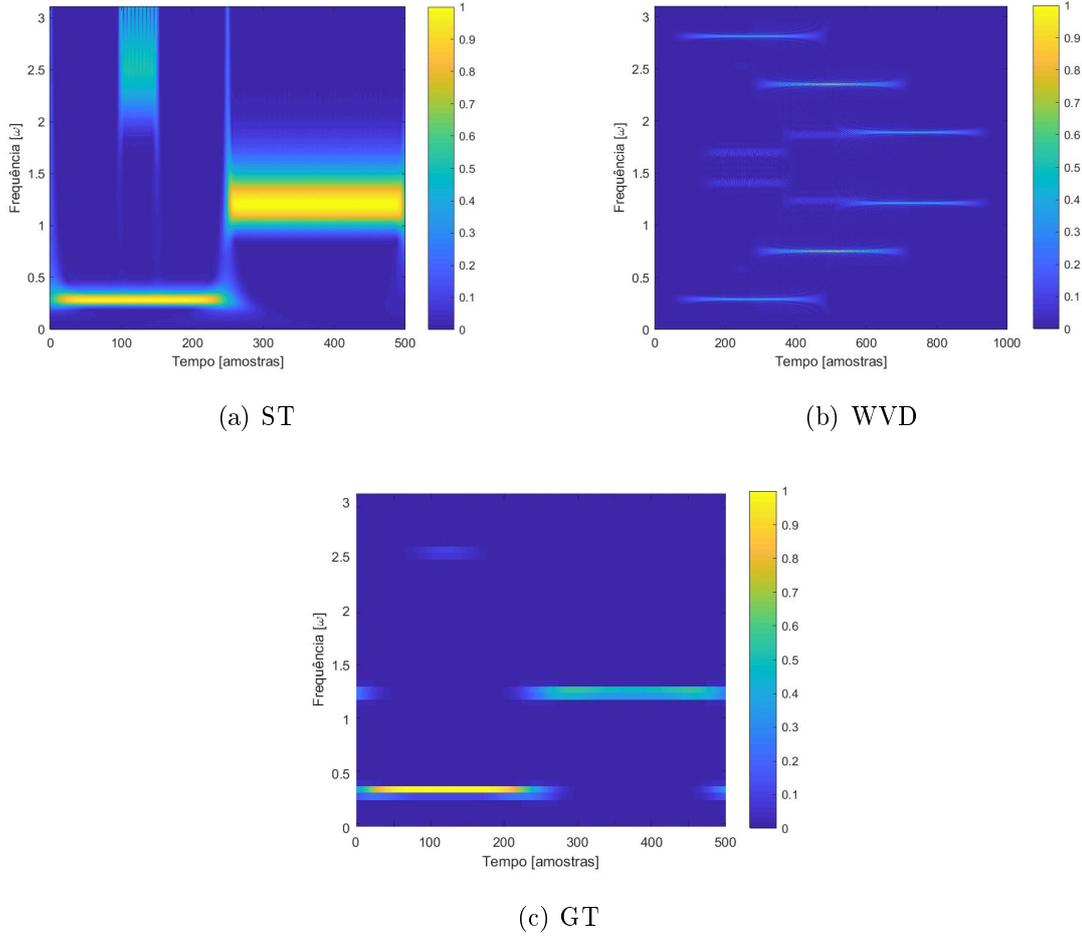


(c) STGT

(d) STGT₂

(e) STGT-Her

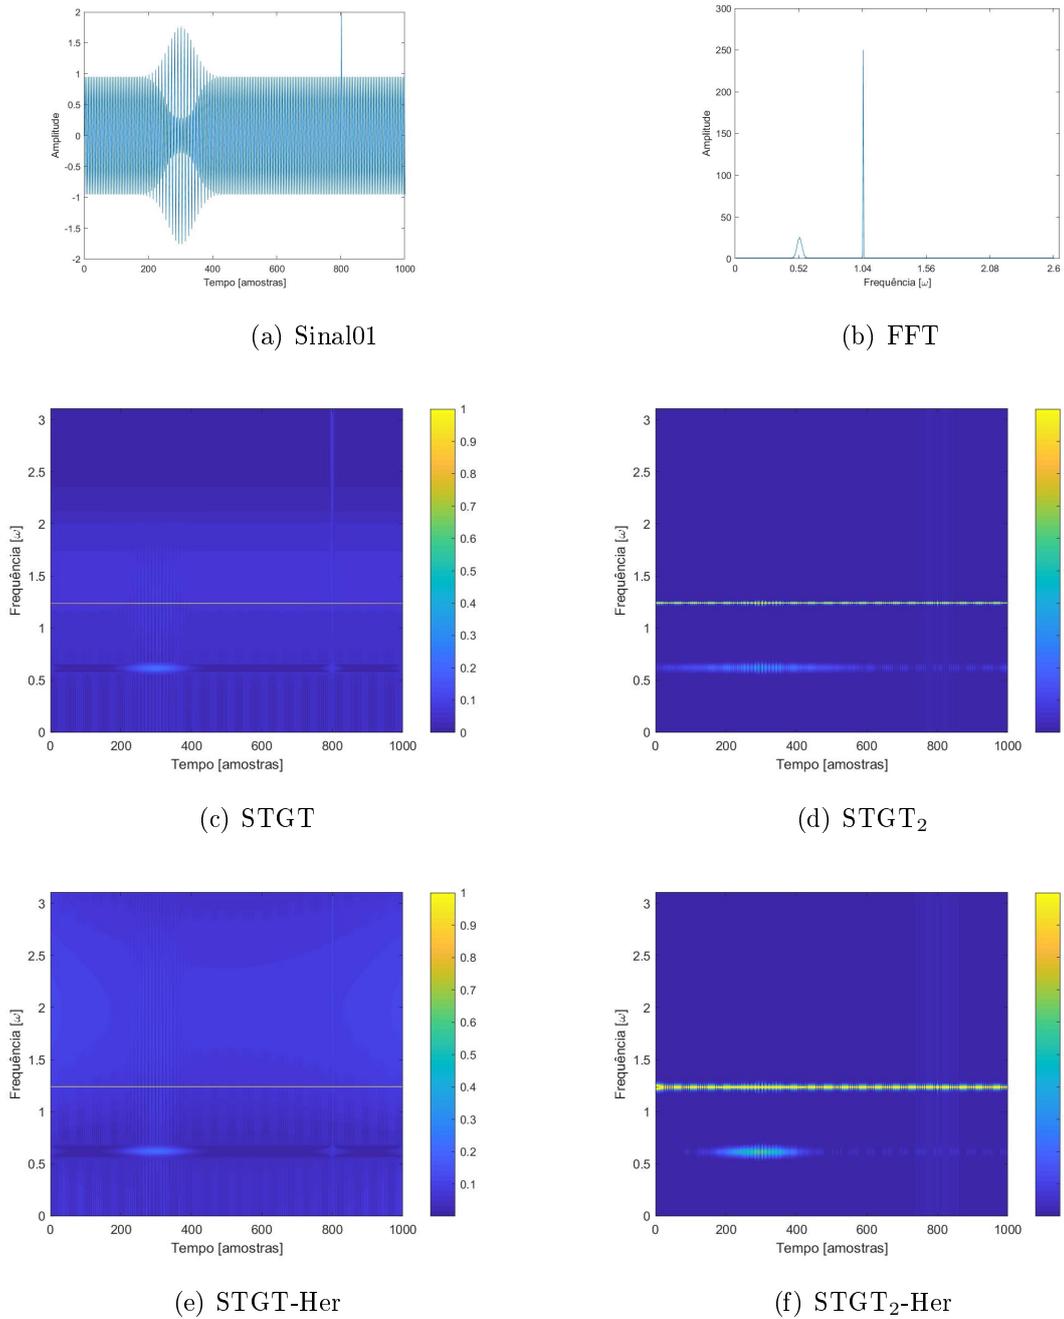
(f) STGT₂-HerFigura 2.3: Comparação Espectral Sinal I_1 .

Figura 2.4: Comparação Espectral Sinal I_1 .

Consideremos agora o sinal *signal* I_2 , que consiste na combinação de uma senóide, um pacote de onda de Gabor, e uma descontinuidade em impulso. A sua expressão analítica é dada pela Eq. (2.54):

$$I_2(t) = 2\delta(t - 800) + \sin\left[\frac{2\pi t}{5}\right] + e^{\frac{-\pi(t-300)^2}{10000}} \cos\left[\frac{\pi}{5}(t - 300)\right] \quad (2.54)$$

Nos espectrogramas das Figs. 2.5 e 2.6 vemos a identificação clara das componentes de frequência pelas STGTs, conforme as Figs. 2.5 (c), (d), (e), e (f), e também pela GT, Fig. 2.6 (c), comprovando o que a FFT, Fig. 2.5 (b), apresenta. A ST perde na resolução em frequência, devido ao espalhamento no espectro, Fig. 2.5 (b). O impulso em $t = 800$ é detectado pela ST, e de maneira sutil – devido à grande resolução temporal – pelas STGTs, mas não pela GT ou pela WVD, sendo que esta última, embora apresentando uma boa resolução em frequência, é prejudicada pelos termos cruzados.

Figura 2.5: Comparação Espectral Sinal I_2 .

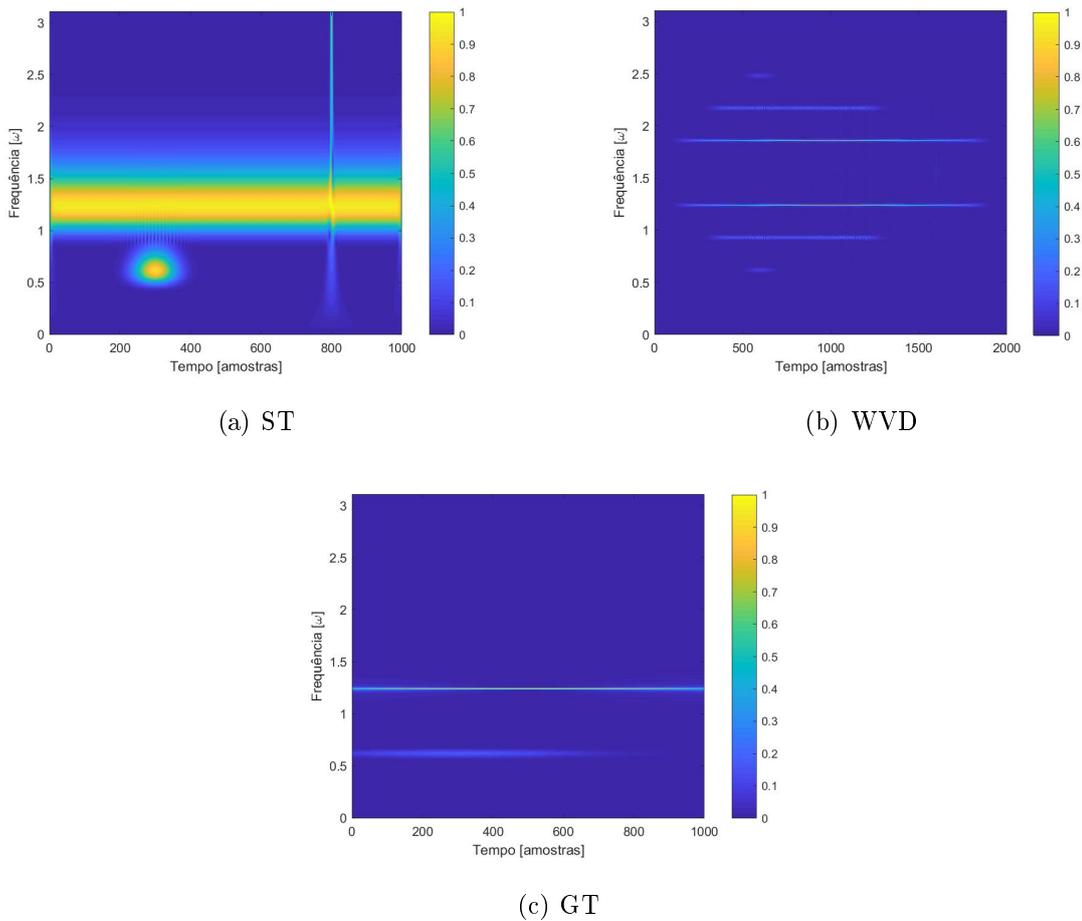
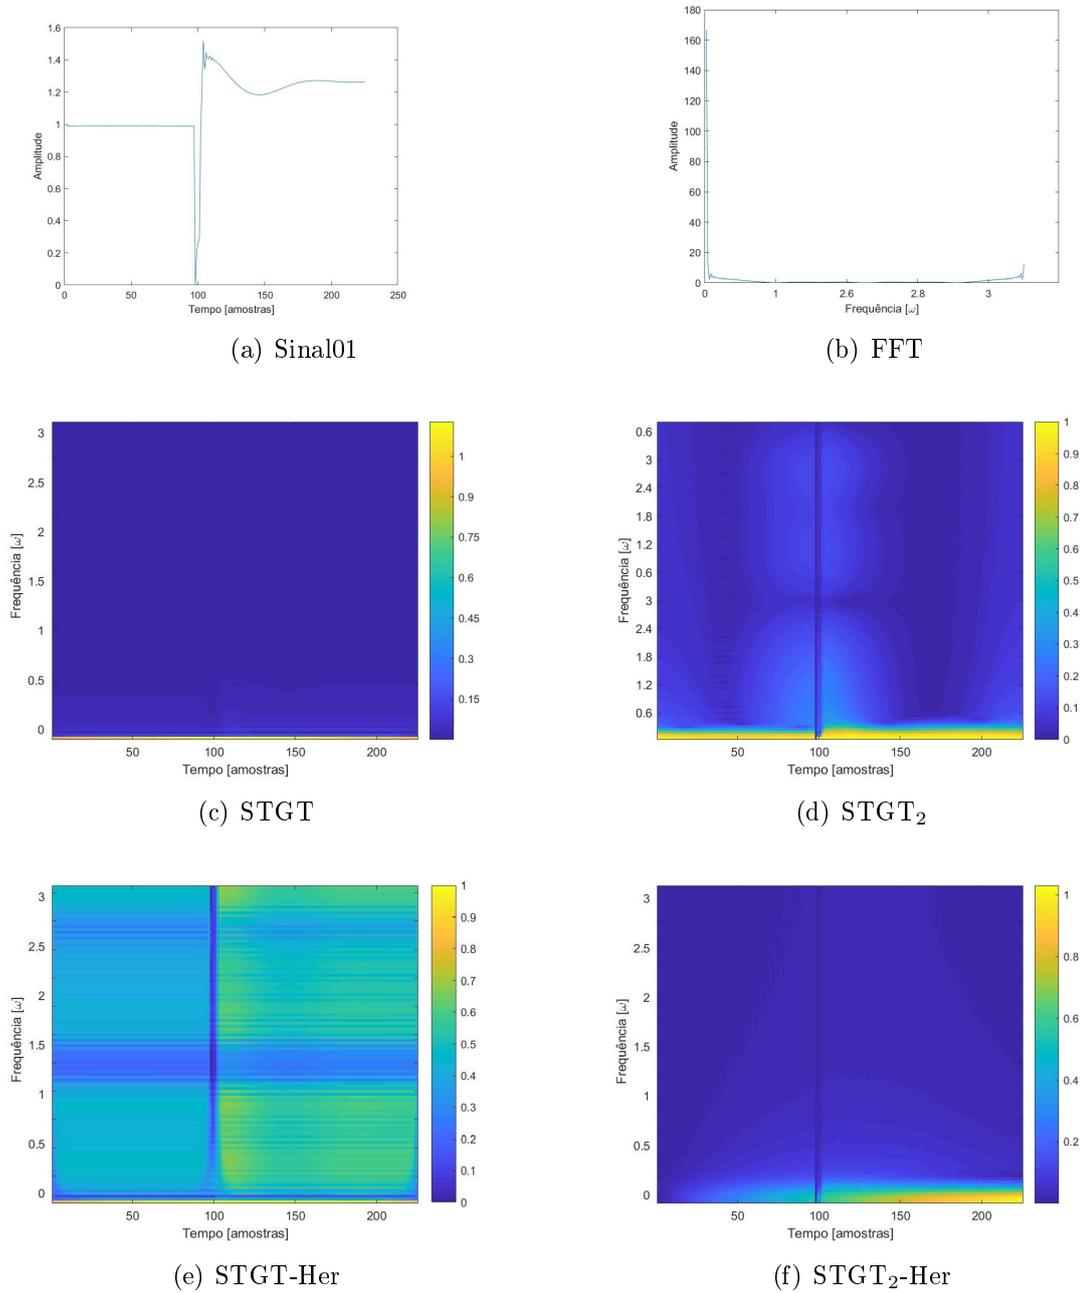
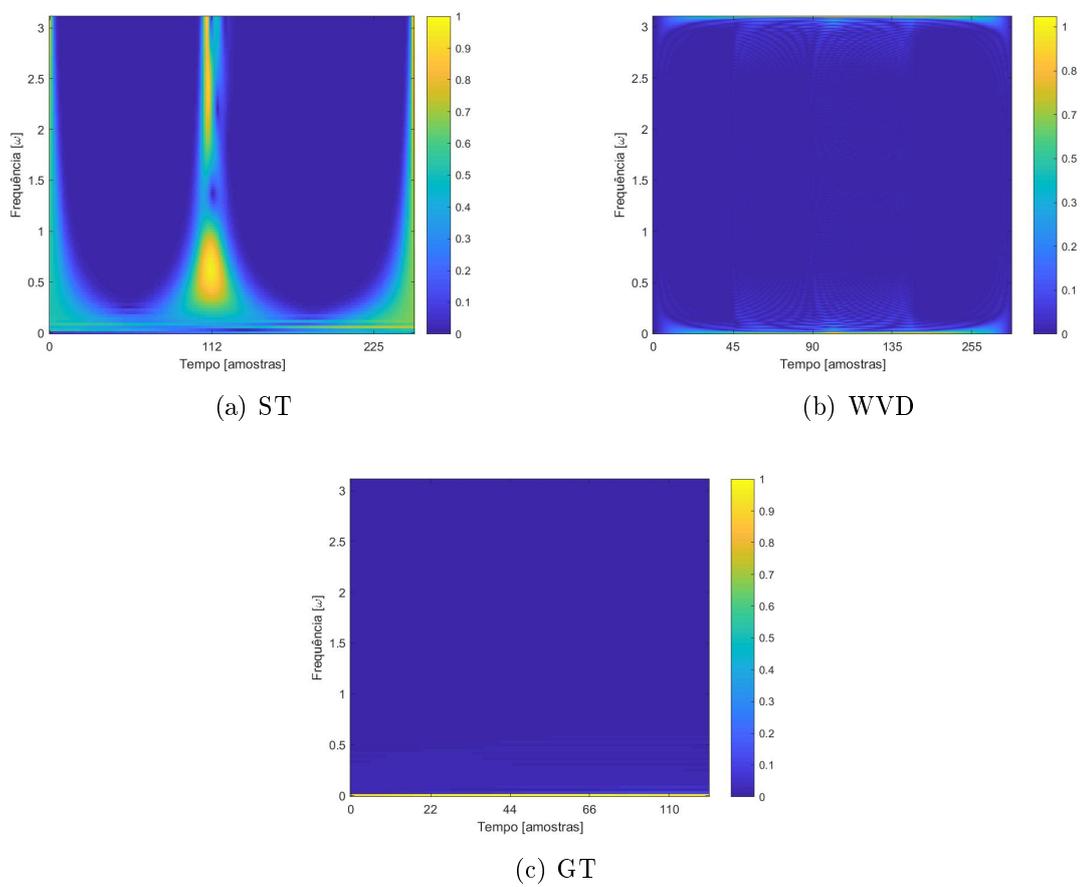


Figura 2.6: Comparação Espectral Sinal I_2 .

O sinal I_3 , da Fig. 2.7 (a), representa uma Variação de Tensão de Curta Duração (VTCD) proveniente de um curto-circuito em uma das fases de um sistema elétrico de potência (SEP). O sinal de tensão foi obtido como uma simulação, com o emprego da toolbox *SimPowerSystems*, do software *Matlab*. O diagrama da rede simulada consiste em um sistema de geração eólica ligado a rede de distribuição [102]. Na Fig. 2.7 (a) pode-se ver de forma clara a mudança brusca da tensão no instante $t = 100$, devido ao curto-circuito. Os espectrogramas da STGT, da GT e da WVD não conseguem detectar o evento. Já a ST o detecta, mas sem identificar de forma clara o instante de ocorrência do curto, devido ao espalhamento temporal. Na análise deste sinal destacam-se a STGT₂, a STGT-Her e a STGT₂-Her, que salientam claramente a descontinuidade no sinal.

O sinal I_4 , na Fig. 2.9 (a), é o traço de um eletrocardiograma (ECG), sinal que descreve a variação temporal da atividade elétrica produzida pelo coração. Ele foi obtido do banco de dados da Physikalisch Technische Bundesanstalt [119], que é o instituto alemão de pesos e medidas. O banco armazena dados de ECG de diversos pacientes, que

Figura 2.7: Comparação Espectral Sinal I_3 .

Figura 2.8: Comparação Espectral Sinal I_3 .

podem ser exportados como matriz de dados para o software *Matlab*. O espectro da FFT do sinal, apresentado na Fig. 2.9 (b), mostra que este possui componentes dominantes nas baixas frequências, o que é característico dos sinais de ECG. As variações no sinal associadas a impulsos ocorridos aproximadamente nos instantes $t = 75$, $t = 300$ e $t = 580$ são identificadas de forma mais precisa pelos espectrogramas das STGTs do que naqueles da GT, da WVD e da ST. Um destaque aqui para a STGT e a STFT-Her, que identificam as componentes de frequência aparecidas entre os impulsos, o que não se dá com as outras abordagens.

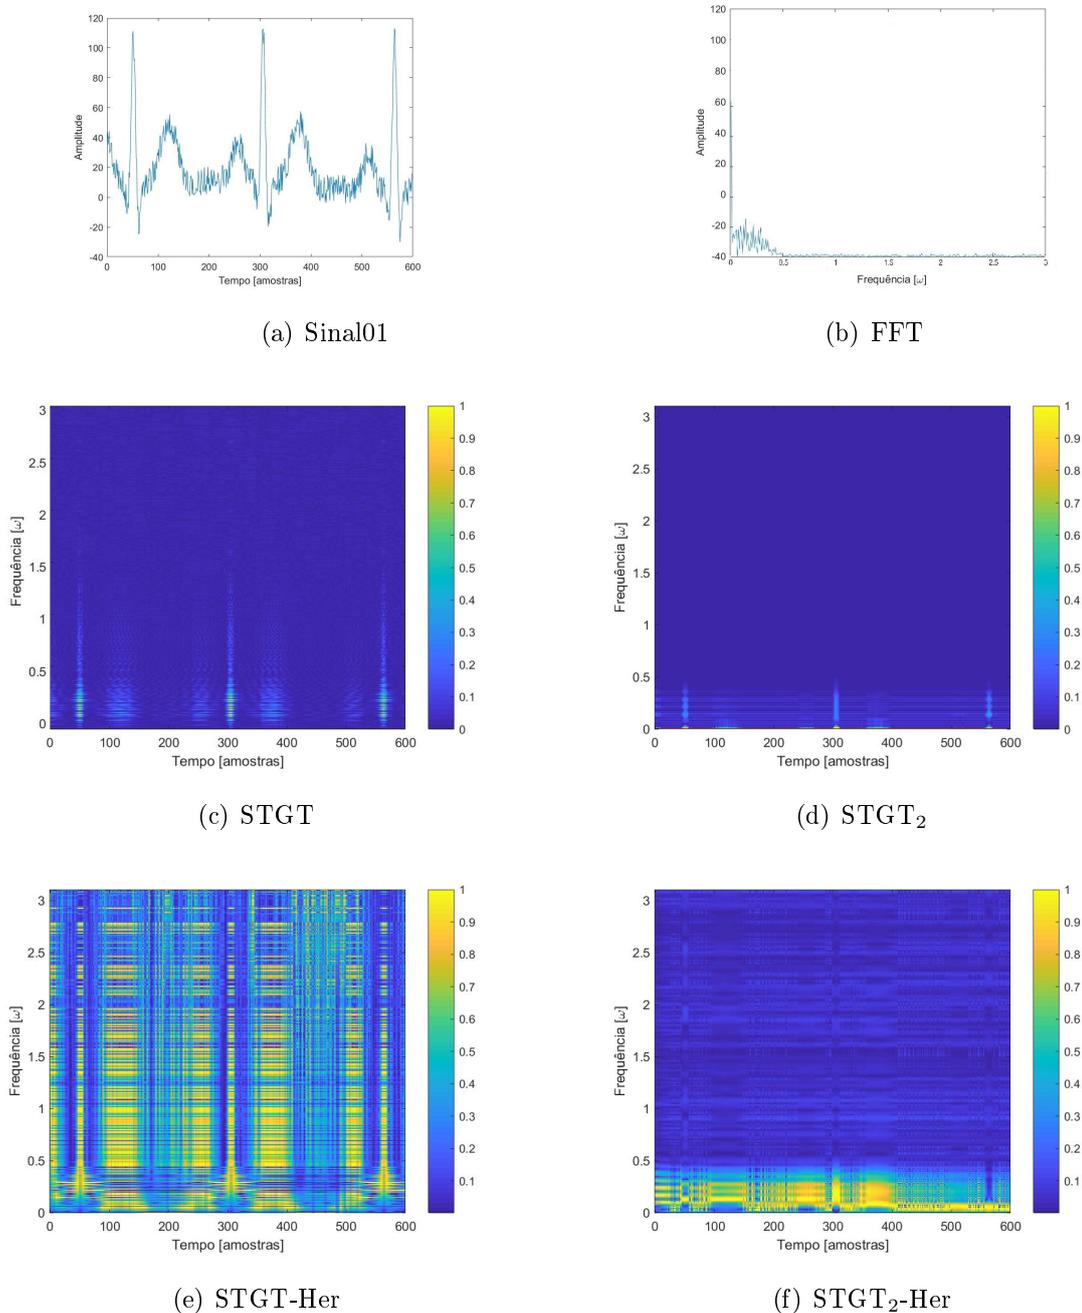


Figura 2.9: Comparação Espectral Sinal I_4 .

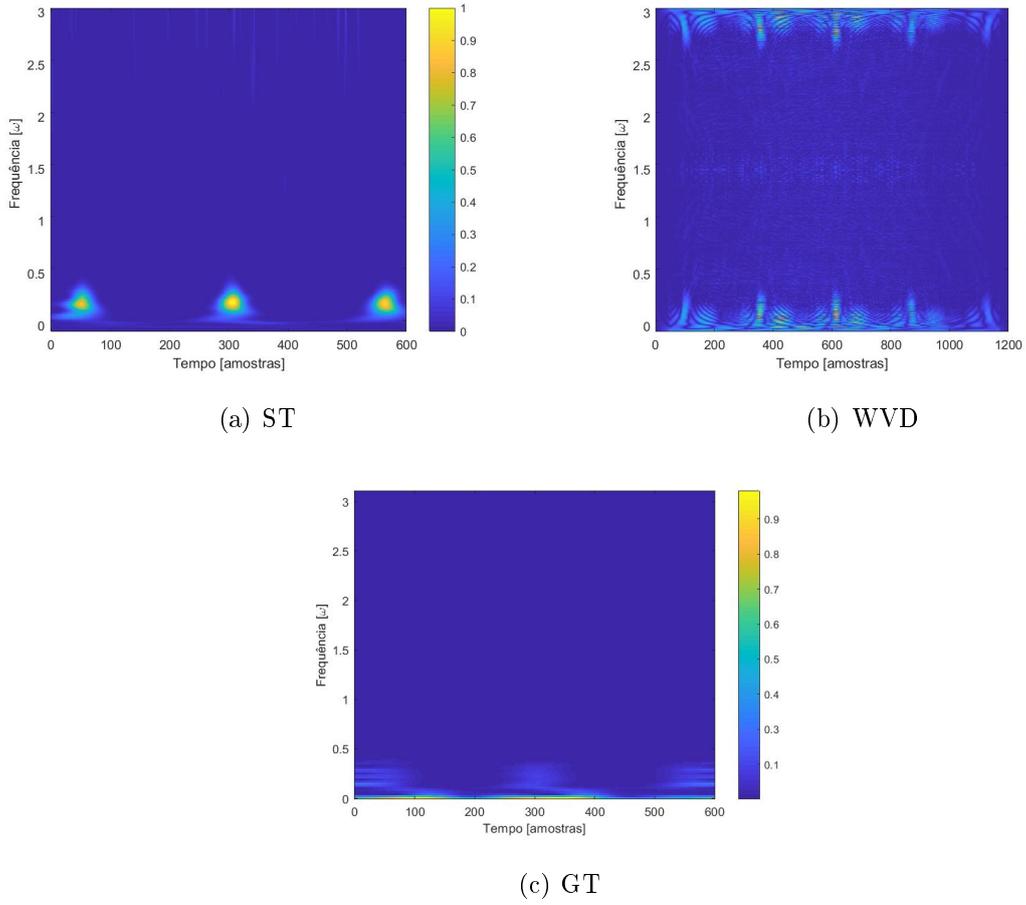


Figura 2.10: Comparação Espectral Sinal I_4 .

A seguir analisou-se o *signal* I_5 da figura 2.11 (a), obtido da referência [171]. O sinal é constituído por dois chirps cruzados e dois bursts de alta frequência, e a sua definição analítica é dada pela equação abaixo,

$$\begin{cases} I_5(t) = \cos[2\pi(10 + t/7)t/256] + \cos[2\pi(256/2.8 - t/6)t/256], & \text{para } t \in [0, 255] \\ I_5(t) = I_5(t) + \cos[2\pi(0, 42t)], & \text{para } t \in [114, 122] \text{ e para } t \in [134, 142]. \end{cases} \quad (2.55)$$

Ao compararmos os espectrogramas apresentados nas Figs. 2.11 e 2.12, vemos que a STGT-Her e a ST, representadas nas Figs. 2.11 (e) e 2.12 (a), respectivamente, identificam da forma mais clara os dois chirps e os dois bursts. Observe-se como a STGT-Her, e também a STGT, separam bem as duas componentes de alta frequência devidas aos bursts, que a ST não consegue distinguir. Na STGT-Her, fica evidente um ligeiro espalhamento nas altas frequências (semelhante ao que se registra com a ST), que resulta do fato de que esta transformada analisa o sinal por meio das funções de codificação das suas derivadas. Devido à presença de variações muito drásticas na amplitude das frequências, como se vê

na FFT do sinal, Fig. 2.11 (b), os espectrogramas das STGTs – Figs. 2.11(c),(d),(e) e (f) – apresentam-se com um aspecto "recortado". Isto se deve à característica das STGTs de serem fiéis às variações temporais e espectrais do sinal. Conforme demonstrado em [171], uma simples suavização da amplitude da FFT permite obter espectrogramas mais limpos com as STGTs, sem prejudicar as suas características gerais. Por outro lado, os espectrogramas das Figs. 2.12 (b) e (c) demonstram que a WVD e a GT não são adequadas para a representação deste tipo de sinais.

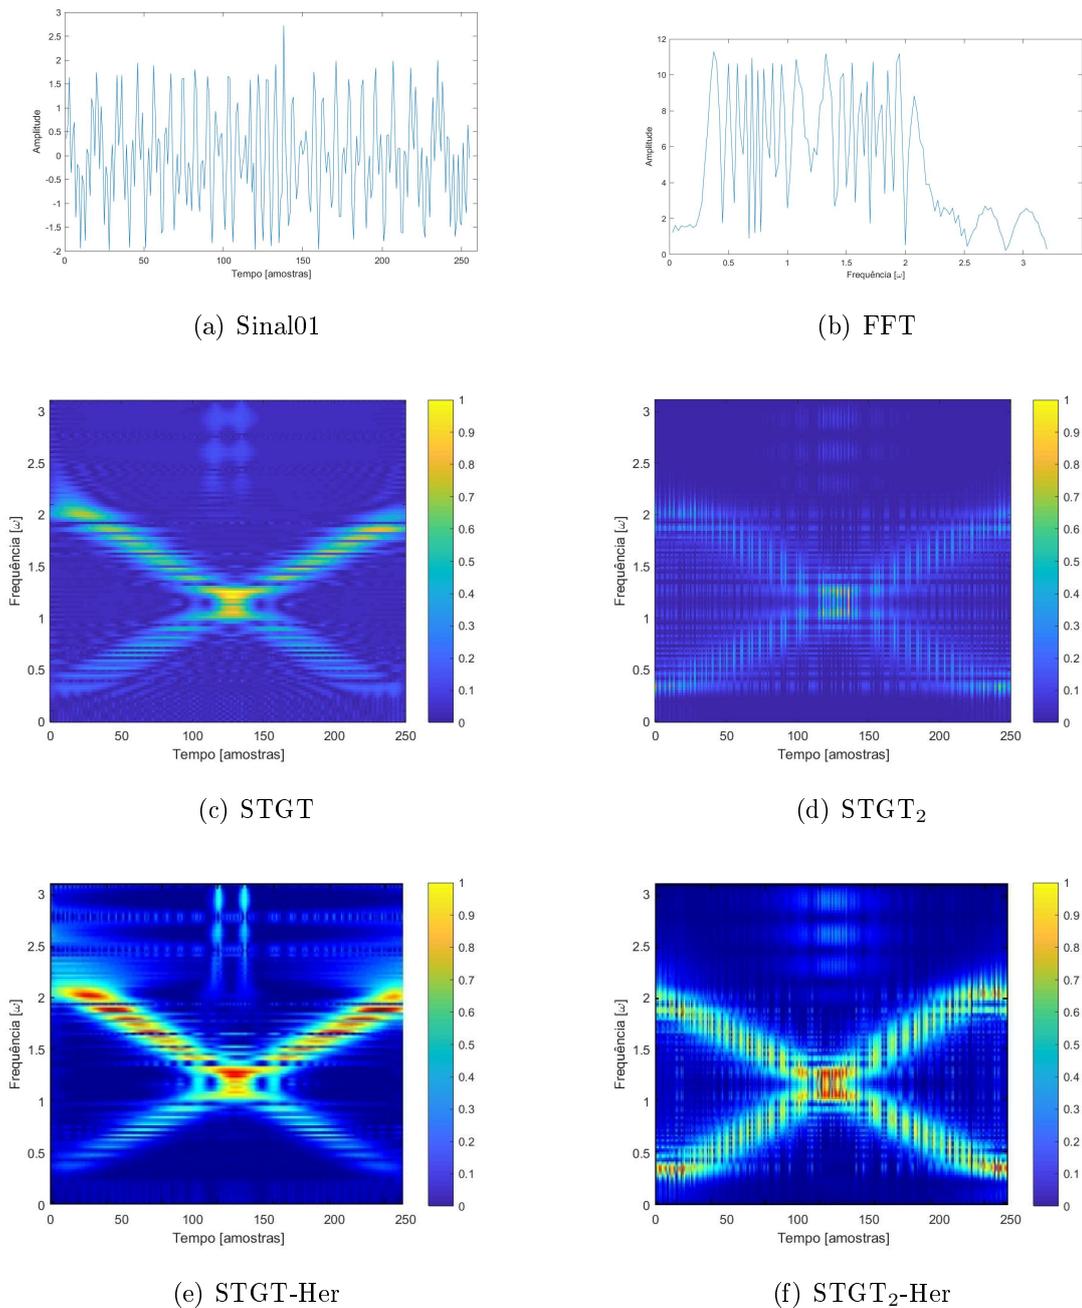


Figura 2.11: Comparação Espectral Sinal I_5 .

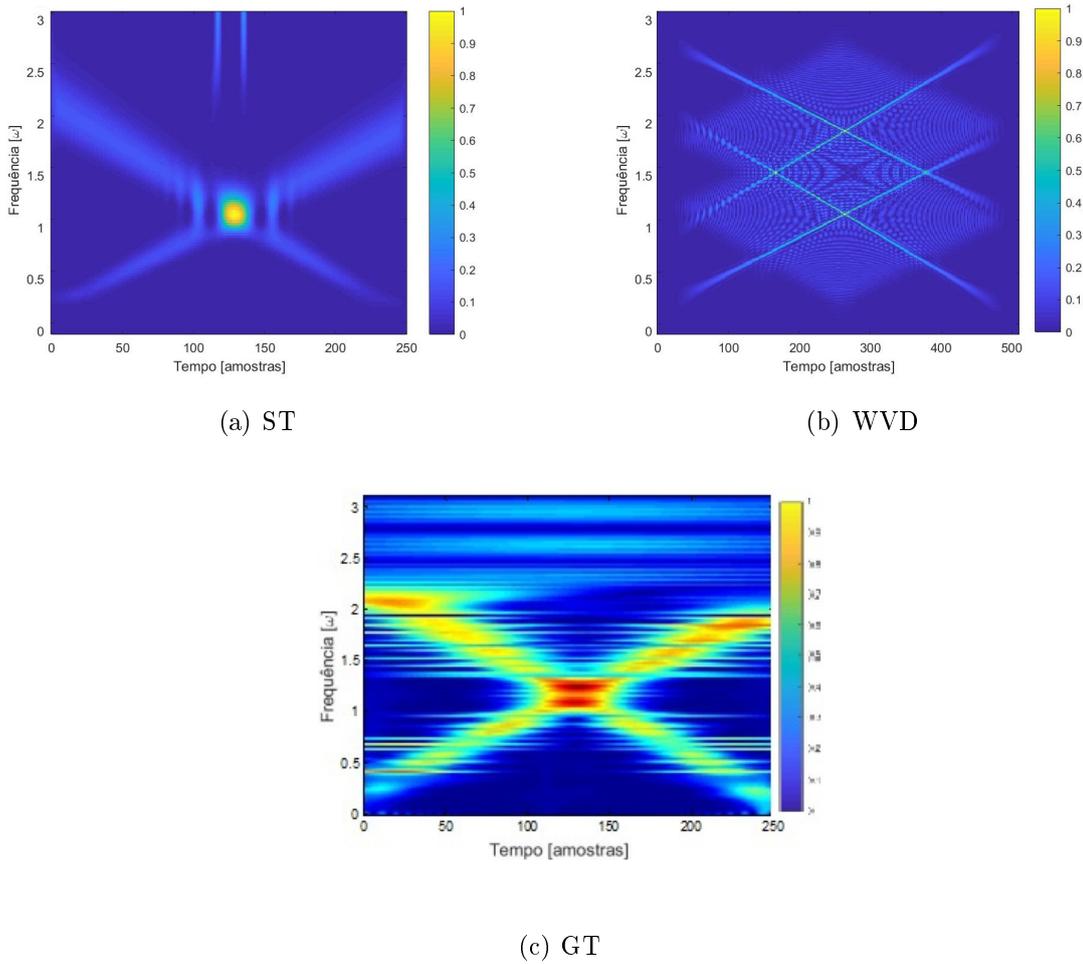
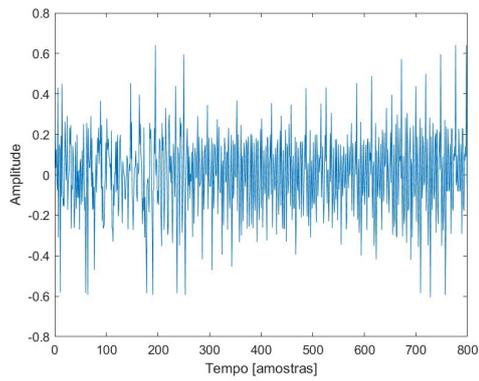
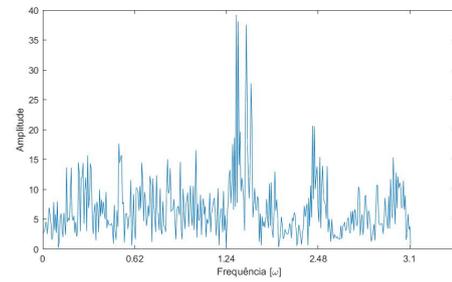


Figura 2.12: Comparação Espectral Sinal I_5 .

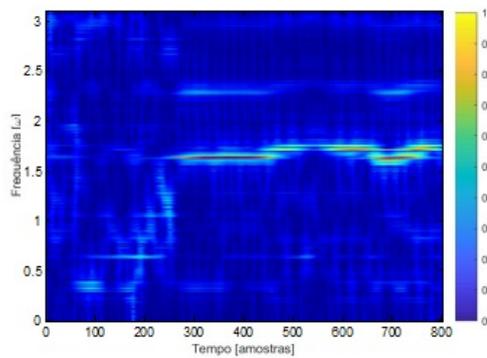
A seguir, apresentamos a análise comparativa das transformadas aplicadas a um traço eletroencefalográfico (EEG). O *signal* I_6 da Fig. 2.13 (a) é um segmento obtido da Ref. [163]. Os espectrogramas das STGTs, Figs. 2.13 (c),(d),(e) e (f), são os mais fiéis ao conteúdo espectral do sinal, conforme indicado pela sua FFT, na Fig. 2.13 (b). Pode-se observar a ótima resolução em frequência e a boa resolução temporal proporcionadas pelas transformadas sintonizadas, em especial a STGT e a STGT-Her. Por outro lado, como demonstra a Fig. 2.14 (a), a ST, embora apresente resolução temporal excelente, perde completamente a resolução em frequência, não permitindo identificar com precisão as faixas importantes de frequência em cada intervalo de tempo, que são fundamentais, por exemplo, para identificar situações de crise epiléptica [163]. Os espectrogramas obtidos com a GT e a WVD, Figs. 2.14 (b),(c), apresentam resolução tempo-frequência inferior à das abordagens sintonizadas.



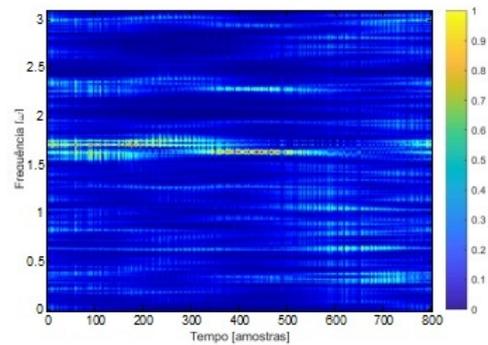
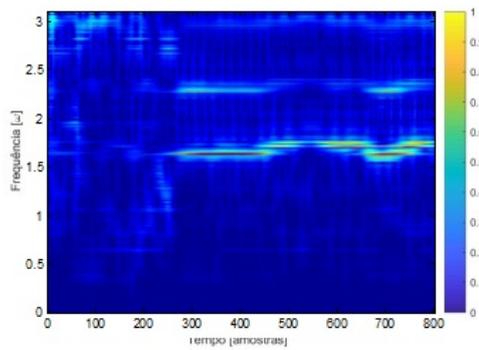
(a) Sinal01



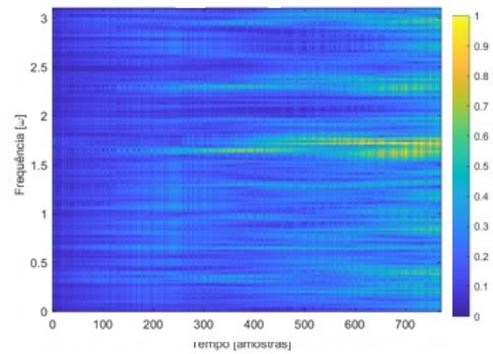
(b) FFT



(c) STGT

(d) STGT₂

(e) STGT-Her

(f) STGT₂-HerFigura 2.13: Comparação Espectral Sinal I_6 .

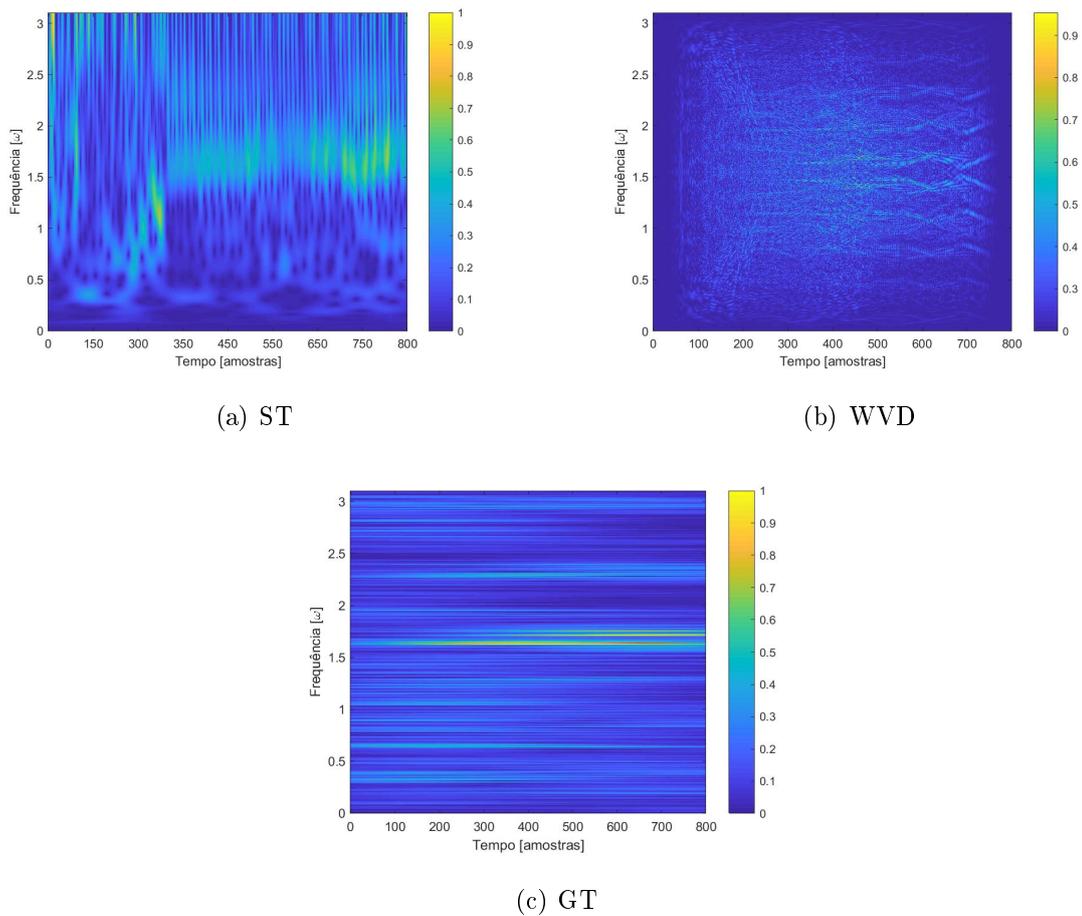


Figura 2.14: Comparação Espectral Sinal I_6 .

2.6 Considerações Finais

Aqui nós apresentamos a formulação matemática de três abordagens tempo-frequência tradicionais – as transformadas de Gabor, S , e de Wigner –, e também da abordagem sintonizada de Gabor em suas versões temporal e espectral – STGT e STGT₂. Foram ainda consideradas duas propostas recentes de extensão da abordagem sintonizada, uma baseada na incorporação dos polinômios de Hermite às funções analisadoras, e uma baseada na transformada de Fourier fracionária como generalização da transformada de Fourier tradicional. Além disso, nós introduzimos uma variante da transformada sintonizada de Gabor temporal a STGT _{ω_0} , que pode ser vantajosa em aplicações a sistemas elétricos de potência, pois os sinais possuem um valor de frequência constante (50 ou 60 Hertz).

A principal característica da abordagem sintonizada de Gabor é a análise de cada sinal por meio das funções de representação do próprio sinal, o que confere às transformadas sintonizadas STGT e STGT₂ propriedades semelhantes às da transformada de Wigner –

porém sem os inconvenientes termos cruzados associados a esta. Por outro lado, como a largura das funções analisadoras depende da frequência, essas transformadas também guardam semelhança com a transformada S , e portanto com as abordagens baseadas em wavelets. Com a incorporação das funções de Hermite aos núcleos de Gabor da STGT e da STGT₂, a abordagem sintonizada passa a utilizar funções analisadoras que correspondem a funções de codificação das derivadas — em qualquer ordem inteira — do sinal analisado. Isto confere a esta abordagem uma flexibilidade que se mostra bastante vantajosa em certas situações, como demonstrado aqui pela inspeção visual das representações tempo-frequência (espectrogramas) obtidas para diferentes classes de sinais. Por exemplo, a abordagem baseada na transformada STGT-Her, que incorpora um fator de Hermite à STGT, mostrou-se vantajosa na detecção de mudanças bruscas, como ilustrado nos casos dos sinais associados a curtos-circuitos em sistemas elétricos, ECGs e EEGs.

No próximo capítulo, nós trataremos, de forma mais aprofundada, da aplicação da abordagem sintonizada aos problemas da análise e da classificação de distúrbios em sistemas elétricos de potência.

Capítulo 3

Sobre os Distúrbios dos SEP e os Classificadores

3.1 Considerações Iniciais

Ao analisar os distúrbios que afetam a QEE, é importante verificar quais são as condições ideais de operação do sistema elétrico, e adotar critérios para comparar as condições reais de operação com as características de um sistema ideal. Num sistema elétrico em condições ideais observam-se, por exemplo, tensões e correntes senoidais com amplitudes constantes nos valores nominais, e frequência constante no valor síncrono. Em um sistema elétrico real, no entanto, estas condições não são sempre verificadas. Em uma rede elétrica real, os equipamentos elétricos estão sempre sujeitos a falhas ou perturbações que influenciam as condições de operação, e, por isso, um sistema de monitoramento de distúrbios é fundamental para a manutenção da qualidade da energia [45]. O comitê de estudos em QEE do IEEE (*IEEE 1159-1995*) distingue categorias específicas de distúrbios, conforme as suas características [72]. Na presente Tese, foram consideradas duas categorias de distúrbios, por serem eles frequentes no sistema elétrico e apresentarem características comuns a vários outros tipos de distúrbios. São estes: os distúrbios que afetam a amplitude do sinal de tensão — especificamente, *afundamentos de tensão* (Sags), *elevações de tensão* (Swells), e *interrupções momentâneas da tensão* (Interrupts) —, e os distúrbios que afetam a forma de onda do sinal de tensão - *harmônicos* (Harmonics), *oscilatórios transientes* (Transients), e *cortes na forma de onda* (Notches e Spikes) [72]. A seguir, nós detalhamos essas duas classes de distúrbios.

3.2 Tipos de Distúrbios dos SEP

3.2.1 Distúrbios da Amplitude do Sinal: *Sags*, *Swells* e *Interrupts*

Tais distúrbios são caracterizados por mudanças súbitas e breves na amplitude da forma de onda, que não afetam a sua frequência fundamental, ω_0 . Eles são modelados matematicamente pelas equações paramétricas abaixo, onde $u(t)$ representa a função degrau unitário. O início e o término da perturbação ocorrem nos instantes t_1 e t_2 , escolhidos de forma que $T \leq t_2 - t_1 \leq 6T$, onde T é o período da forma de onda. O parâmetro A representa a amplitude do distúrbio, que varia no intervalo $[0,1,0,9]$, para os *Sags* e *Swells*, e no intervalo $[0,9,1]$, no caso dos *Interrupts*.

Sags:

$$v(t) = \{1 - A[u(t - t_1) - u(t - t_2)]\} \sin(\omega_0 t) \quad (3.1)$$

Swells:

$$v(t) = \{1 + A[u(t - t_1) - u(t - t_2)]\} \sin(\omega_0 t) \quad (3.2)$$

Interrupts:

$$v(t) = \{1 - A[u(t - t_1) - u(t - t_2)]\} \sin(\omega_0 t) \quad (3.3)$$

Um distúrbio do tipo *Interrupt* equivale, portanto, a um do tipo *Sag* em que a amplitude cai para menos de 0,1 p.u. A figura 3.1 traz exemplos dos distúrbios que afetam a amplitude do sinal.

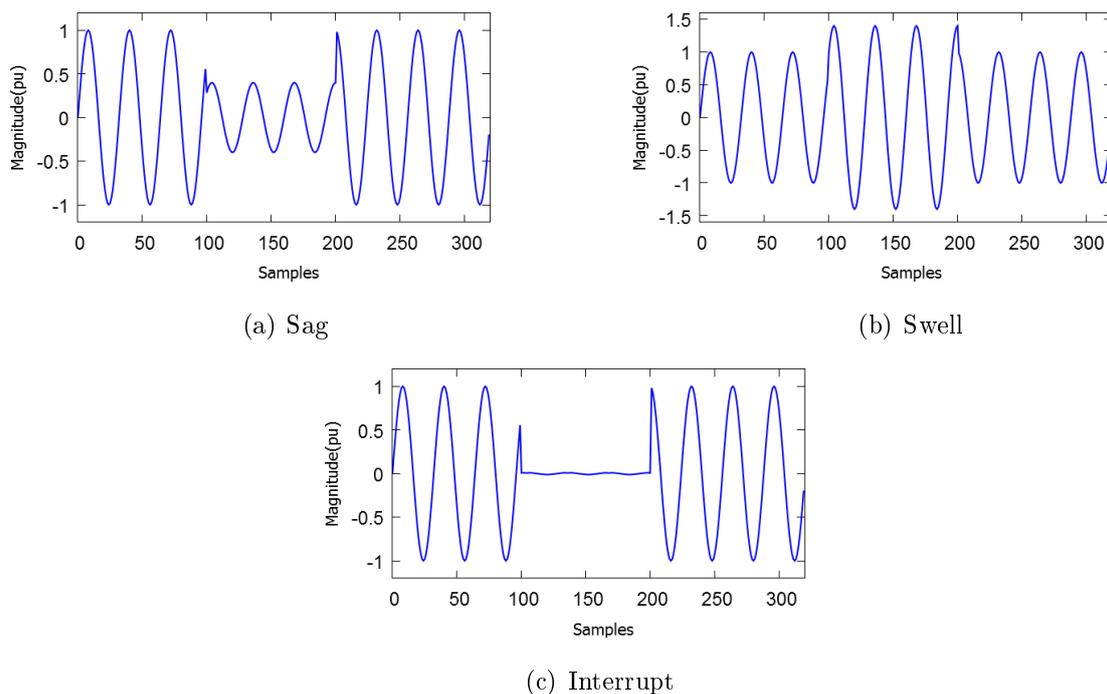


Figura 3.1: Distúrbios que afetam a amplitude do sinal

3.2.2 Distúrbios da Forma de Onda do Sinal: *Harmonics*, *Transients*, *Spikes* e *Notches*

Tais perturbações geram frequências espúrias, que interferem na forma de onda original: no caso dos *Harmonics*, aparecem componentes em múltiplos inteiros de ω_0 ; os distúrbios tipo *Transients* envolvem oscilações breves de alta frequência, enquanto os *Notches* e os *Spikes* são perturbações periódicas que também afetam o conteúdo espectral do sinal. Os instantes t_1 e t_2 , para os distúrbios do tipo *Transient*, foram escolhidos de forma que $0,5T \leq t_2 - t_1 \leq 3T$, enquanto que para os *Notches* e os *Spikes* eles satisfazem $0,01T \leq t_2 - t_1 \leq 0,05T$. As equações paramétricas são:

Harmonics:

$$v(t) = \sin(\omega_0 t) + A_3 \sin(3\omega_0 t) + A_5 \sin(5\omega_0 t) + A_7 \sin(7\omega_0 t) \quad (3.4)$$

onde A_3 , A_5 , e A_7 variam em $[0,02, 1]$.

Transients:

$$v(t) = \sin(\omega_0 t) + Ae^{-c(t-t_1)} \sin(\alpha\omega_0 t)[u(t-t_1) - u(t-t_2)] \quad (3.5)$$

onde os parâmetros A , α e c possuem intervalos de variação $[0,1,0,8]$, $[10,15]$, e $[5,10]$, respectivamente.

Notches e Spikes:

$$v(t) = \sin(\omega_0 t) \pm \text{sgn}(\sin(\omega_0 t)) \times \sum_{i=0}^9 A \{u(t - [t_1 + i \cdot 0,02]) - u(t - [t_2 + i \cdot 0,02])\} \quad (3.6)$$

onde A possui intervalo de variação $[0,1,0,4]$, e onde $\text{sgn}(\cdot)$ denota a função *signum*, que retorna o sinal do seu argumento. A equação com o sinal positivo em frente à *signum* corresponde ao distúrbio tipo *Spikes*, enquanto o negativo corresponde ao *Notches*. A figura 3.2 traz exemplos dos distúrbios que afetam a frequência do sinal.

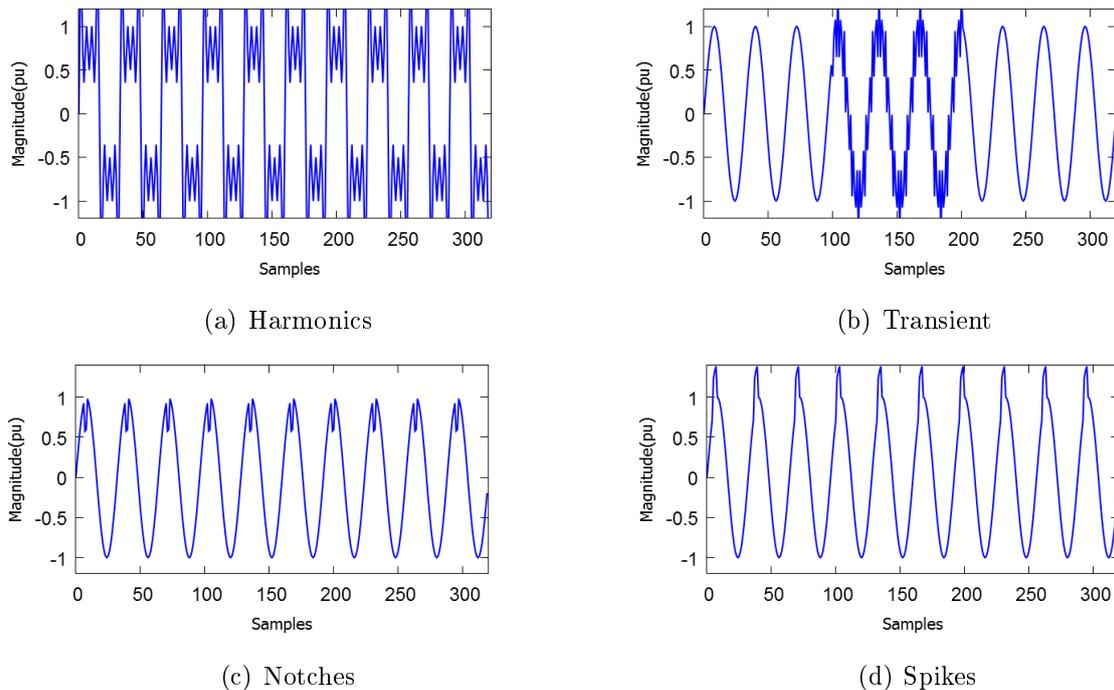


Figura 3.2: Distúrbios que afetam a frequência do sinal

3.2.3 Distúrbios: Causas, Efeitos e Soluções

Ao analisar os distúrbios que afetam a QEE, é importante verificar quais são as condições ideais de operação de um SEP, que se tornam o critério para avaliar a QEE em um sistema real. Para um sistema elétrico em condições ideais tem-se: tensões e correntes alternadas com formas senoidais, amplitudes constantes nos valores nominais, frequência constante no valor síncrono, tensões trifásicas equilibradas, fator de potência unitário nas cargas, e

perdas nulas na transmissão e distribuição [50]. Em um sistema elétrico real, no entanto, estas características ideais não são possíveis de satisfazer em sua totalidade. Em uma rede elétrica real existem equipamentos elétricos os quais estão sempre sujeitos a falhas ou perturbações que influenciam nas condições ideais desejáveis para a operação. Por isso, um sistema de monitoração e classificação de distúrbios que permita a implementação de eventuais soluções é fundamental para se obter um sistema elétrico com qualidade de energia. Os tópicos abaixo descrevem as causas e os efeitos da ocorrência de distúrbios no SEP. Estas informações são importantes para prover soluções visando minimizar ou eliminar tais distúrbios [50].

- **Distúrbio:** Sag / Swell
Causa: Partida de grandes equipamentos, curto-circuitos, falha em equipamentos ou manobras da concessionária.
Efeitos: Perda de dados e erros de processamento de computadores, desligamento de equipamentos, oscilações em motores com redução de vida útil.
Soluções: Nobreak, reguladores de tensão.
- **Distúrbio:** Interrupções
Causa: Curto-circuitos, descargas atmosféricas, e outros acidentes que exijam manobras precisas de fusíveis, disjuntores, etc.
Efeitos: Queda do sistema, danificação de componentes, perda de produção.
Soluções: Nobreak, geradores de emergência (para interrupções de longa duração).
- **Distúrbio:** Oscilações Transientes
Causa: Descargas atmosféricas, manobras da concessionária, manobras de grandes cargas e bancos de capacitores.
Efeitos: Travamento, perda de memória e erros de processamento em computadores, queima de placas eletrônicas, danificação de materiais de isolamento e de equipamentos.
Soluções: Supressores de transientes, nobreak com supressores de transientes, transformadores de isolamento.
- **Distúrbio:** Harmônicos
Causa: Reatores eletrônicos, inversores de frequência, retificadores e outras cargas não lineares.
Efeitos: Sobreaquecimento de cabos e equipamentos, diminuição da performance de motores, operação errônea de disjuntores, relés e fusíveis.

Soluções: Filtros de harmônicos, reatores de linha, melhorias na fiação e no aterramento, transformadores de isolação.

- **Distúrbio:** Spikes / Notches

Causa: Equipamentos eletrônicos de potência, cargas não lineares.

Efeitos: Erros de processamento em computadores, queima de placas eletrônicas, recepções distorcidas (áudio e vídeo).

Soluções: Filtros de linha, transformadores de isolação.

3.3 Classificação dos Distúrbios

Para a classificação dos distúrbios a partir dos espectrogramas gerados pelas diversas abordagens TF, foram empregados quatro diferentes tipos de classificadores, baseados em Similaridade, Redes Neurais Artificiais (ANN), Máquinas de Vetores de Suporte (SVM), e Árvores de Decisão (DT). A metodologia seguida pelos três últimos é semelhante, abrangendo as etapas descritas a seguir. A estratégia de classificação por Similaridade é ligeiramente distinta, e será apresentada no final do capítulo.

Para a classificação por ANN, SVM e DT, nós seguimos uma metodologia abrangendo três etapas. Na primeira etapa, aplicam-se as transformadas TF (STGTs, ST, GT e WVD) aos sinais com os distúrbios a serem classificados, gerando-se desta forma as Matrizes TF. A segunda etapa consiste na extração de nove atributos de cada matriz TF gerada, a serem utilizados como entrada para os classificadores. Na última etapa, de posse dos vetores de atributos, são aplicados os algoritmos de classificação para obtenção do resultado final, que é o reconhecimento dos tipos de distúrbio que afetam os sinais de entrada. Esta metodologia encontra-se representada no fluxograma da Fig. 3.3.¹

¹Por simplicidade, a classificação por Similaridade também é incluída na figura

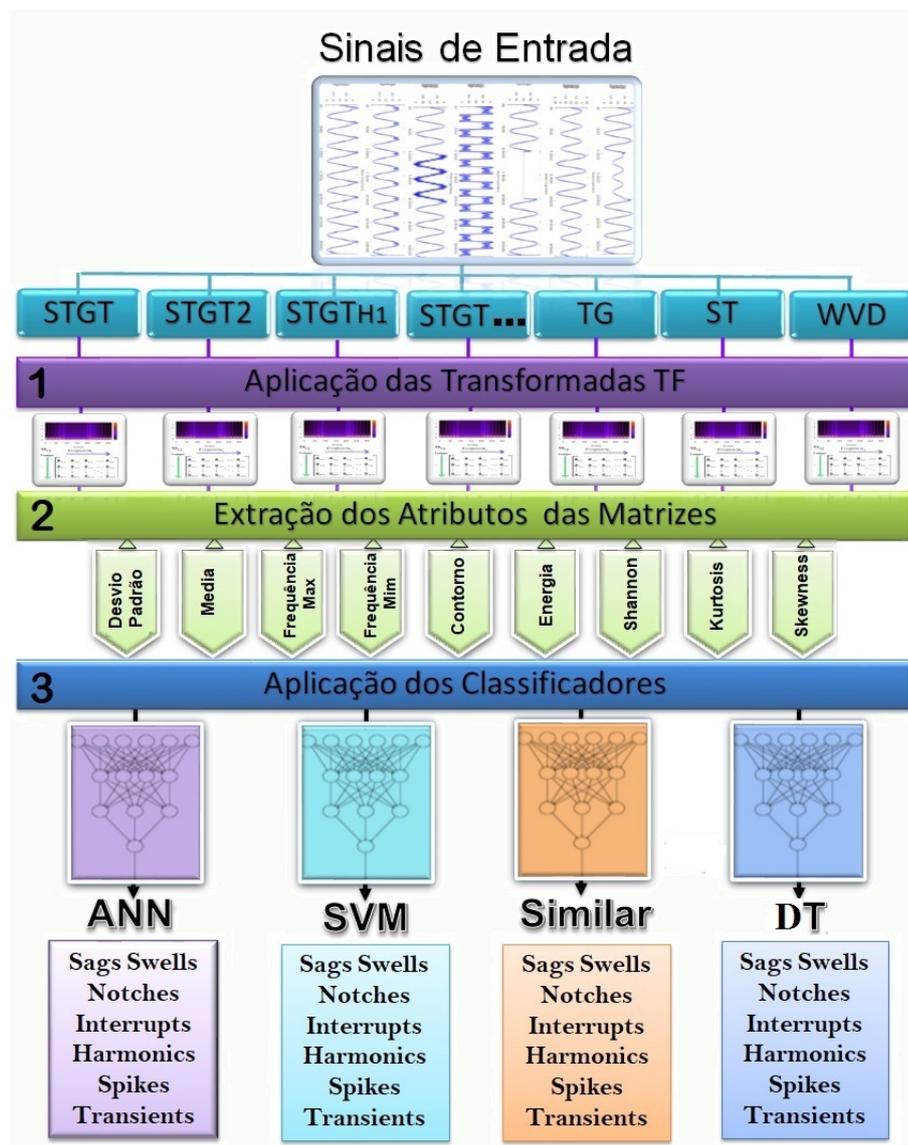


Figura 3.3: Representação da Metodologia de Classificação utilizada.

3.3.1 Classificação por Redes Neurais Artificiais

As redes neurais artificiais (ANN - Artificial Neural Networks) são sistemas paralelamente distribuídos compostos por unidades simples de processamento denominadas de neurônios artificiais [28]. A Fig. 3.4 exibe o modelo de um neurônio artificial, que consiste em uma estrutura lógico-matemática que procura simular, simplificada, a forma, o comportamento e as funções de um neurônio biológico. Assim, os dendritos do neurônio biológico são substituídos por entradas, cujas ligações com o corpo celular artificial se realizam através de elementos chamados de pesos sinápticos (simulando as sinapses biológicas).

Cada sinal de entrada, X_i , é multiplicado pelo peso sináptico W_i , e repassado ao

neurônio. A este está associado um valor fixo, diferente de zero, denominado limiar de ativação. A resposta do neurônio é obtida computando-se a combinação linear dos sinais de entrada, $X_1.W_1 + X_2.W_2 + \dots + X_n.W_n$, e subtraindo-se o limiar de ativação, θ . Isto resulta no potencial de ativação, u , que, avaliado por meio da função de ativação g , resulta no sinal de saída do neurônio (ver a Eq. 3.7). A função de ativação pode assumir diferentes formas. As mais conhecidas são: função linear, função sigmoide e função exponencial [28] [34].

$$y = g(u), \text{ para } u = \sum_{i=1}^N W_i.X_i - \theta \quad (3.7)$$

Numa ANN, os neurônios são dispostos em uma ou mais camadas, e interligados pelos pesos sinápticos, como na Fig. 3.5, que ilustra um Multi-Layer Perceptron (MLP), o tipo de ANN utilizado no presente trabalho. Este consiste em um conjunto de nós fontes, formando a camada de entrada, uma ou mais camadas escondidas, e uma camada de saída [34][93]. Cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características, seus pesos incorporando uma codificação dos atributos dos padrões de entrada. No treinamento, um conjunto de exemplos é apresentado para a rede, que ajusta os seus pesos sinápticos de forma iterativa até que ela extraia as características necessárias para representar as informações fornecidas. Os pesos são inicializados com valores pseudo-aleatórios, e são alterados em uma direção que irá reduzir o erro na classificação. Posteriormente, estes pesos são fixados e utilizados para gerar soluções para novos padrões fornecidos como entrada [34][71].

Para o treinamento, podem ser utilizados diferentes algoritmos, que diferem basicamente pelo modo como é realizado o ajuste dos pesos. Os algoritmos de treinamento dividem-se em dois tipos: os de aprendizado supervisionado e os de aprendizado não-supervisionado. No aprendizado não-supervisionado são fornecidos à rede somente valores de entrada, que são organizados em diferentes classes de acordo com a semelhança de suas propriedades, por meio do ajuste dos pesos da rede. No treinamento supervisionado, existe um supervisor externo que fornece à rede tanto os valores de entrada disponíveis quanto os valores de saída esperados [71].

No nosso trabalho, foi empregado um MLP com três camadas de neurônios de função de ativação degrau, e um algoritmo de aprendizado supervisionado via retropropagação de erro (*backpropagation*) [28]. A camada de entrada recebe o vetor contendo as caracte-

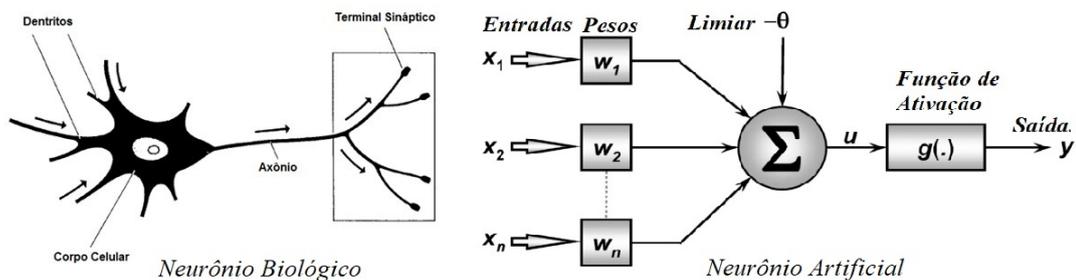


Figura 3.4: Estrutura neurônio biológico - neurônio Artificial.

rísticas (atributos) extraídos da matriz TF de cada sinal analisado, e o envia para a única camada oculta da rede, que por sua vez procede com o algoritmo de classificação.

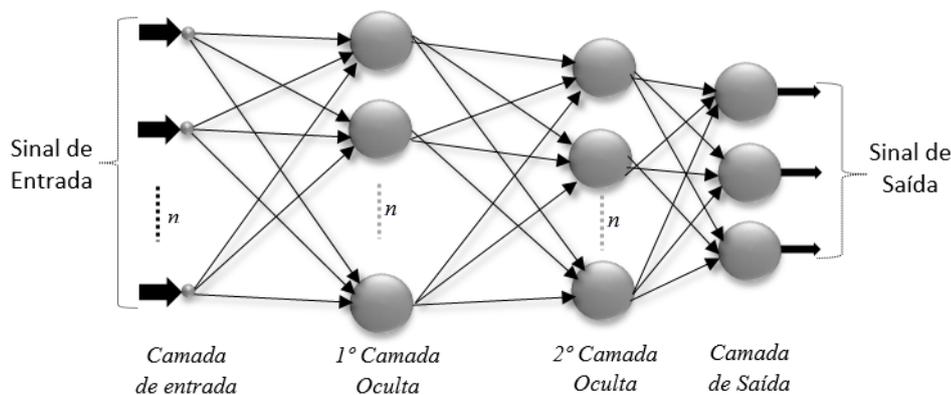


Figura 3.5: Estrutura Rede MLP.

3.3.2 Classificação por *Support Vector Machines*

Desenvolvidas por Vapnik [168] de forma conceitual, as *máquinas de vetores suporte*, do inglês Support Vector Machines (SVM), são uma técnica, fundamentada na teoria do aprendizado estatístico, que utiliza o aprendizado de máquina visando a maximização da capacidade de generalização e a minimização do risco estrutural. Em poucas palavras, a capacidade de generalização é a capacidade de a máquina computacional classificar de forma eficiente, dado o seu conjunto de treinamento, e o risco estrutural é a probabilidade de classificação errônea de padrões ainda não apresentados – ou seja, a probabilidade de erro de classificação, com novas classes propostas [61]. A ideia principal de uma SVM é construir um "hiperplano ótimo", como superfície de decisão, de tal forma que a margem de separação entre classes distintas seja máxima. Assim, o SVM consiste em um mapeamento – linear ou não-linear –, do vetor de dados de entrada, para um espaço de características de alta dimensionalidade (hiperplano ótimo), que é oculto da entrada e da

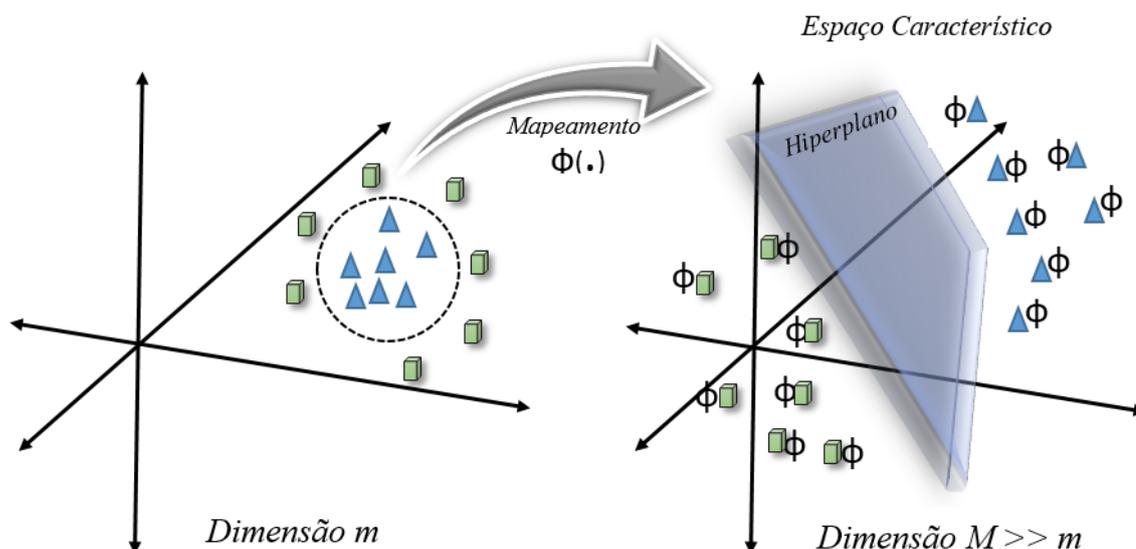


Figura 3.6: Representação do mapeamento para o espaço característico e a separação de dados através de um hiperplano.

saída.

A teoria que define os conceitos e a formulação matemática da função do hiperplano ótimo é a teoria de aprendizado estatístico [168], que visa dotar a máquina da capacidade de generalizar padrões ainda não apresentados. Para exemplificar, a Figura 3.6 ilustra a aplicação, sobre elementos inicialmente mapeados em um espaço de dimensão m , de uma função ϕ que os re-mapeia para um novo espaço de dimensão M , chamado de espaço de características [62] [168]. Observa-se que, no primeiro espaço, de dimensão m , os dados não podem ser separados por um hiperplano, mas no segundo espaço, de dimensão M , isto é possível. Em princípio, esta técnica pode ser implementada em dois passos, por dois algoritmos: no primeiro, um mapeamento não-linear, por meio de uma função ϕ escolhida a priori, mapeia os dados de entrada para um espaço característico, e depois, um segundo algoritmo define um hiperplano a ser utilizado como superfície de decisão, para classificar os dados neste novo espaço.

Para ilustrar a aplicação do hiperplano como superfície de decisão, considere um espaço de dados X , e uma amostra de treinamento dada por $[(x_i, d_i)]_{i=1}^N$, em que x_i é o padrão de entrada para o i -ésimo exemplo, e d_i é a resposta desejada correspondente (saída-classificada). Inicialmente, vamos assumir que o padrão (classe) representado pelo subconjunto $d_i = +1$ e o padrão representado pelo subconjunto $d_i = -1$ são linearmente separáveis [61]. A equação de uma superfície de decisão, na forma de um hiperplano, que realiza esta separação será:

$$f(\mathbf{x}) = \mathbf{w}^T \cdot x + b = 0 \quad (3.8)$$

onde $w^T \cdot x$ é o produto escalar entre os vetores w e x , sendo x um vetor de entrada que representa os padrões de treinamento, w é o vetor de pesos ajustáveis normal ao hiperplano, e b é um limiar, também conhecido como bias, de modo que $b/\|w\|$ corresponde à distância do hiperplano com relação à origem, com $b \in \Re$ [179][29]. A Figura 3.7 representa este hiperplano de separação para um conjunto de treinamento bidimensional.

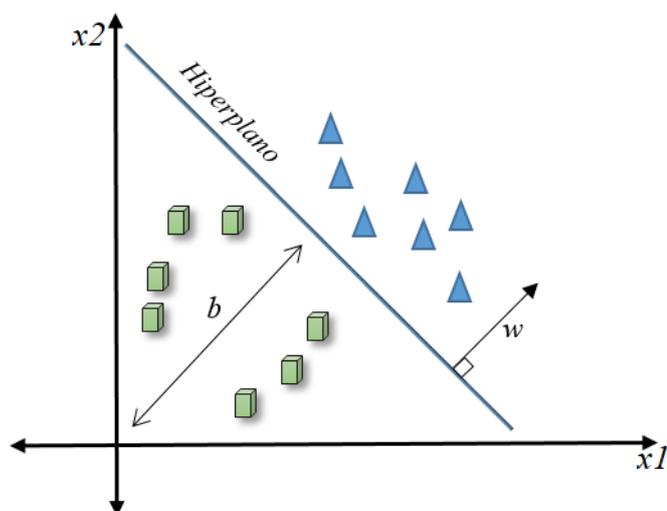


Figura 3.7: Representação de um hiperplano de separação

A função $f(x)$, na Equação (3.8), divide o espaço de dados, X , em duas regiões: $w^T \cdot x + b > 0$ e $w^T \cdot x + b < 0$. Uma função sinal, $g(x) = \text{sgn}(f(x))$, pode então ser empregada na obtenção das classificações, pois ela permite definir um número infinito de hiperplanos equivalentes, como

$$g(x) = \text{sgn}(f(x)) = \begin{cases} d_i = +1, & \text{se } w^T \cdot x + b > 0, \\ d_i = -1, & \text{se } w^T \cdot x + b < 0 \end{cases} \quad (3.9)$$

A distância entre o hiperplano definido na Equação (3.9) e o ponto de dados mais próximo é denominada de margem de separação, e é representada por ρ . O algoritmo de SVM tem por objetivo encontrar o *hiperplano ótimo*, que separe o conjunto de dados de treinamento sem erro e maximize a margem de separação, ρ . A Figura 3.8 ilustra a construção geométrica de um hiperplano ótimo para um espaço de entrada bidimensional, salientando-se a margem de separação máxima, ρ_o (a partir da qual, nós definimos $r \equiv \rho_o/2$), um hiperplano H_1 , definido por $w^T x + b = +1$, e outro hiperplano H_2 , definido por

$w^T x + b = -1$, onde se encontram os vetores de suporte (ver adiante). A distância entre os hiperplanos H_1 e H_2 é ρ_0 [61] [29].

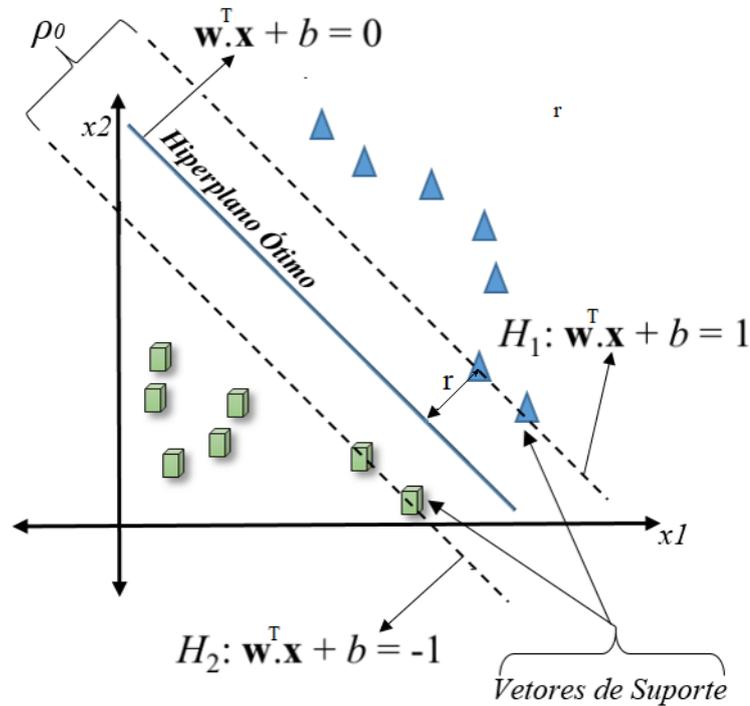


Figura 3.8: Representação SVM.

Considerando que w_o e b_o representam os valores ótimos do vetor peso e do bias, que determinam um valor ótimo para a margem de separação ρ_o , a Equação (3.8) para o hiperplano ótimo pode ser reescrita como $f(x_o) = w_o^T \cdot x_o + b_o = 0$. Sendo assim, um conjunto de treinamento é linearmente separável se w_o e b_o satisfizerem a restrição

$$g(x_i) = \text{sgn}(f(x_i)) = \begin{cases} d_i = +1, & \text{se } w_o^T \cdot x_i + b_o \geq +1, \\ d_i = -1, & \text{se } w_o^T \cdot x_i + b_o \leq -1 \end{cases} \quad (3.10)$$

e o problema a resolver passa a ser agora o de encontrar os parâmetros w_o e b_o para este hiperplano ótimo, dado um conjunto de treinamento $\{(x_i, d_i)\}$ [61]. Os pontos de dados particulares, (x_i, d_i) , onde temos $d_i = +1$ ou $d_i = -1$, concordante com a Eq. (3.9) que pode ser satisfeita com o sinal de igualdade, conforme já descrito (*hiperplano H_1 , definido por $w^T \cdot x + b = +1$, e hiperplano H_2 , definido por $w^T \cdot x + b = -1$*), são chamados de *vetores de suporte*, e representam as amostras do conjunto de treinamento que definem um hiperplano ótimo de separação entre as classes (ver Fig. 3.8). São esses pontos que influenciam diretamente na localização do hiperplano ótimo, de máxima margem, pois são os pontos mais próximos da superfície de decisão [158] [167] [61].

Considerando agora um vetor de suporte $x^{(s)}$ de classe positiva, para o qual $d^{(s)} = +1$, então, por definição, a partir de $w^T \cdot x + b = +1$ teremos para este vetor:

$$g(x^{(s)}) = w_o^T \cdot x^{(s)} + b_o - 1 = 0, \text{ para } d_i = +1 \quad (3.11)$$

Após o cálculo dos vetores de suporte, por definição podemos calcular a distância r do vetores de suporte até o hiperplano ótimo, sendo $r = g(x)/\|w_o\|$ (ver Fig. 3.8), assim sendo, temos:

$$r = \frac{w_o^T x^{(s)} + b_o}{\|w_o\|} = \begin{cases} \frac{+1}{\|w_o\|}, & \text{se } d^s = +1 \\ \frac{-1}{\|w_o\|}, & \text{se } d^s = -1 \end{cases} \quad (3.12)$$

onde o sinal positivo indica que $x^{(s)}$ pertence ao lado positivo do hiperplano ótimo, e o sinal negativo indica o oposto. Conforme a Equação (3.12), pode-se concluir que a distância entre os hiperplanos H_1 e H_2 , da Fig. 3.8, é dada por $\rho = 2r = 2/\|w_o\|$, e a distância entre o hiperplano ótimo e H_1 ou H_2 é dada por $1/\|w_o\|$.

Assim, a minimização da norma Euclideana do vetor dos pesos $\|w\|$ leva à maximização da margem, que é um dos objetivos do SVM [158] [167] [61]. Isto nos leva ao problema clássico da minimização da função-custo

$$J(w, b, \alpha) = \frac{1}{2}\|w\|^2 - \sum_{i=1}^N \alpha_i (d_i (w^T x + b) - 1) \quad (3.13)$$

onde os α_i são *multiplicadores de Lagrange* não-negativos. A solução desse problema pode ser obtida com o emprego de técnicas conhecidas de otimização [61] [158], envolvendo:

- i) a minimização da Equação (3.13) com relação a w e b ,
- ii) a maximização dos α_i , com $\alpha_i > 0$,

A abordagem acima esboçada, válida para classes linearmente separáveis, pode ser estendida para o caso não-linear [62] [168]. No nosso trabalho, a técnica SVM supervisionada foi aplicada a um problema de classificação multi-classes (diferentes tipos de distúrbio), com o emprego de uma abordagem binária “um contra todos” (*one-versus-all*), o que reduz o problema multi-classe a um conjunto de dados binário, permitindo assim a utilização da abordagem básica do SVM [25] [61] [158].

3.3.3 Classificação por Árvore de Decisão - Decision Tree

Os classificadores baseados em árvore de decisão (*Decision Tree - DT*) procuram encontrar formas de dividir sucessivamente o domínio de interesse em vários subconjuntos, até que cada um deles contemple apenas uma classe, ou até que uma das classes demonstre uma clara maioria, não se justificando posteriores divisões (caso em que se gera uma *folha* contendo a classe majoritária). A árvore de decisão é estruturada hierarquicamente em um conjunto de *nós* interconectados, sendo que cada *nó* interno testa um atributo de entrada com base em uma constante de decisão, e determina qual será o próximo *nó* descendente. Já os *nós-folhas* classificam as instâncias que os atingem, de acordo com o rótulo associado a cada um deles [140]. O conhecimento, em uma árvore de decisão, é portanto representado por cada *nó*, que ao ser testado conduz a busca para um *nó* filho, até que se chegue a um *nó-folha*, como representado na Fig. 3.9 [23].

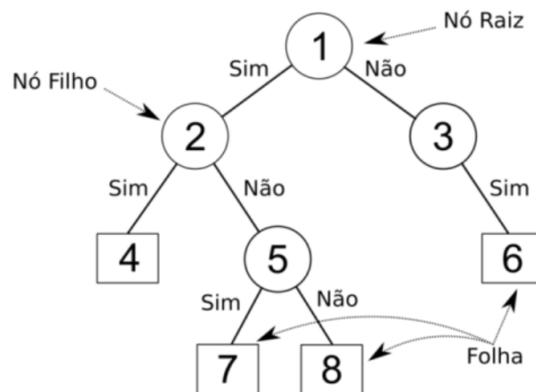


Figura 3.9: Representação de uma Árvore de Decisão.

Uma árvore de decisão é essencialmente uma série de declarações *if-then*, que, quando aplicadas a um registro de uma base de dados, resultam na classificação daquele registro. Para exemplificar, extraiu-se da Ref. [60] um algoritmo básico de árvore de decisão (ver Algoritmo 1), onde os parâmetros de entrada são:

- i) Partição de dados de treinamento D , que contém registros já rotulados, ou seja, com classes conhecidas.
- ii) Lista de atributos dos dados, ou seja, as características pertinentes a cada registro.
- iii) Um método (algoritmo) utilizado para determinar o *critério de divisão* que particiona os registros em classes individuais. O critério de divisão deve retornar o atributo

que melhor discrimina os dados de acordo com a classe.

Algoritmo 1 Algoritmo - Árvore de Decisão

Require: Entrada: \leftarrow Partição de dados D ; lista atributos; Método seleção atributo.

Saída: \rightarrow Uma árvore de decisão

Criar um nó N

se Registros em D são todas da mesma classe, C **então**

N como um nó folha rotulado com a classe C .

fim se

se lista atributos *está vazia*, C **então**

N como um nó folha rotulado com a classe majoritária em D .

fim se

Aplicar *Método seleção atributo* (D , lista atributos) para encontrar o *melhor critério de divisão*

rotular o nó N com o *critério de divisão*

se atributo divisão e discreto e divisão de múltiplos caminhos é permitida **então**

lista atributos \leftarrow lista atributos – atributo divisão // remove o atributo da lista

fim se

para saída j de critério divisão **faça**

seja D_j o conjunto de registros de dados em D que satisfazem a saída j // uma partição

se D_j está vazia **então**

anexar uma folha rotulada com a classe majoritária em D ao nó N

se não

anexar o nó retornado por *Gerador de árvore de decisão* (D_j , lista atributos) ao nó N ;

fim se

fim para

Retorne N

Verifica-se, pelo algoritmo, que a árvore inicia com um único nó, N , que representa todos os registros em D . Se todos os registros em D pertencerem à mesma classe, a ação é fazer de N uma folha rotulada com a classe em questão. Se a lista de atributos *está vazia*, não existem atributos sobrando para que os registros sejam particionados, então retorna-se N como nó-folha rotulado com a classe majoritária. Caso contrário, chama-se a função *Método seleção atributo*, para determinar o atributo que melhor particiona D em classes individuais. O nó N é então rotulado com o critério de divisão, e para cada saída do critério de divisão, um ramo é criado a partir de N , particionando D em subconjuntos. O algoritmo usa o mesmo processo recursivamente, para formar uma árvore de decisão para os registros de cada partição resultante de D [60] [30].

Vale ressaltar que, para a construção de uma árvore a partir de um grande conjunto de treinamento, utilizam-se algoritmos como os tradicionais $C4.5$ e $ID3$, os quais utilizam o critério *ganho de informação*, para escolher o melhor atributo a ser usado em cada nó,

e adota-se a estratégia de *pós-poda*, a fim de reduzir o tamanho da árvore [140] [85] [30].

Entre as principais vantagens do uso das árvores de decisão, se destaca a fácil interpretação dos seus resultados, pois a classificação é obtida de forma explícita, simplificando a sua interpretação. Além disso, os resultados geralmente são fornecidos rapidamente, devido à eficiência computacional característica desta técnica [140] [85] [30].

3.3.4 Seleção dos Atributos para Classificação

A seleção de atributos é um procedimento de otimização que busca pelo menor subconjunto capaz de proporcionar a melhor acurácia no processo de classificação, sendo, portanto, uma etapa primordial para o reconhecimento de padrões, de tal forma que o classificador apresentará uma baixa taxa de acertos se os atributos não forem bem escolhidos [139].

No contexto desta Tese, a seleção dos atributos foi realizada observando-se as características das matrizes TF tanto no domínio do tempo como o domínio da frequência. Na Tabela 3.1 tem-se a descrição de cada atributo considerado. Nas equações, o índice j corresponde às colunas da Matriz TF (referentes ao Tempo), e o índice i corresponde às suas linhas (referentes à Frequência). A Média, o Desvio Padrão, a Assimetria (*Skewness*), a Curtose e a Entropia, que são medidas estatísticas, referem-se a características da matriz TF no domínio do tempo (*ver Eqs. 3.14 até 3.18*); já o cálculo da Energia-Parseval, da Energia de contorno em 50Hz, e as Amplitudes Máxima e Mínima em Frequência referem-se a características obtidas no domínio da frequência (*ver Eqs. 3.19 até 3.22*) [20][23][131].

Tabela 3.1: Atributos

ID	Atributos	Expressão
AT1	Média	$\mu_i = \frac{1}{N} \sum_{j=1}^N M(i, j) \quad (3.14)$
AT2	Desvio Padrão	$\sigma_i = \sqrt{\frac{1}{N} \sum_{j=1}^N (M(i, j) - \mu_i)^2} \quad (3.15)$
AT3	Skewness	$\sigma_{skew} = \frac{1}{(N-1)\sigma^3} \sum_{j=1}^N (M(i, j) - \mu_i)^3 \quad (3.16)$
AT4	Curtose	$\sigma_{Kurt} = \frac{1}{(N-1)\sigma^4} \sum_{j=1}^N (M(i, j) - \mu_i)^4 \quad (3.17)$
AT5	Entropia	$Ent = \frac{1}{N} \sum_{j=1}^N \log(M(i, j))^2 \quad (3.18)$
AT6	Energia-Parseval	$Eng = \frac{1}{N} \sum_{j=1}^N (M(i, j))^T ^2 \quad (3.19)$
AT7	Energia em 50Hz	$Eng_{50Hz} = \frac{1}{N} \sum_{j=1}^N (M(i, j))^T ^2, para, i = 50Hz \quad (3.20)$
AT8	Amp Máx. de Frequência	$Amp_{max} = Max[\frac{1}{N} \sum_{j=1}^N M(i, j)] \quad (3.21)$
AT9	Amp Mín. de Frequência	$Amp_{min} = Mim[\frac{1}{N} \sum_{j=1}^N M(i, j)] \quad (3.22)$

3.3.5 Software de Classificação - WEKA

A suíte WEKA (*Waikato Environment for Knowledge Analysis*)² é formada por um conjunto de implementações de algoritmos de diversas técnicas de mineração de dados, métodos para predição numérica, métodos de classificação, métodos de agrupamento e associação de dados, entre outras funcionalidades. O WEKA foi escolhido para o nosso trabalho devido à sua praticidade, e por apresentar, como principal característica, a portabilidade de um software livre [174]. Para a presente Tese, o software WEKA foi utilizado como classificador, fazendo-se uso dos seus algoritmos *ANN*, *SVM* e *DT*. Para processamento e classificação pelo WEKA, os dados precisam ser convertidos para um dos formatos de arquivo suportados pelo mesmo, sendo por nós adotado o formato próprio do software, denominado de *arff* (*Attribute Relation File Format*). O arquivo no formato *arff* é um arquivo ASCII composto de três partes. A primeira parte, chamada de relação, é indicada pelo marcador *@relation*, que aparece na primeira linha do arquivo com a função de identificação. A segunda parte, iniciada sempre com o marcador *@attribute*, contém a lista de todos os parâmetros ou atributos, devendo-se definir o tipo de cada parâmetro ou os valores que ele pode assumir. A terceira parte encontra-se logo após a linha com

²Software de domínio público desenvolvido na Universidade de Waikato na Nova Zelândia. Disponível em <http://www.cs.waikato.ac.nz/ml/weka/>.

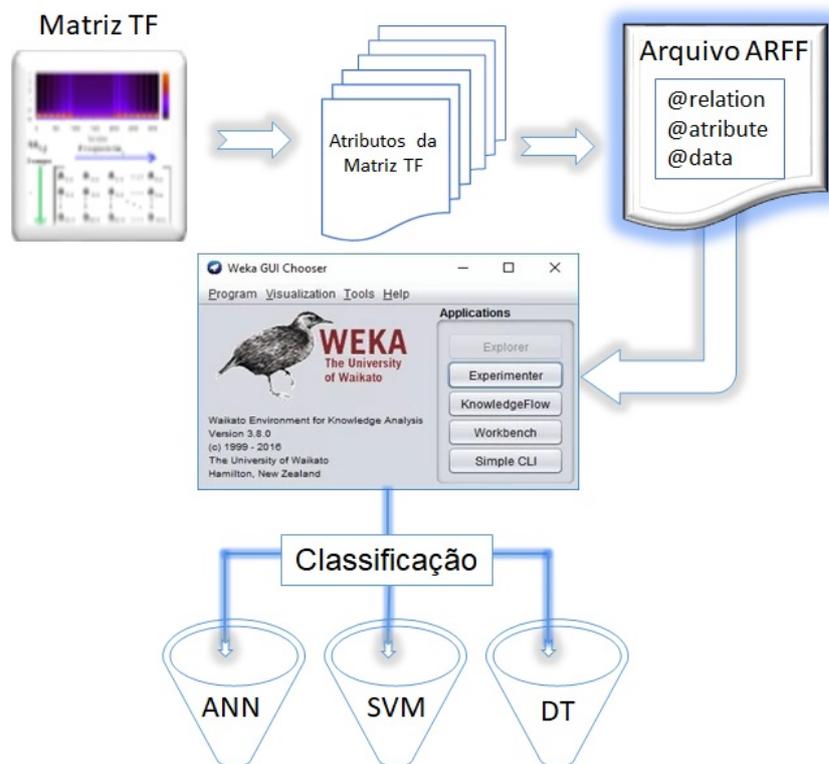


Figura 3.10: Etapas de classificação com WEKA.

o marcador *@data*, e consiste das instâncias, isto é, dos dados a serem classificados com os valores dos parâmetros para cada instância. A Fig. 3.10 exemplifica a utilização do software WEKA por meio de um fluxograma. Primeiramente, nós temos os vetores de atributos calculados a partir da matriz TF. O arquivo contendo os vetores dos atributos é então convertido para o formato *arff*, e é posteriormente processado pelo software de classificação WEKA, que fornece os dados de classificação obtidos com os algoritmos ANN, SVM e DT. [106] [59]

3.4 Classificação por Similaridade

Em [182], um método simples e eficiente para a classificação de distúrbios foi introduzido, com base no cálculo de uma medida da similaridade entre a matriz tempo-frequência de um sinal elétrico perturbado e as matrizes geradas a partir de sinais ideais sob diversos tipos de distúrbio. Este método não se enquadra exatamente no padrão acima descrito para a classificação por ANN, SVM ou DT, e por essa razão é aqui apresentado separadamente.

A medida de similaridade proposta em [182] é uma comumente utilizada em aplicações

de análise digital de imagens [187]:

$$S_{AB} = \frac{\sum_{i=1}^H \sum_{j=1}^W M_A(i, j) M_B(i, j)}{\sqrt{\sum_{i=1}^H \sum_{j=1}^W M_A^2(i, j) \cdot \sum_{i=1}^H \sum_{j=1}^W M_B^2(i, j)}} \quad (3.23)$$

onde M_A e M_B denotam as magnitudes das duas matrizes tempo-frequência sendo comparadas, ambas com largura W e altura H , de forma que $1 \leq j \leq W$ e $1 \leq i \leq H$. S_{AB} é portanto uma medida da correlação entre as matrizes, assumindo o valor máximo de 1, quando as duas matrizes são idênticas – i.e., quando $M_A(i, j) = M_B(i, j)$, $\forall i, j$.

Nesta Tese, os seguintes procedimentos foram implementados, para a aplicação da Eq. (3.23):

1- A partir das equações paramétricas de cada distúrbio a ser analisado, geraram-se conjuntos de 100 formas de onda ideais (sem ruído), para o sinal elétrico sob cada distúrbio. A transformada tempo-frequência de cada uma das formas de onda ideais foi então computada, obtendo-se a sua média sobre todo o conjunto. Isto resultou em uma matriz tempo-frequência padronizada para cada distúrbio, a ser usada como referência no cálculo de similaridade.

2- De posse das matrizes de referência, geraram-se outros 1000 sinais com distúrbios, variando-se aleatoriamente os seus parâmetros característicos, de modo a simular uma condição real. Para a devida análise de impacto, os sinais de teste foram gerados com razões SNR (relação sinal-ruído) de 20dB, 30dB, e 40dB.

3- O módulo da transformada tempo-frequência foi computado para cada sinal de teste, gerando as matrizes M_A a serem comparadas com as matrizes padronizadas M_B , segundo a métrica S_{AB} . A matriz padronizada de maior similaridade com a matriz de entrada (sinal com distúrbio desconhecido) aponta o tipo do distúrbio sob investigação.

O algoritmo de identificação foi executado para cada um dos 1000 casos, com SNR de 20dB, 30dB e 40dB, totalizando assim 3000 casos para cada um dos sete tipos de distúrbio considerados, ou seja, um total de 21.000 casos de distúrbio foram analisados e classificados.

3.5 Considerações Finais

Neste Capítulo, nós descrevemos as duas grandes categorias de distúrbios que afetam a qualidade da energia elétrica: os distúrbios que afetam a amplitude do sinal de tensão

– especificamente, *afundamentos de tensão* (Sags), *elevações de tensão* (Swells), e *interrupções momentâneas da tensão* (Interrupts) –, e os distúrbios que afetam a forma de onda do sinal de tensão – *harmônicos* (Harmonics), *oscilatórios transientes* (Transients), e *cortes na forma de onda* (Notches e Spikes). Descrevemos também as técnicas de classificação utilizadas na presente Tese, nomeadamente, o classificador por Redes Neurais - ANN, o classificador por Máquina de Vetor de Suporte - SVM, o classificador por Árvore de Decisão - DT, e o classificador por Similaridade. Para que estes classificadores possam ter bom desempenho, os vetores de atributos em que se baseia a classificação devem ser criteriosamente escolhidos. No nosso caso, os atributos foram selecionados de modo a extrair, de cada matriz TF, características distintas para cada tipo de distúrbio analisado, permitindo a sua classificação pelo software WEKA.

No próximo Capítulo, nós apresentaremos os resultados de classificação obtidos a partir de três diferentes tipos de bancos de dados, a saber: um banco de sinais sintéticos, um banco de sinais reais obtidos em laboratório, e um banco de sinais reais obtidos de um grupo de pesquisas do IEEE.

Capítulo 4

Aplicação das Transformadas Sintonizadas à Análise de Distúrbios nos SEP

4.1 Considerações Iniciais

O nosso trabalho investigou o desempenho das transformadas sintonizadas de Gabor em uma tarefa de classificação de diversos tipos de distúrbios em sistemas elétricos de potência, utilizando três bases de dados distintas: i) sinais sintéticos gerados com o software MATLAB; ii) sinais reais obtidos de uma base do IEEE, e iii) sinais reais produzidos no laboratório do IFTM. Para efeito de comparação, considerou-se também o desempenho, nessa mesma tarefa, das transformadas de Gabor, S e de Wigner. Os espectrogramas obtidos com as diversas abordagens Tempo-Frequência foram utilizados como entrada para classificadores baseados em Similaridade, Redes Neurais Artificiais (ANN), Support Vector Machines (SVM), e Árvores de Decisão (DT).

4.2 Sinais Gerados com o MATLAB

Foram analisados dez tipos de distúrbio sobre formas de onda sintéticas geradas com o MATLAB, como já descrito no Capítulo 3. Os sinais têm frequência fundamental de 50 Hz, e utilizou-se frequência de amostragem de 1,6 kHz (um ciclo de 32 amostras), totalizando 10 ciclos (320 amostras) para cada um dos sinais, considerados tanto sem ruído como sob ruído de 40 dB, 30 dB, 20 dB e 10 dB. Foram geradas 100 amostras de cada distúrbio, totalizando 1000 amostras para classificação, sendo 200 amostras utilizadas para treinamento dos classificadores. As matrizes TF foram obtidas através da implementação, também em MATLAB, dos algoritmos correspondentes. A precisão dos procedimentos de

classificação empregados pode ser avaliada a partir das Tabelas 4.1 e 4.2, que informam o percentual de identificação de cada distúrbio, sob os diferentes níveis de ruído. Em todos os casos, as Transformadas Sintonizadas alcançaram as melhores taxas de classificação geral, seguidas pela ST. Aqui, para efeito de exposição e análise dos resultados, nos restringiremos a sinais gerados sob ruído de 10 dB (o maior nível de ruído). Outros resultados aparecem no Anexo B.

A Tabela 4.1 apresenta os dados em porcentagem da classificação de cada categoria de distúrbio, a sua última coluna informando o total, em porcentagem, de classificação com cada um dos classificadores, e a última linha, o desempenho geral na classificação de cada tipo de distúrbio, calculado como a média entre todos os percentuais de classificação. O gráfico de barras da Fig. 4.1 rerepresenta esses mesmos dados da Tabela 4.1, apresentando a porcentagem de classificação geral para cada distúrbio analisado, o que evidencia os distúrbios com maior ou menor facilidade de classificação.¹

¹Nos nossos experimentos com a FrSTGT, o valor do parâmetro β foi fixado em 0,14, e portanto apenas o valor de α é informado nas tabelas e figuras a seguir.

Tabela 4.1: Desempenho das Transformadas na Classificação dos Distúrbios - 10dB.

Transformadas	Classificadores	Distúrbios Analisados										Performance Total
		Sags	Swells	Interrupts	Harmonics	Transients	Spikes	Notches	Sags+Harmonics	Swells+Harmonics	Interrupt+Harmonics	
STGT	Sim	77,5	78,75	60	77,5	81,25	81,25	75	76,25	88,75	90	78,62
	ANN	88,75	90	93,75	97,5	96,25	86,25	81,25	83,75	78,75	78,75	87,5
	SVM	81,25	80	62,5	81,25	87,5	85	78,75	78,75	81,25	91,25	80,75
	DT	93,75	91,25	93,75	93,75	97,5	87,5	85	83,75	81,25	85	89,25
STGT _{H1}	Sim	92,5	97,5	100	93,75	93,75	86,25	92,5	90	88,75	86,25	92,12
	ANN	100	105	100	100	95	90	93,75	100	100	87,5	97,12
	SVM	50	75	65	93,75	95	83,75	81,25	87,5	62,5	63,75	75,75
	DT	98,75	100	100	100	97,5	93,75	95	98,75	96,25	93,75	97,37
STGT ₂	Sim	93,75	91,25	98,75	98,75	97,5	93,75	88,75	93,75	87,5	85	92,87
	ANN	100	95	100	100	98,75	100	93,75	100	97,5	93,75	97,87
	SVM	96,25	93,75	100	100	100	97,5	90	97,5	90	88,75	95,37
	DT	100	97,5	100	100	93,75	97,5	100	100	93,75	97,5	98
STGT _{2H1}	Sim	88,75	75	68,75	93,75	80	87,5	93,75	68,75	50	75	78,12
	ANN	100	91,25	85	100	53,75	93,75	57,5	95	52,5	91,25	82
	SVM	100	78,75	100	100	85	93,75	98,75	81,25	63,75	78,75	88
	DT	100	80	73,75	100	85	82,5	87,5	71,25	52,5	80	81,25
STGT _{ω_0}	Sim	92,5	87,5	100	81,25	85	93,75	100	95	88,75	78,75	90,25
	ANN	100	91,25	100	100	97,5	85	80	100	100	93,75	94,75
	SVM	85	81,25	100	87,5	81,25	80	86,25	93,75	87,5	92,5	87,5
	DT	100	91,25	100	88,75	97,5	93,75	98,75	95	88,75	86,25	94
FrSTGT _{$\alpha=0,1$}	Sim	81,25	76,25	81,25	68,75	56,25	80	72,5	68,75	76,25	72,5	73,37
	ANN	70	80	96,25	100	88,75	93,75	68,75	38,75	62,5	78,75	77,75
	SVM	87,5	100	86,25	78,75	88,75	82,5	72,5	31,25	56,25	62,5	74,62
	DT	88,75	80	96,25	100	52,5	93,75	87,5	36,25	88,75	78,75	80,25
FrSTGT _{$\alpha=0,5$}	Sim	93,75	77,5	81,25	75	68,75	80	68,75	86,25	85	81,25	79,75
	ANN	80	92,5	85	100	75	93,75	77,5	100	88,75	78,75	87,12
	SVM	93,75	97,5	92,5	85	81,25	87,5	68,75	35	78,75	68,75	78,87
	DT	100	80	73,75	100	85	82,5	87,5	71,25	52,5	80	81,25
GT	Sim	93,75	97,5	98,75	93,75	80	80	81,25	68,75	67,5	62,5	82,37
	ANN	100	92,5	100	100	86,25	93,75	98,75	95	78,75	70	91,5
	SVM	87,5	67,5	75	100	76,25	75	80	81,25	66,25	78,75	78,75
	DT	100	92,5	96,25	100	75	93,75	98,75	95	100	91,25	94,25
TWVD	Sim	93,75	97,5	97,5	81,25	68,75	80	85	86,25	75	82,5	84,75
	ANN	90	92,5	63,75	100	68,75	83,75	90	95	100	91,25	87,5
	SVM	100	78,75	100	100	97,5	93,75	98,75	81,25	67,5	82,5	90
	DT	88,75	92,5	100	100	86,25	93,75	98,75	100	88,75	92,5	94,12
ST	Sim	87,5	93,75	100	92,5	100	97,5	93,75	81,25	85	86,25	91,75
	ANN	100	100	100	100	97,5	93,75	78,75	85	86,25	93,75	93,5
	SVM	85	100	97,5	100	100	81,25	80	88,75	87,5	88,75	90,87
	DT	100	100	100	100	86,25	93,75	98,75	87,5	88,75	96,25	95,12
Total		91,5	89	90,56	94,06	85,43	88,65	86,09	82,56	80,25	83,37	

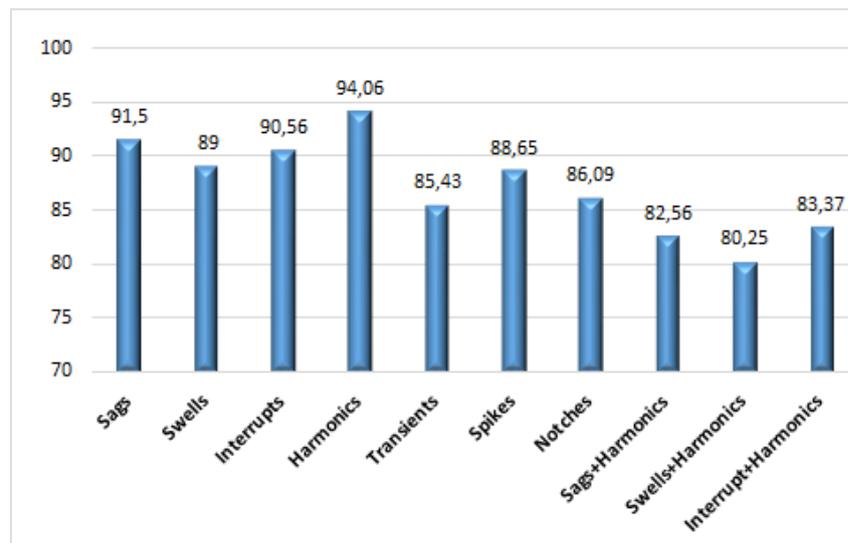


Figura 4.1: Nível de Classificação dos Distúrbios Sintéticos.

A Tabela 4.2 descreve o desempenho geral de cada transformada, quando utilizada com cada tipo de classificador (*Similaridade, ANN, SVM, DT*), neste caso para os níveis de ruído de 10 dB a ∞ dB. A última coluna da tabela informa o percentual de classificação obtido com cada abordagem TF, de acordo com o classificador utilizado. Destaca-se, em negrito, o maior índice de classificação obtido para cada categoria de classificador. A Fig. 4.2 reapresenta, sob a forma de histogramas, dados retirados da Tabela 4.2, evidenciando o desempenho individual de cada transformada para cada tipo de classificador.

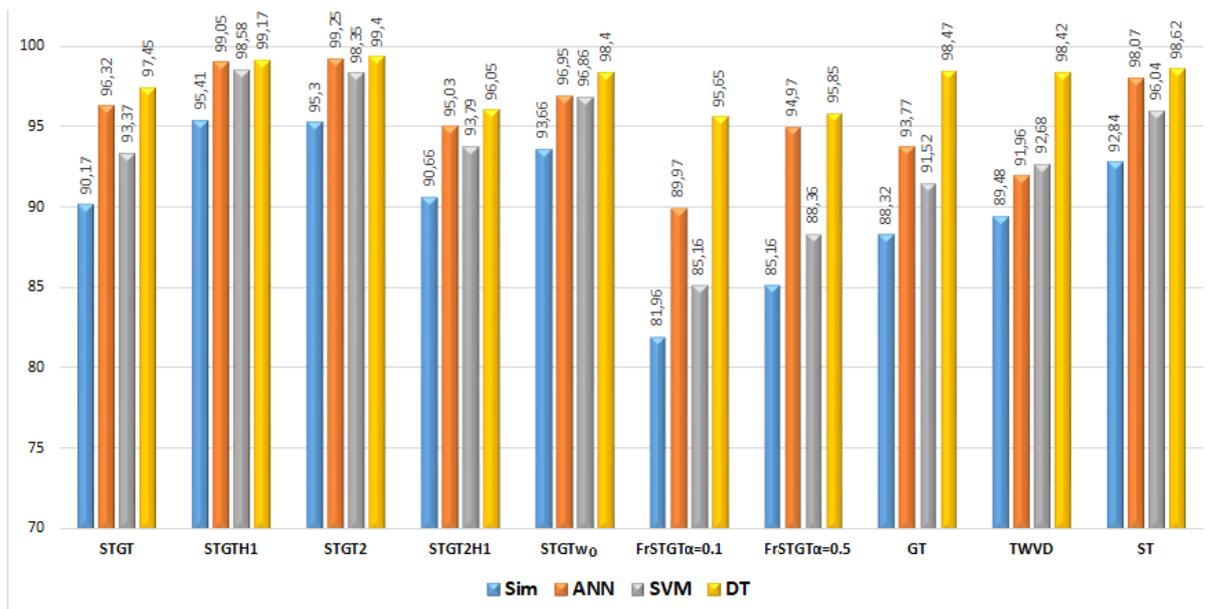


Figura 4.2: Desempenho das Transformadas na Classificação dos Distúrbios Sintéticos

Tabela 4.2: Classificação de Distúrbios de sinais Sintéticos

Classificadores	Transformadas	10dB	20dB	30dB	40dB	∞ dB	Total
Similaridade	STGT	78,5	87,99	93,12	95,6	95,65	90,17
	STGT _{H1}	92,12	95,15	95,8	96,85	97,15	95,41
	STGT ₂	92,87	94,23	94,68	97,36	97,38	95,30
	STGT _{2H1}	78,12	91,2	90,36	96,31	97,32	90,66
	STGT _{ω_0}	90,25	92,65	93,25	95,68	96,5	93,66
	FrSTGT _{$\alpha=0,1$}	73,37	77,25	78,23	88,69	92,3	81,96
	FrSTGT _{$\alpha=0,5$}	79,75	80,12	82,36	91,23	92,36	85,16
	GT	82,37	85,36	90,2	92,35	91,36	88,32
	TWVD	84,75	89,25	89,21	91,89	92,3	89,48
	ST	91,5	92,38	92,34	93,25	94,74	92,84
ANN	STGT	87,25	98,8	98,85	98,55	98,15	96,32
	STGT _{H1}	97,12	99,65	99,5	99,5	99,5	99,05
	STGT ₂	97,87	99,6	100	98,8	100	99,25
	STGT _{2H1}	82	97,8	97,25	98,85	99,25	95,03
	STGT _{ω_0}	94,75	96,85	96,3	98,2	98,65	96,95
	FrSTGT _{$\alpha=0,1$}	77,75	92,5	95	94,95	89,65	89,97
	FrSTGT _{$\alpha=0,5$}	87,75	95,45	97,3	98,4	95,95	94,97
	GT	92,25	95,35	96,4	94,35	90,5	93,77
	TWVD	87,62	91,8	92,4	92,6	95,4	91,96
	ST	93,75	99,2	99	99,2	99,2	98,07
SVM	STGT	82,5	91,99	95,12	98,6	98,65	93,37
	STGT _{H1}	96,12	99,15	97,8	99,85	100	98,58
	STGT ₂	96,87	98,23	96,68	100	100	98,35
	STGT _{2H1}	82,12	95,2	92,36	99,31	100	93,79
	STGT _{ω_0}	94,25	96,65	95,25	98,68	99,5	96,86
	FrSTGT _{$\alpha=0,1$}	77,37	81,25	80,23	91,69	95,3	85,16
	FrSTGT _{$\alpha=0,5$}	83,75	84,12	84,36	94,23	95,36	88,36
	GT	86,37	89,36	92,2	95,35	94,36	91,52
	TWVD	88,75	93,25	91,21	94,89	95,3	92,68
	ST	95,5	96,38	94,34	96,25	97,74	96,04
DT	STGT	89,25	99,5	99,5	99,5	99,5	97,45
	STGT _{H1}	97,37	100	99,5	99,5	99,5	99,17
	STGT ₂	98	100	99,5	99,5	100	99,4
	STGT _{2H1}	81,25	100	99,5	99,5	100	96,05
	STGT _{ω_0}	94	99,5	99,5	99,5	99,5	98,4
	FrSTGT _{$\alpha=0,1$}	80,25	99,5	99,5	99,5	99,5	95,65
	FrSTGT _{$\alpha=0,5$}	81,25	99,5	99,5	99,5	99,5	95,85
	GT	94,37	99,5	99,5	99,5	99,5	98,47
	TWVD	94,12	99,5	99,5	99,5	99,5	98,42
	ST	95,12	99,5	99,5	99,5	99,5	98,62

4.2.1 Análise dos Espectrogramas

Os espectrogramas obtidos sob as perturbações que não afetam o conteúdo em frequência dos sinais originais são mostrados nas Figuras 4.3 a 4.5. Tanto para os *Sags* como para os *Swells*, fica evidente que a $STGT_2$ produz uma identificação precisa do início e do fim da perturbação, e com melhor resolução que as transformadas tradicionais. No caso dos distúrbios do tipo *Interrupts*, a vantagem da $STGT_2$ fica ainda mais marcada, merecendo destaque também a $STGT_{H1}$ e a $STGT_{\omega(0)}$.

Os espectrogramas correspondentes aos distúrbios que geram frequências indesejáveis (*Harmonics*, *Transients*, *Notches* e *Spikes*) aparecem nas Figuras 4.6 a 4.9. É evidente que as abordagens sintonizadas identificam com precisão as componentes espectrais espúrias, com a $STGT_2$, a $STGT_{H1}$ e a $STGT_{\omega(0)}$ proporcionando a melhor resolução neste caso. Em contraste, a ST mostra uma resolução bastante pobre, que piora nas altas frequências, como seria de se esperar face às características dessa transformada. É também interessante observar que a $STGT_2$, além de identificar precisamente as frequências espúrias, também preserva a informação sobre os semiciclos temporais da forma de onda do sinal. Além disso, como ilustrado para o experimento com as *Spikes* e as *Notches*, as magnitudes de Fourier são replicadas no espectrograma da $STGT_2$ e da $STGT_{H1}$, uma característica que não se observa com as demais transformadas (ST, GT, TWD). Os espectrogramas das Figs. 4.10 a 4.12 correspondem a perturbações compostas, ou seja, a sinais sob distúrbios que interferiram tanto na amplitude como na frequência original.

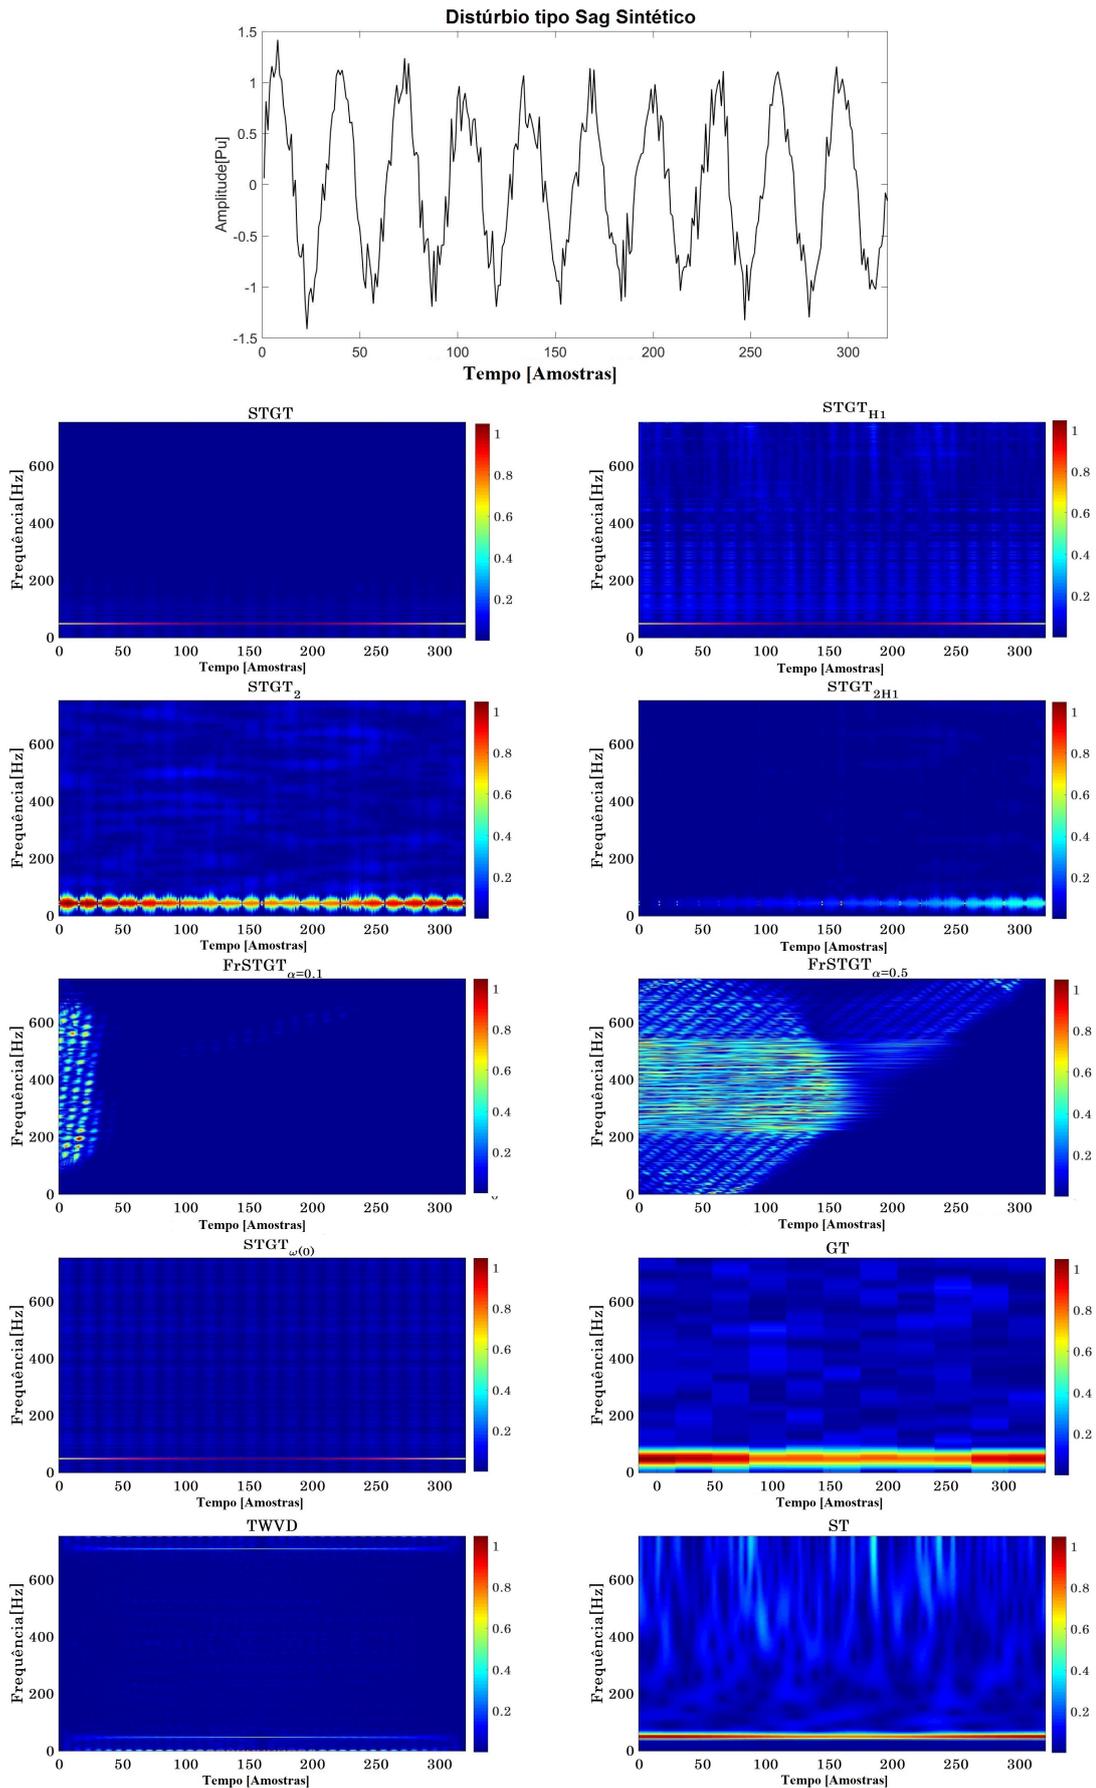


Figura 4.3: Aplicação das Transformadas a um Distúrbio Sintético tipo Sag.

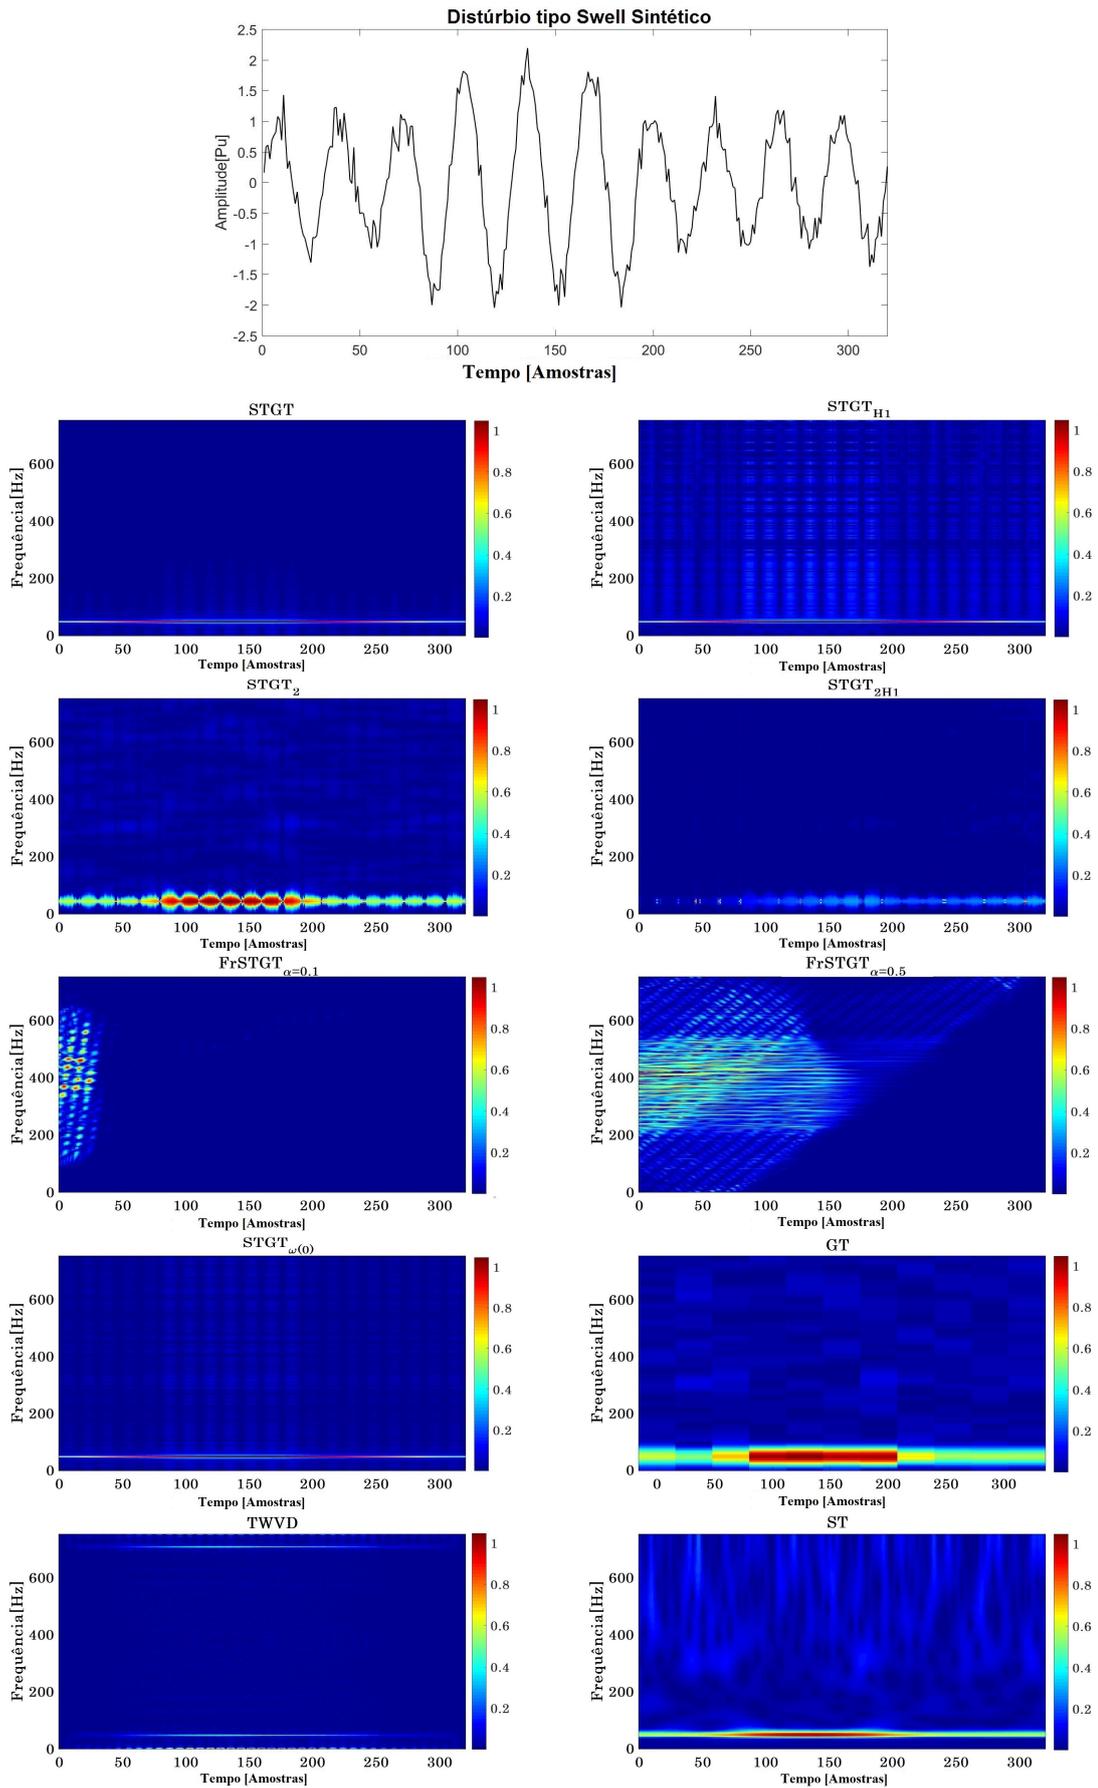


Figura 4.4: Aplicação das Transformadas a um Distúrbio Sintético tipo Swell.

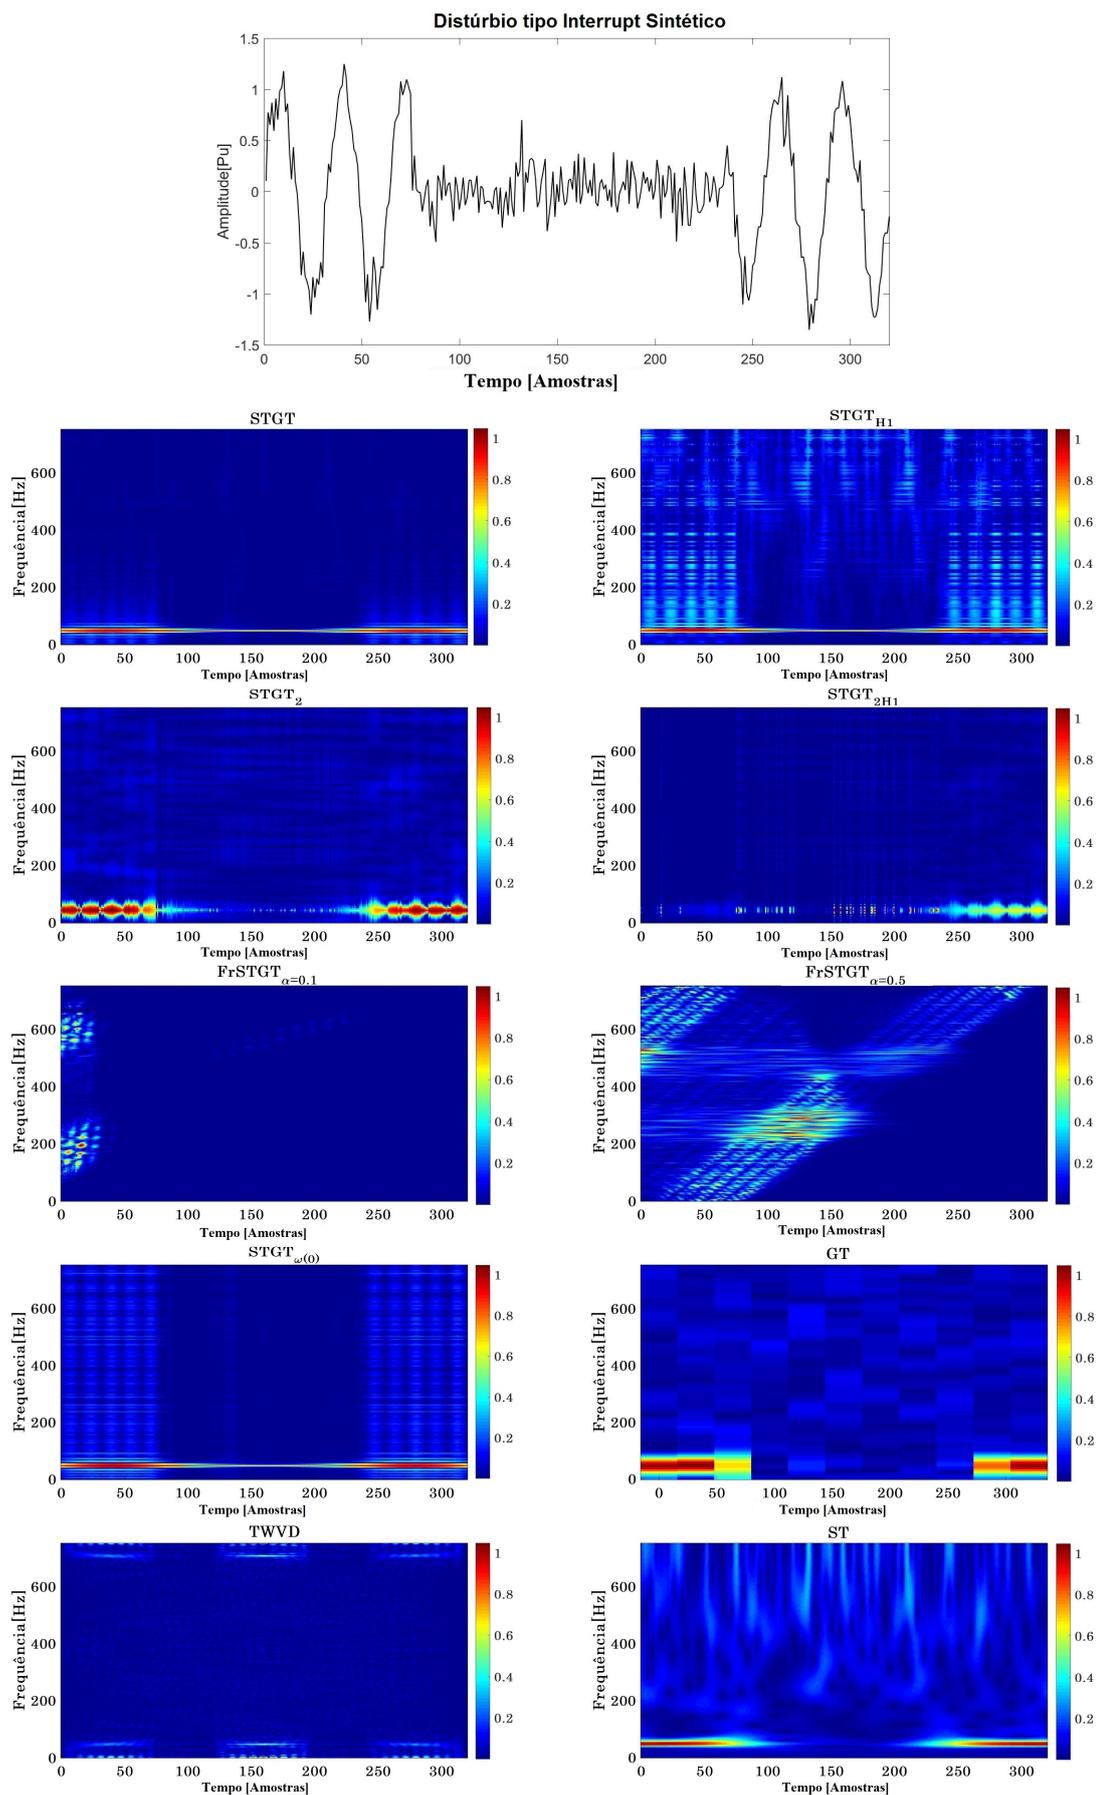


Figura 4.5: Aplicação das Transformadas a um Distúrbio Sintético tipo Interrupt.

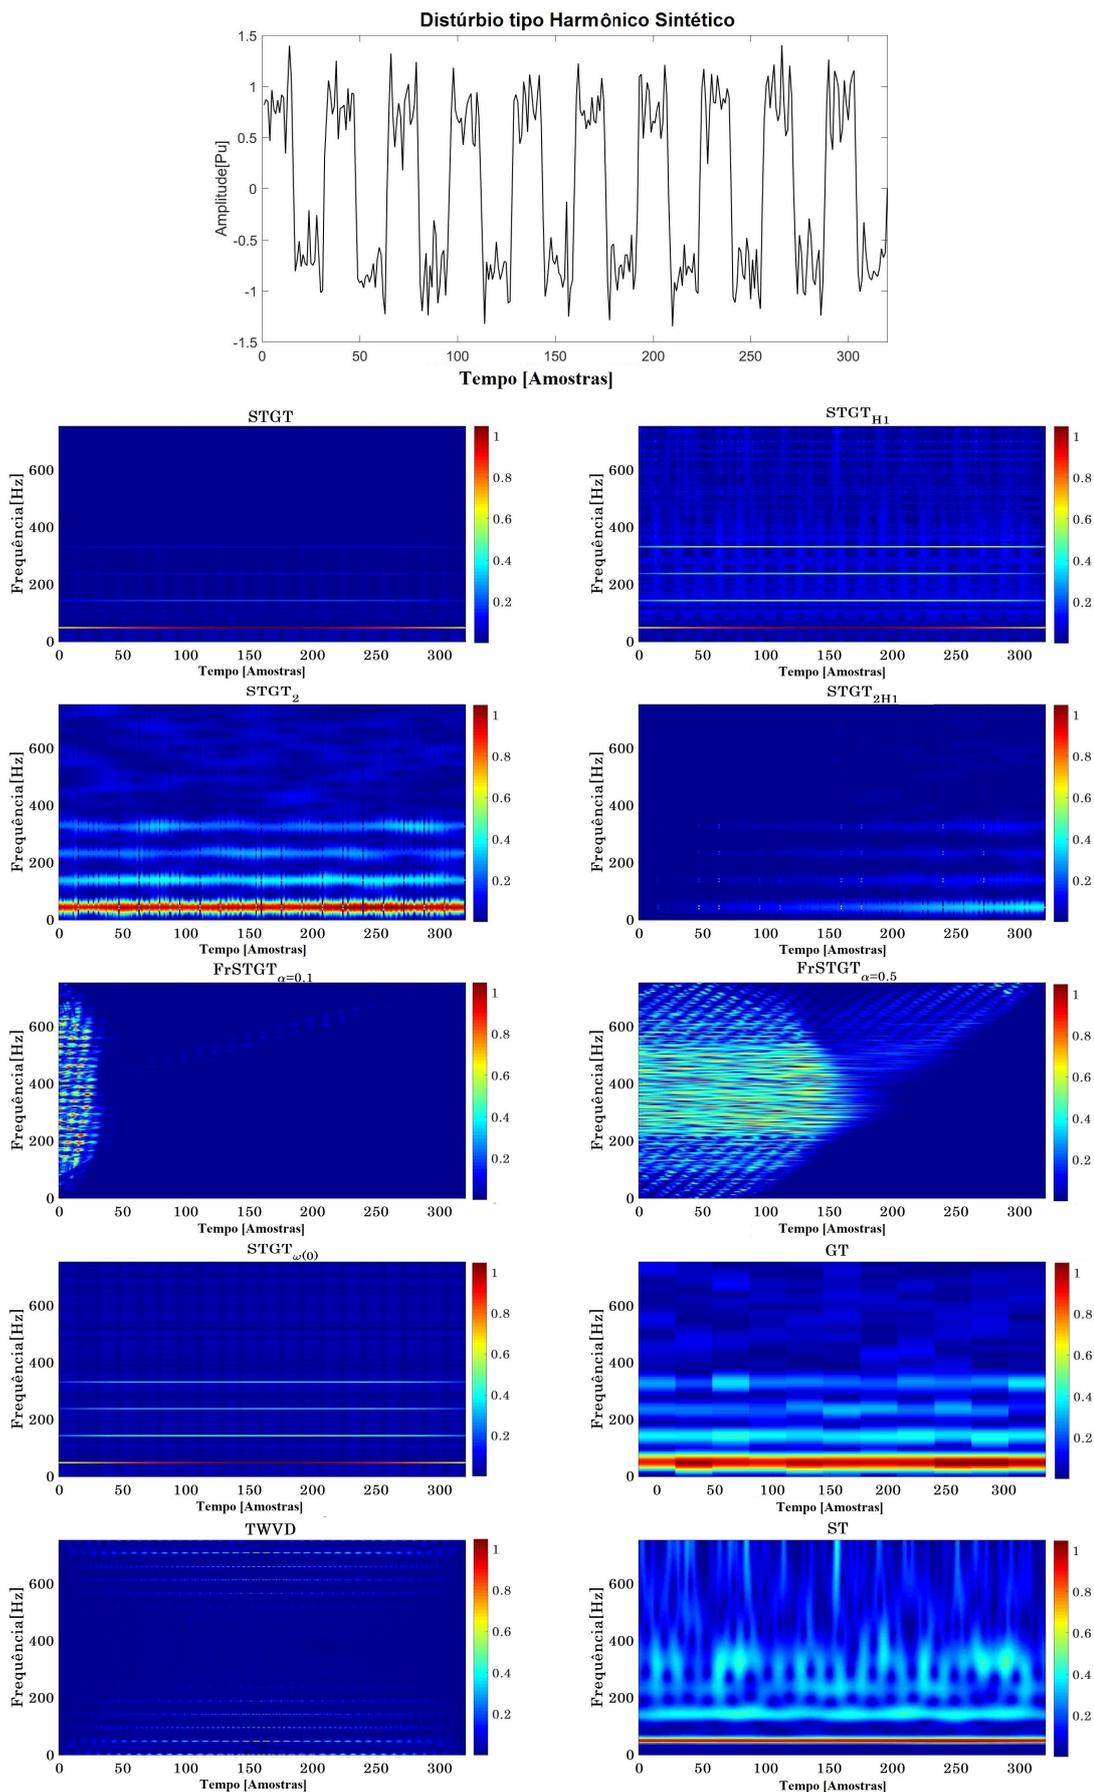


Figura 4.6: Aplicação das Transformadas a um Distúrbio Sintético tipo Harmônico.

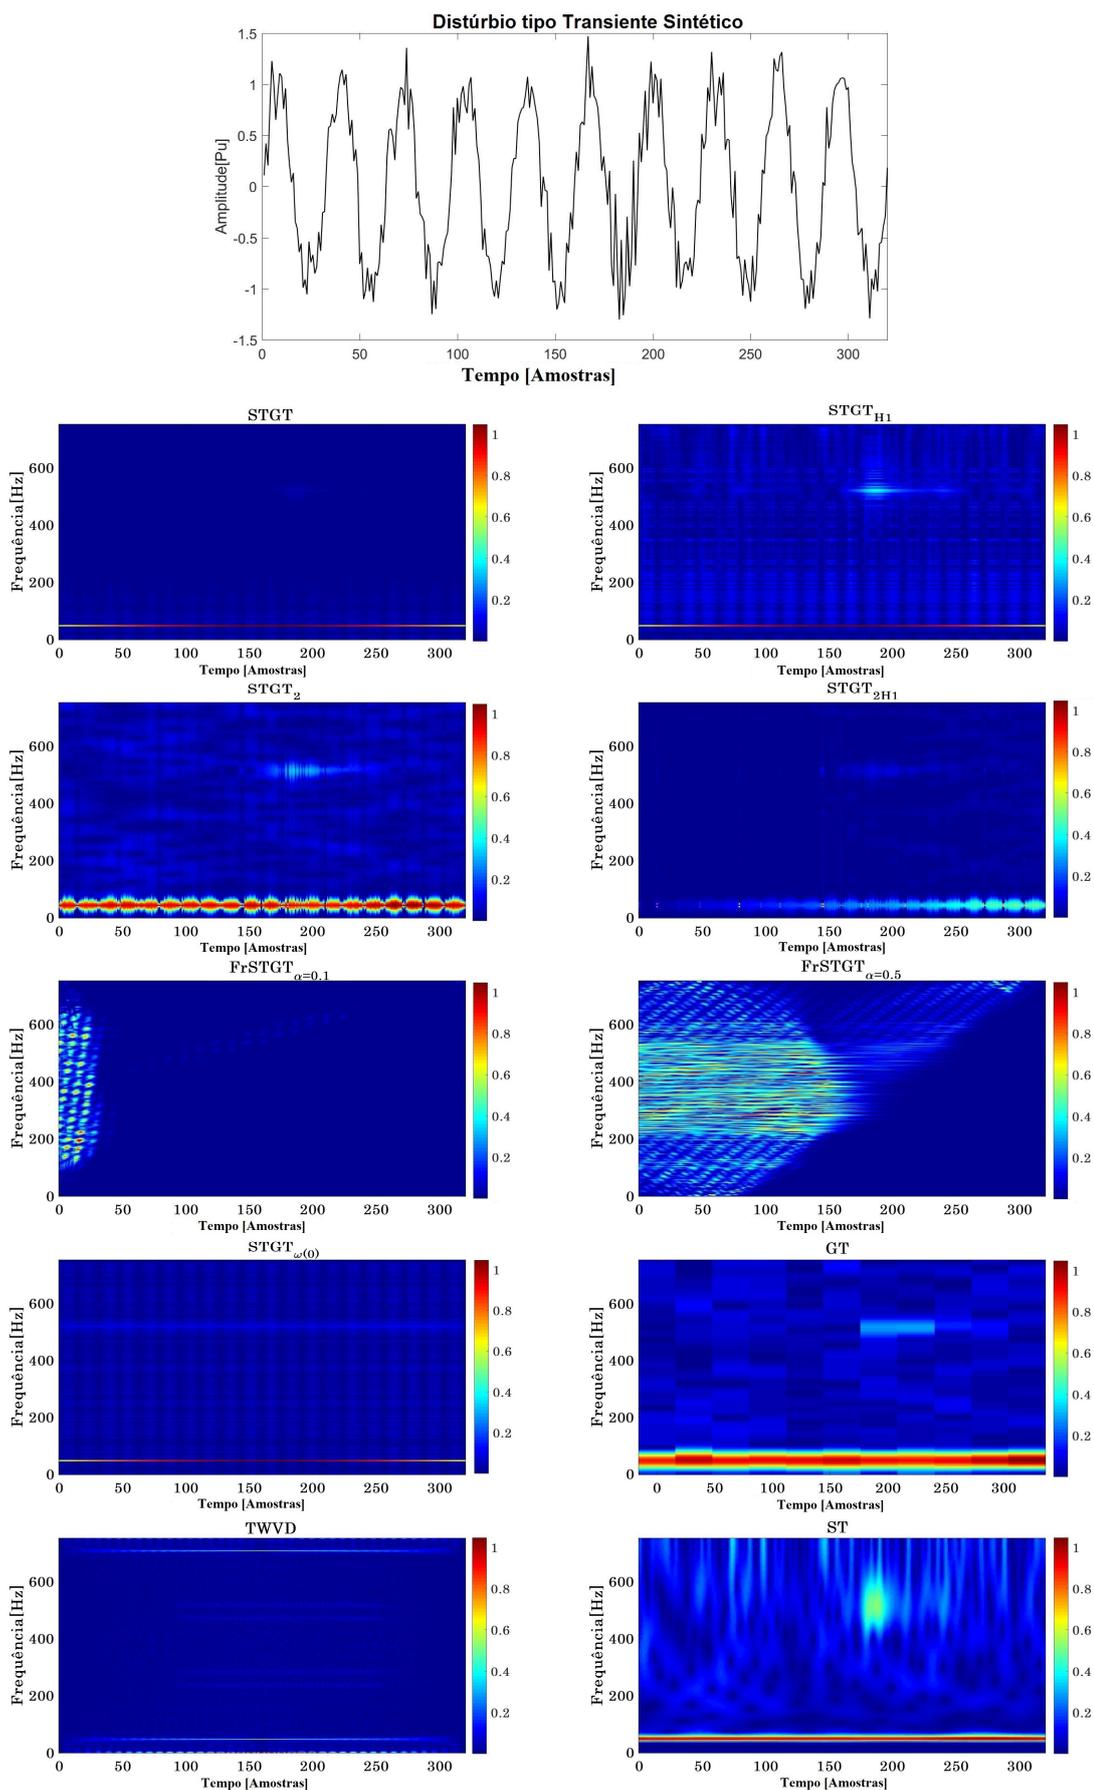


Figura 4.7: Aplicação das Transformadas a um Distúrbio Sintético tipo Transiente.

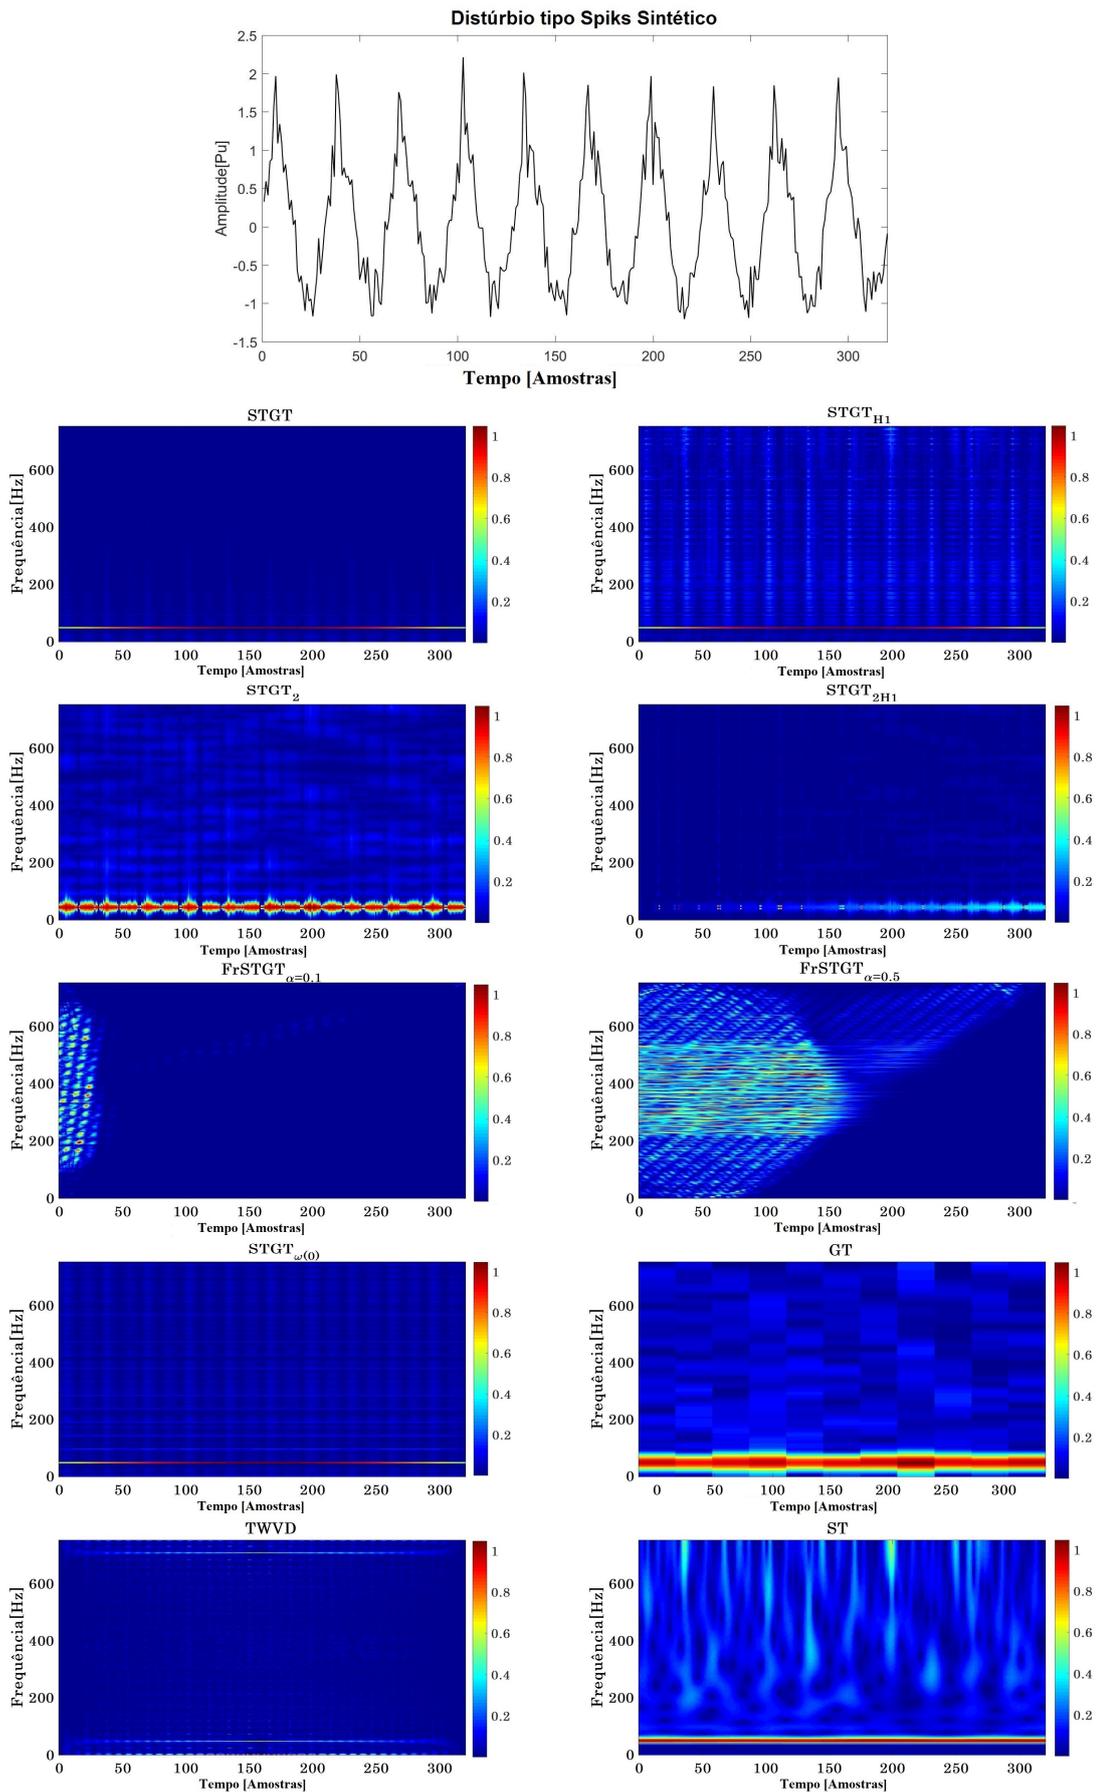


Figura 4.8: Aplicação das Transformadas a um Distúrbio Sintético tipo Spiks.

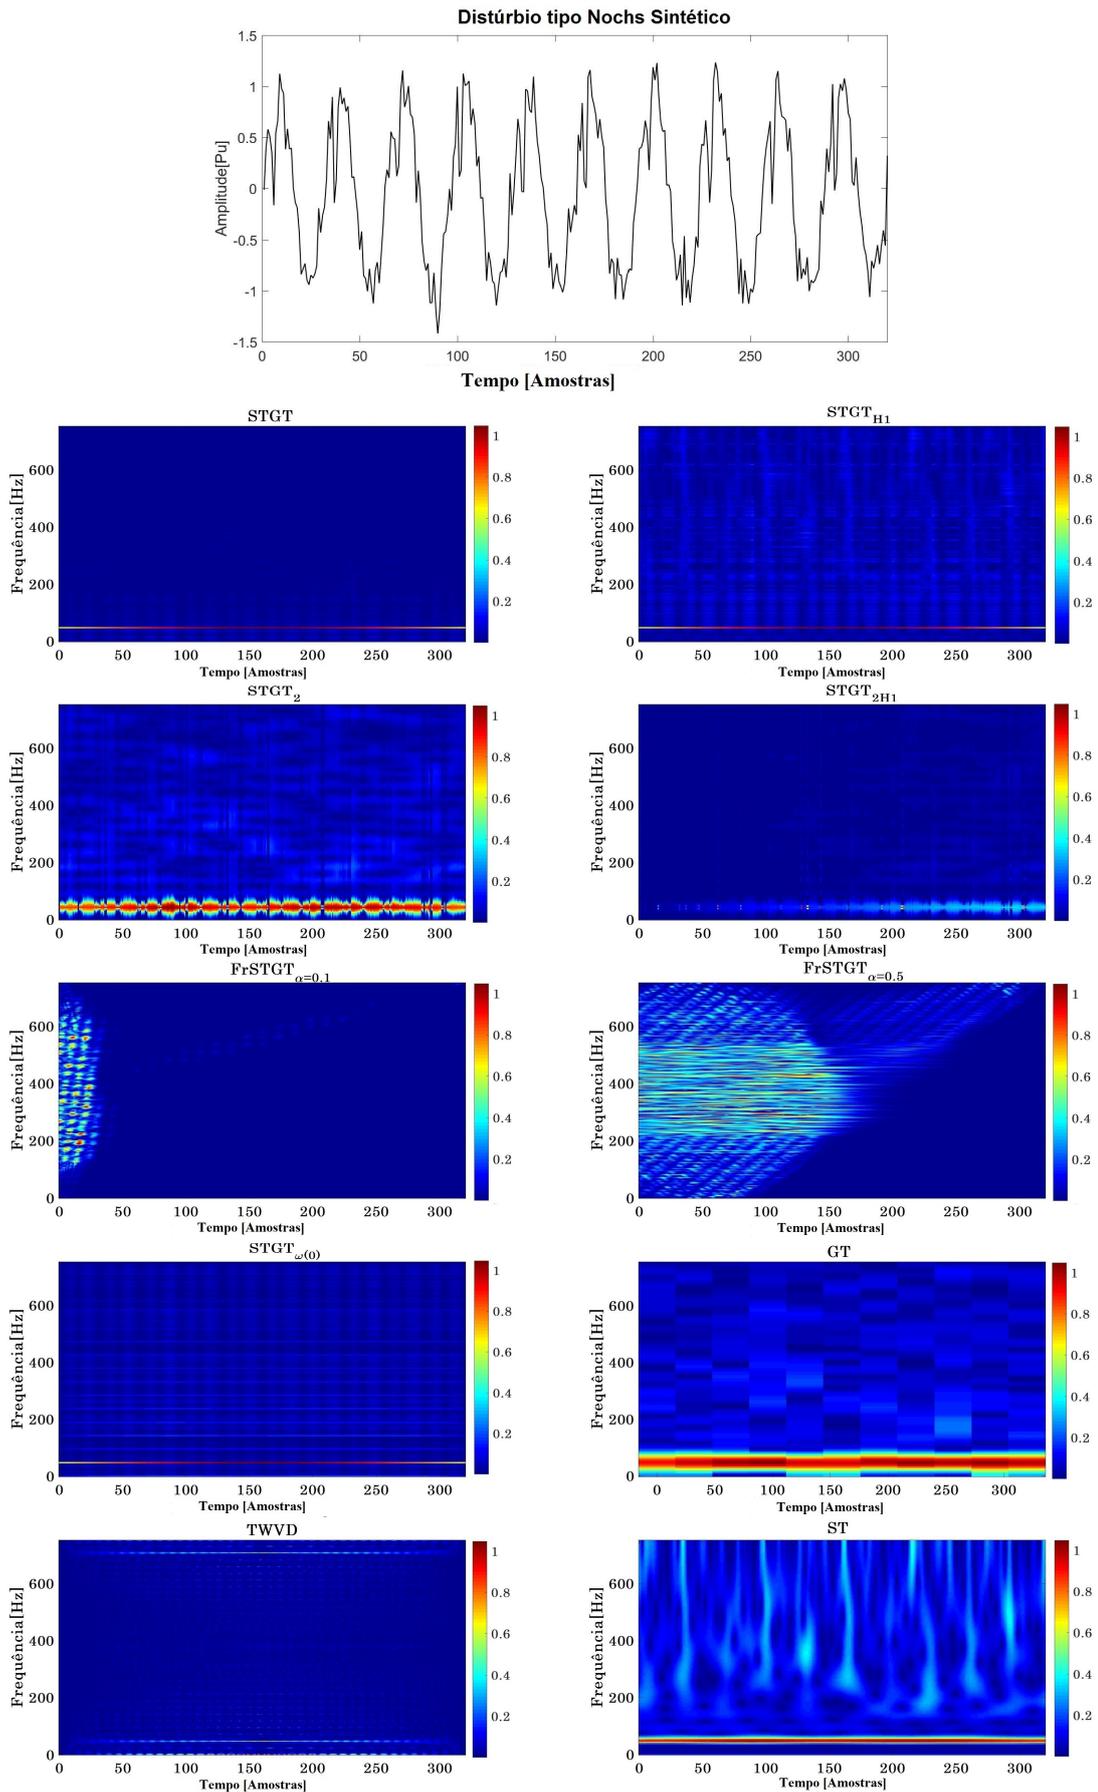


Figura 4.9: Aplicação das Transformadas a um Distúrbio Sintético tipo Notches

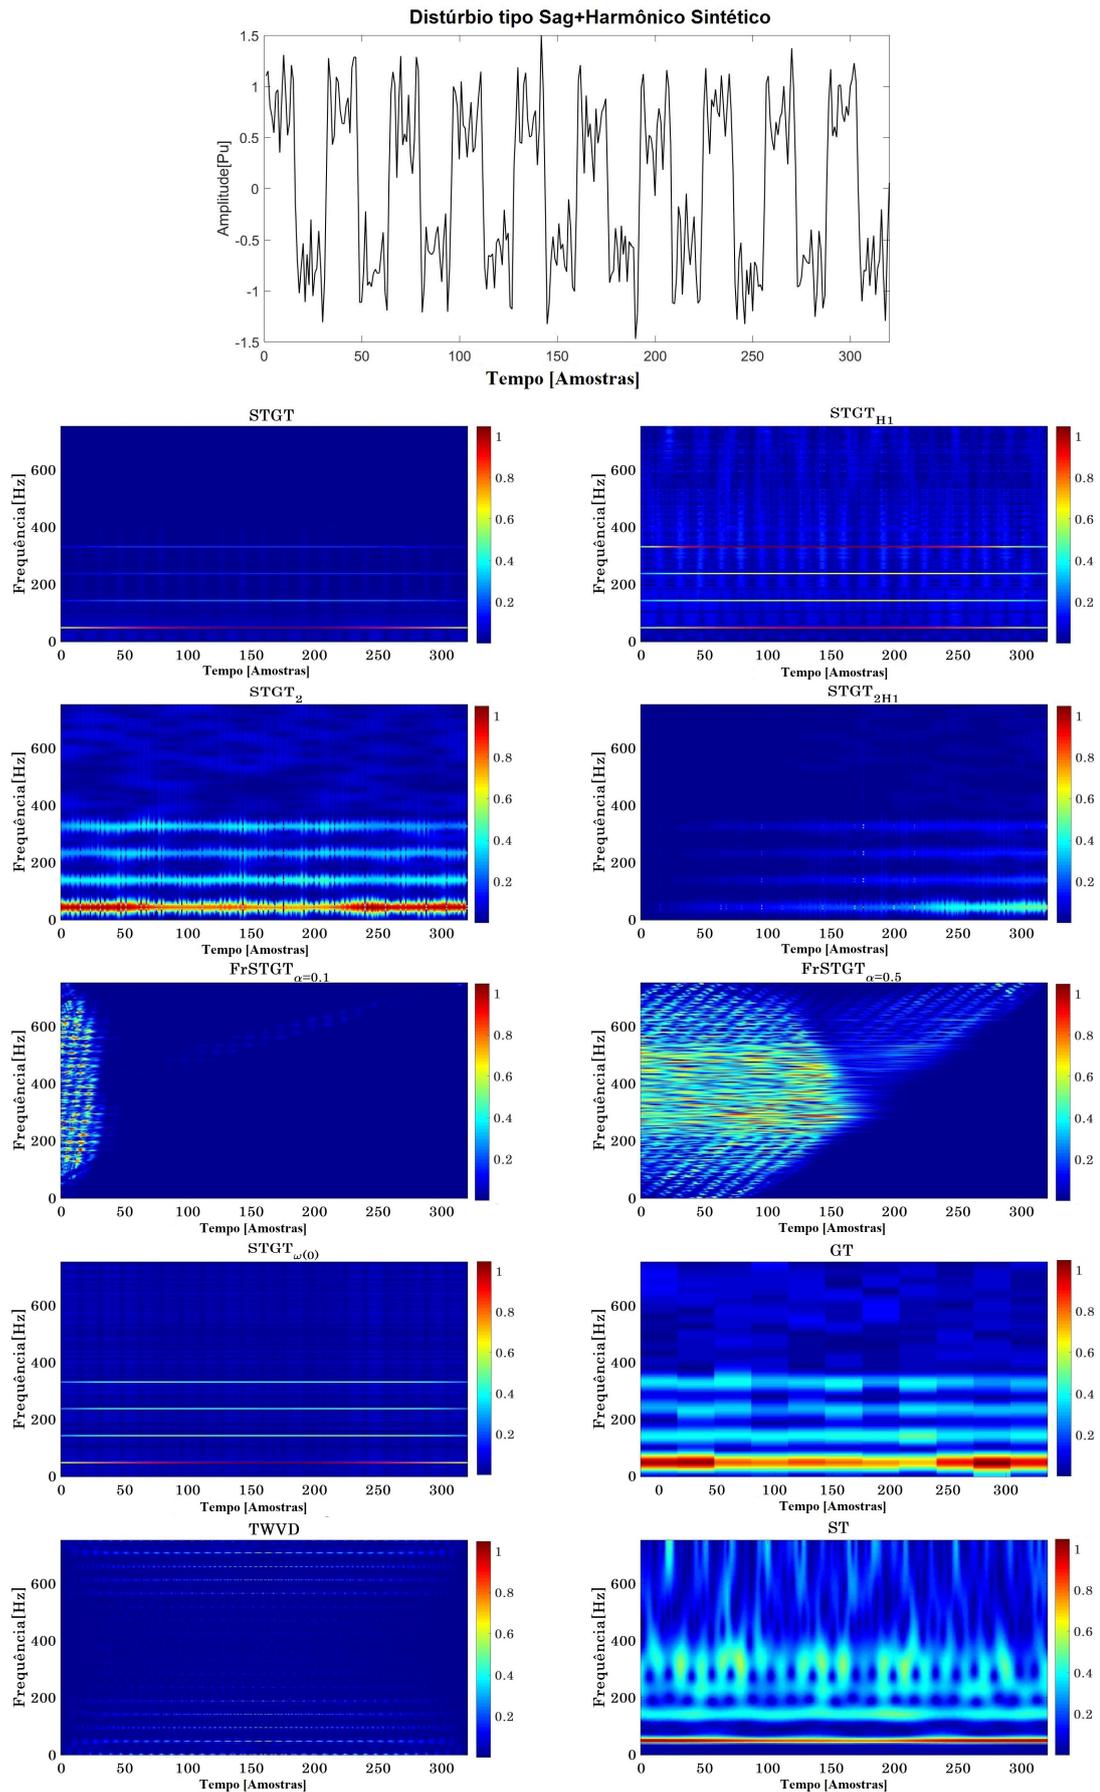


Figura 4.10: Aplicação das Transformadas a um Distúrbio Sintético tipo Sag+Harmônico.

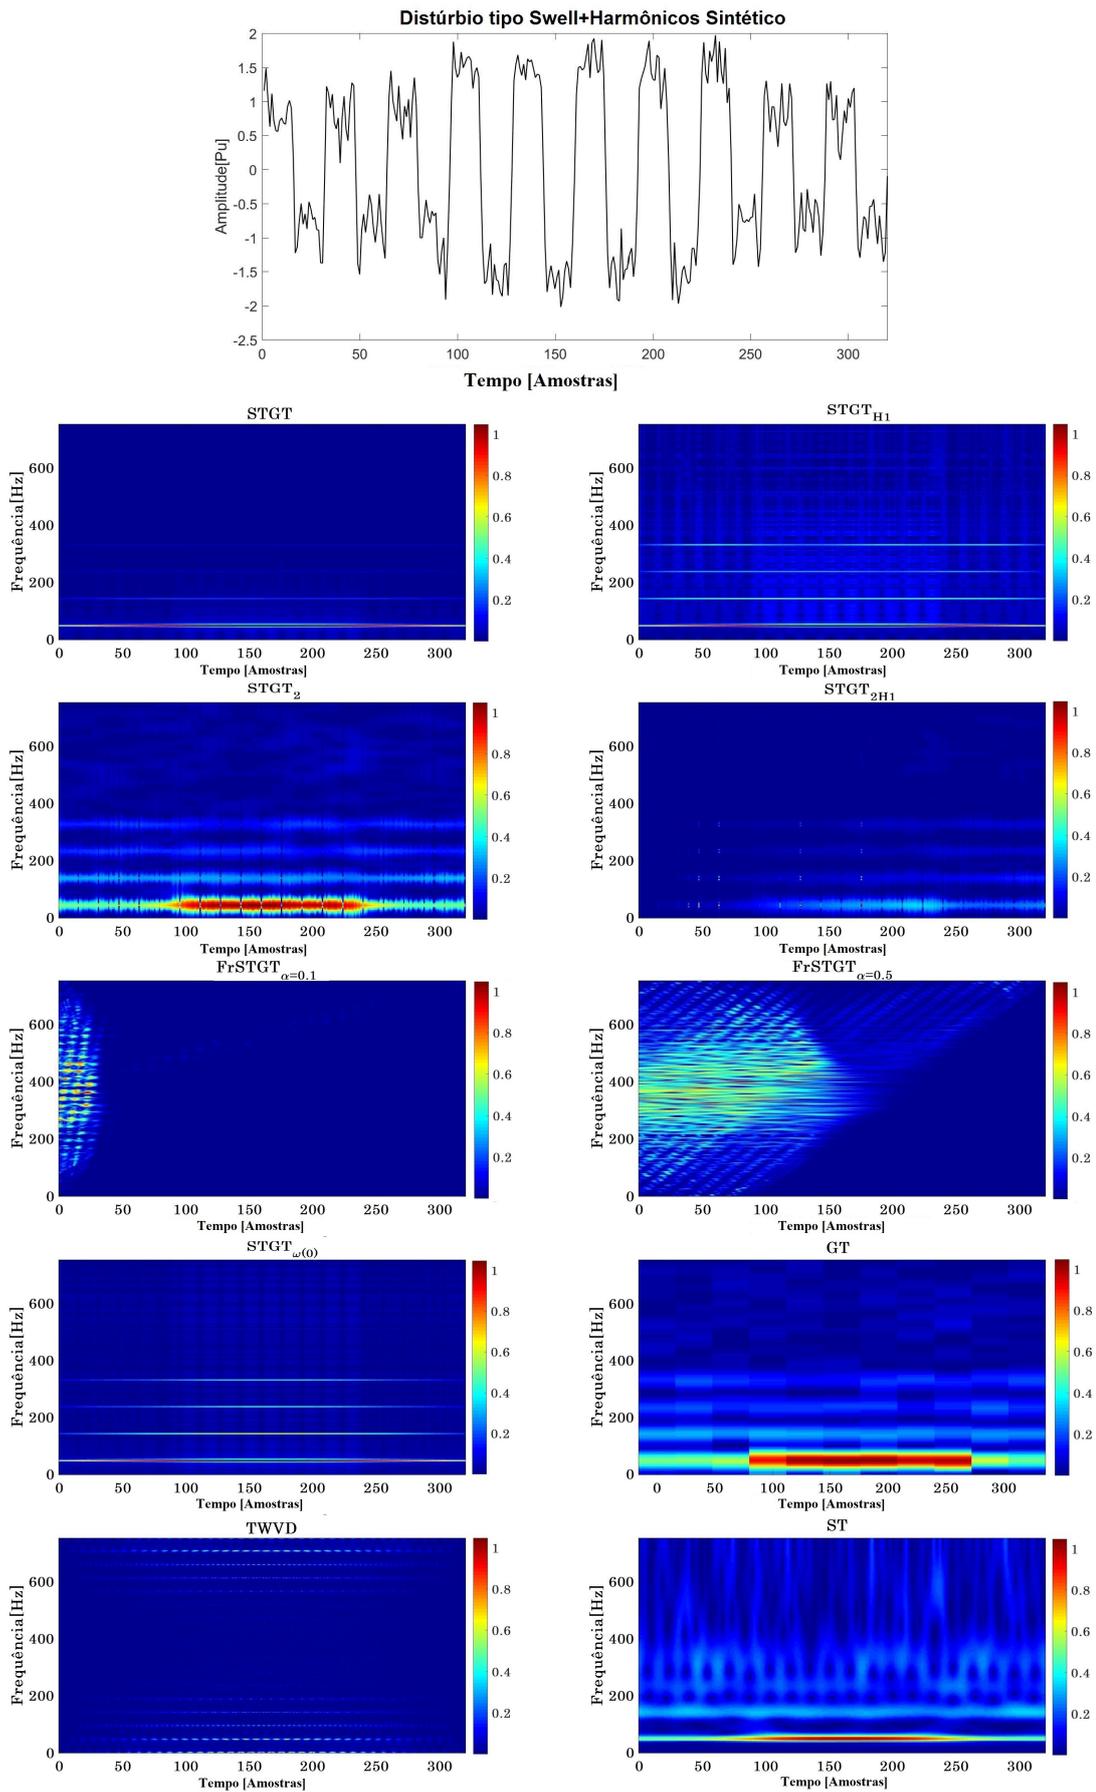


Figura 4.11: Aplicação das Transformadas a um Distúrbio Sintético tipo Swell+Harmônico.

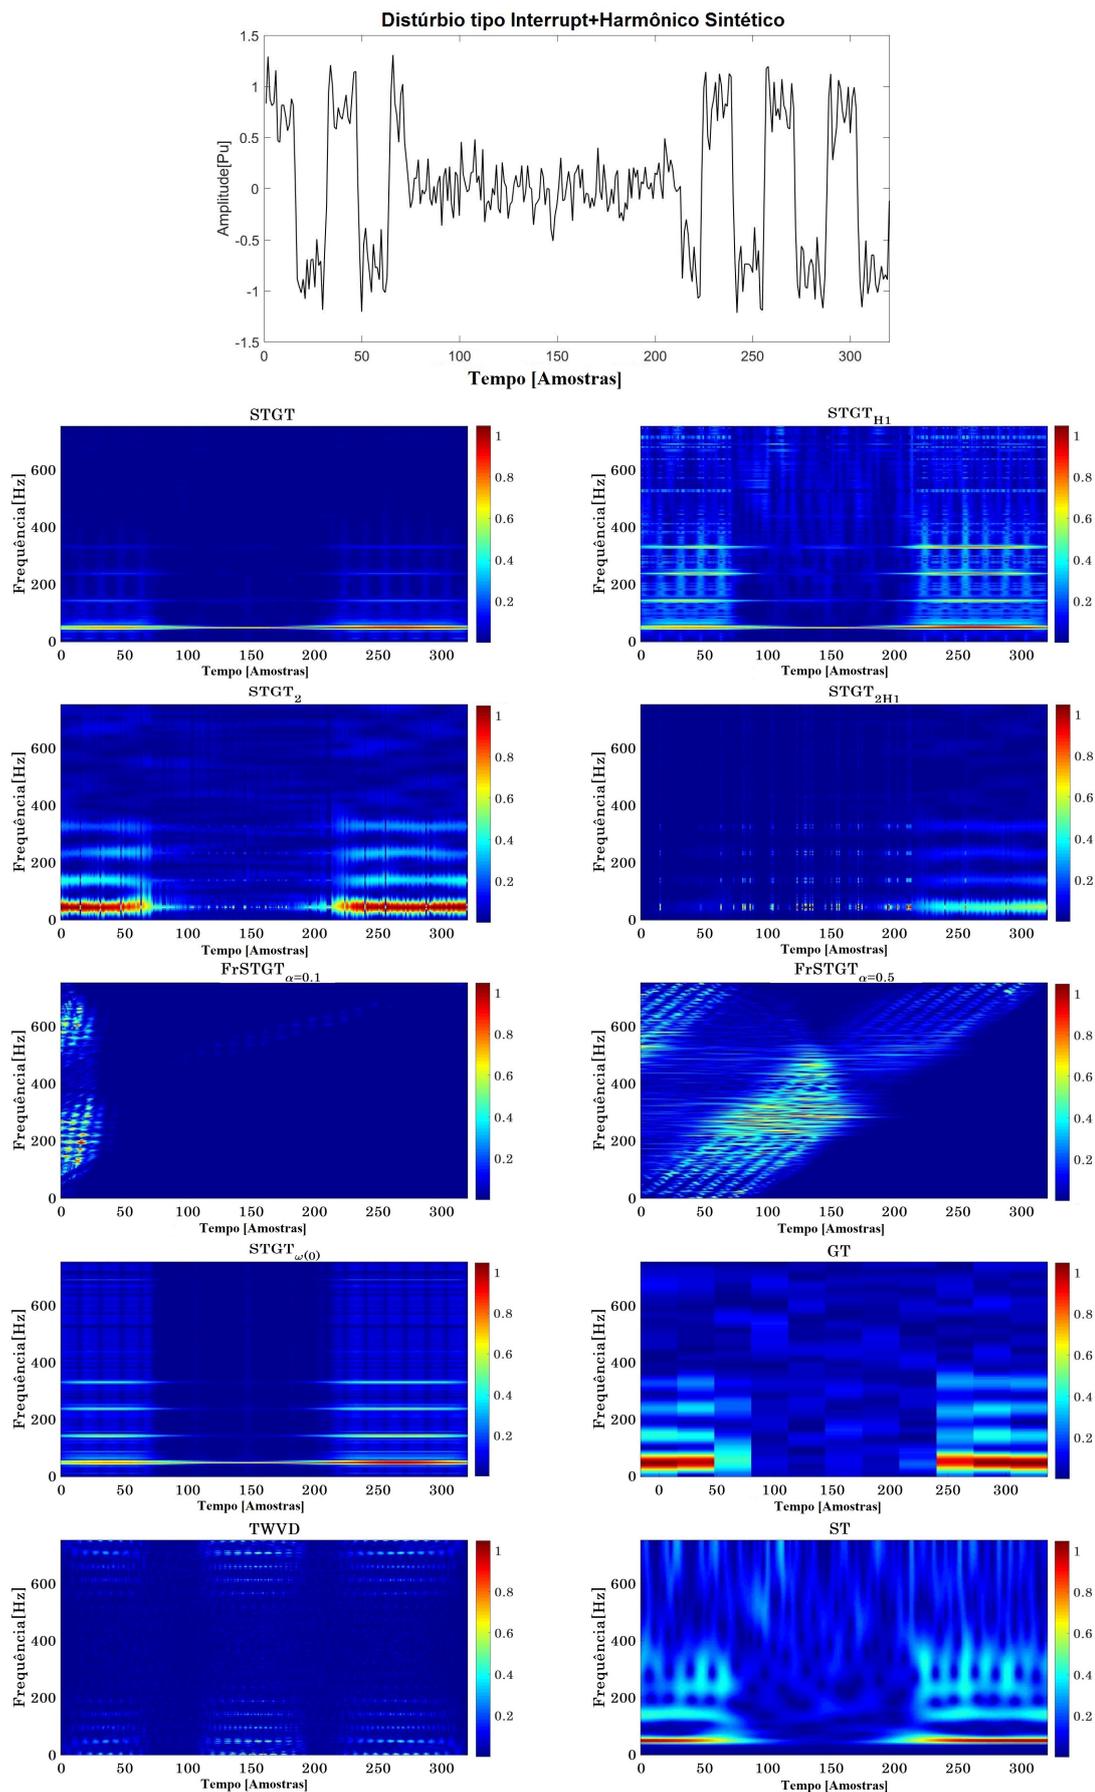


Figura 4.12: Aplicação das Transformadas a um Distúrbio Sintético tipo Interrupt + Harmônico.

Em resumo, destacamos da análise dos sinais do MATLAB, os índices de classificação alcançados pelas transformadas sintonizadas quando utilizadas com as redes neurais — $STGT_2$ (99,25%), $STGT_{H1}$ (99,05%) —, e com as árvores de decisão — $STGT_2$ (99,4%) e $STGT_{H1}$ (99,17%), sendo que a tradicional transformada S (ST) aparece como terceira melhor opção, com os índices de 98,07% para ANN, e 98,62% para DT. As transformadas sintonizadas fracionárias alcançaram baixos índices de classificação, em comparação às anteriores — $STGTF_{Frac.\alpha=0,1}$, 89,97% para ANN — o que já era esperado, pois, por inspeção visual, nota-se a descaracterização do espectro por estas transformadas. Também a TWVD obteve baixo índice de classificação (91,96% para ANN) sendo este o segundo menor índice de classificação geral. Com relação aos classificadores, a classificação por similaridade teve a pior performance, com índice médio de classificação de 90,29% , seguido pelo classificador SVM, com média de 93,47%. Os classificadores ANN e DT obtiveram índices médios de 95,53% e 97,74% respectivamente, como se verifica pelos dados da Tabela 4.2.

4.3 Sinais Experimentais IEEE e PSCOPE

Visando melhor avaliar a eficiência do método proposto, foram considerados também distúrbios adquiridos pelo grupo de trabalho *P1159.3* do IEEE (*Institute of Electrical and Electronics Engineers*),² e também por um grupo de pesquisa da Universidade Federal de Juiz de Fora, o PSCOPE (*Processamento de Sinal e Inteligência Computacional Aplicada a Sistemas de Potência*).³ A utilização destas duas bases de dados amplia a diversidade dos tipos de distúrbios analisados aqui (são dez tipos distintos de distúrbios a serem classificados, conforme Tabela 4.3).

Nesta etapa do trabalho, foram utilizados 100 sinais com uma frequência de amostragem de 15.360 Hz, correspondendo a aproximadamente 4 ciclos da componente fundamental (60 Hz). Exemplos desses sinais são apresentados abaixo, nas Figs. 4.15 a 4.17. Verifica-se que não há uniformidade nos dados quanto ao ruído, cuja intensidade não é informada. As figuras apresentam também os resultados da aplicação das transformadas tempo-frequência, merecendo destaque os espectrogramas da $STGT_2$ e da $STGT_{H1}$, que proporcionam a melhor resolução para os distúrbios analisados, evidenciando o início e o final da sua ocorrência.

A Tabela 4.3 traz o resumo geral da classificação obtida, enquanto o gráfico de barras da Figura 4.13 permite avaliar o grau de dificuldade apresentado por cada distúrbio, destacando-se como mais difíceis os *Notches* e o distúrbio composto *Interrupt+Harmônicos* (índice de classificação de 81,75%), enquanto no outro extremo se encontram os distúrbios do tipo *Harmonics*, com índice de classificação de 95,8%. Já o gráfico de barras da Fig. 4.14 apresenta os dados de desempenho das transformadas TF, representados em porcentagem de classificação correta. Aqui, o destaque cabe à $STGT_2$, com 90,2%, 94,4%, 92,3% e 94,7%, respectivamente, quando empregada com os classificadores *Sim*, *ANN*, *SVM* e *DT*, e para a $STGT_{H1}$, com 90,2%, 93,5%, 73,5% e 94,2%, nos mesmos casos. Em comparação, a ST obteve 89,4%, 90,7%, 88,3% e 91,9%, respectivamente, com os mesmos classificadores.

²O IEEE 1159.3 é um Grupo de Trabalho que tem por objetivo fornecer ao setor de qualidade de energia as especificações de sinais de dados, por meio de um padrão de formato aberto para a transferência de dados de qualidade de energia entre instrumentos e computadores. Esse padrão de transferência permite o processamento e a análise de medições de qualidade de energia usando dados de vários fornecedores e de vários dispositivos. Disponível em <http://grouper.ieee.org/groups/1159/3/docs.html>

³O PSCOPE é um grupo de pesquisa que busca desenvolver soluções completas para monitoramento, diagnóstico, proteção e controle de sistemas de potência baseadas em Processamento Digital de Sinais (DSP) e Inteligência Computacional (CI). A filosofia de design do grupo baseia-se em três pilares: hardware, software e algoritmos. Disponível em <http://www.ufjf.br/pscope-eng/ieee-task-force/database/>

Tabela 4.3: Classificação de Distúrbios - IEEE e PSCOPE

Transformadas	Classificadores	Distúrbios Analisados										Performance Total
		Sags	Swells	Interrupts	Harmonics	Transients	Spikes	Notches	Sags+Harmonics	Swells+Harmonics	Interrupt+Harmonics	
STGT	Sim	75	80	71	84	83	77	72	78	88	88	79,6
	ANN	84	89	98	100	95	81	77	83	80	79	86,6
	SVM	78	81	73	87	88	80	75	81	82	89	81,4
	DT	88	90	98	97	96	82	80	85	82	84	88,2
STGT _{H1}	Sim	88	95	99	97	93	81	86	98	88	77	90,2
	ANN	95	100	100	100	96	84	87	100	97	76	93,5
	SVM	54	80	71	97	94	79	77	33	67	86	73,8
	DT	93	100	100	100	98	87	88	97	94	84	94,2
STGT ₂	Sim	89	90	95	98	96	87	83	93	87	84	90,2
	ANN	94	93	97	100	97	92	87	98	95	91	94,4
	SVM	91	92	99	97	98	90	84	96	89	87	92,3
	DT	94	95	99	100	93	90	92	98	92	94	94,7
STGT _{2H1}	Sim	84	77	74	97	82	82	87	73	57	76	78,9
	ANN	93	90	87	98	61	87	58	94	59	89	81,6
	SVM	93	80	98	100	86	87	91	83	68	79	86,5
	DT	93	81	78	100	86	78	82	75	59	80	81,2
STGT _{ω_0}	Sim	88	87	94	87	86	87	92	94	88	79	88,2
	ANN	94	90	100	100	96	80	76	100	98	79	91,3
	SVM	82	82	94	92	83	76	81	93	87	90	86
	DT	94	90	100	93	96	87	91	94	88	79	91,2
FrSTGT _{$\alpha=0,1$}	Sim	78	78	79	77	63	76	70	73	78	74	74,6
	ANN	69	81	91	100	89	87	67	49	67	79	77,9
	SVM	83	97	83	85	89	78	70	43	62	66	75,6
	DT	84	81	91	100	60	87	82	47	88	79	79,9
FrSTGT _{$\alpha=0,5$}	Sim	88	79	79	82	73	76	67	87	85	81	79,7
	ANN	77	91	82	99	78	87	74	100	88	79	85,5
	SVM	88	95	88	90	83	82	67	46	80	71	79
	DT	93	81	73	100	86	78	82	75	59	80	80,7
GT	Sim	88	95	93	97	82	76	77	73	71	66	81,8
	ANN	93	91	100	99	87	87	91	94	80	72	89,4
	SVM	83	71	74	100	79	72	76	83	70	79	78,7
	DT	93	91	91	100	78	87	91	94	98	89	91,2
TWVD	Sim	88	95	92	87	73	76	80	87	77	82	83,7
	ANN	85	91	65	99	73	79	84	94	98	89	85,7
	SVM	93	80	100	100	96	87	91	83	68	79	87,7
	DT	84	91	100	99	87	87	91	100	88	79	90,6
ST	Sim	84	92	94	96	98	90	87	83	85	85	89,4
	ANN	94	98	94	100	96	87	75	86	86	91	90,7
	SVM	82	97	92	98	98	77	76	89	87	87	88,3
	DT	94	97	94	100	87	87	91	88	88	93	91,9
Total		86,6	88,35	89,5	95,8	86,45	82,92	80,87	83	81,2	81,75	

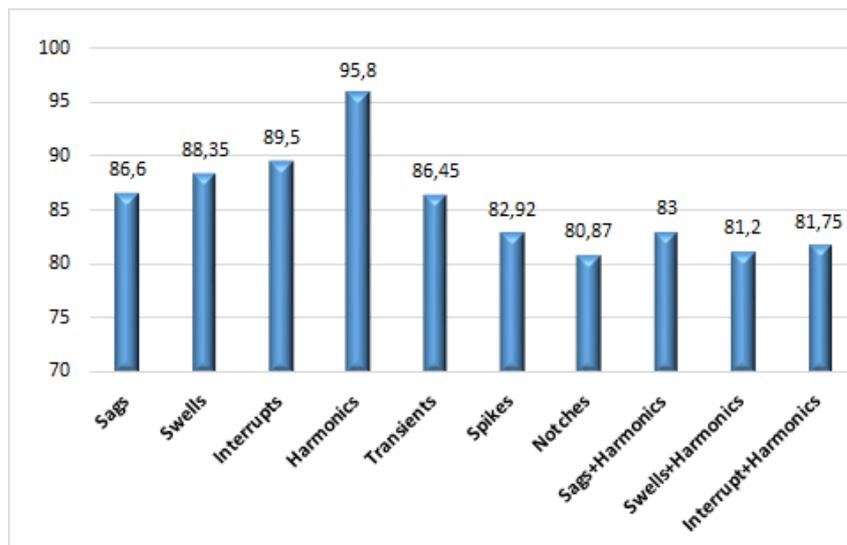


Figura 4.13: Nível de Classificação dos Distúrbios Analisados - IEEE e PSCOPE

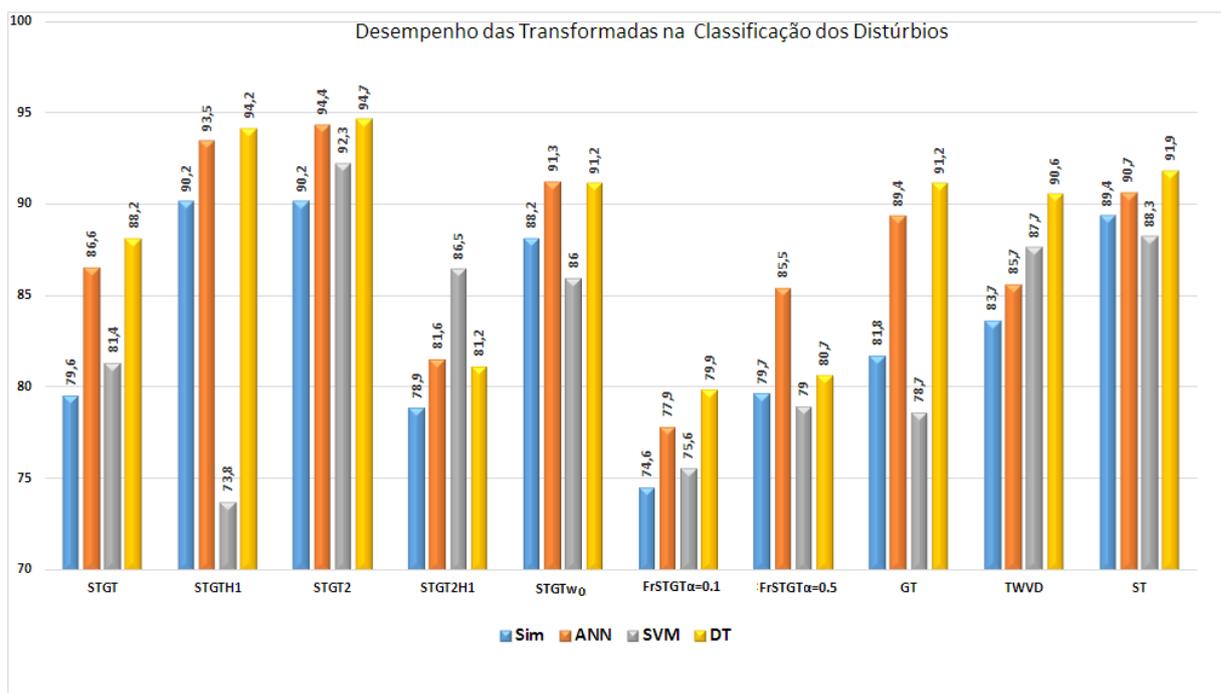


Figura 4.14: Desempenho das Transformadas na Classificação dos Distúrbios - IEEE e PSCOPE.

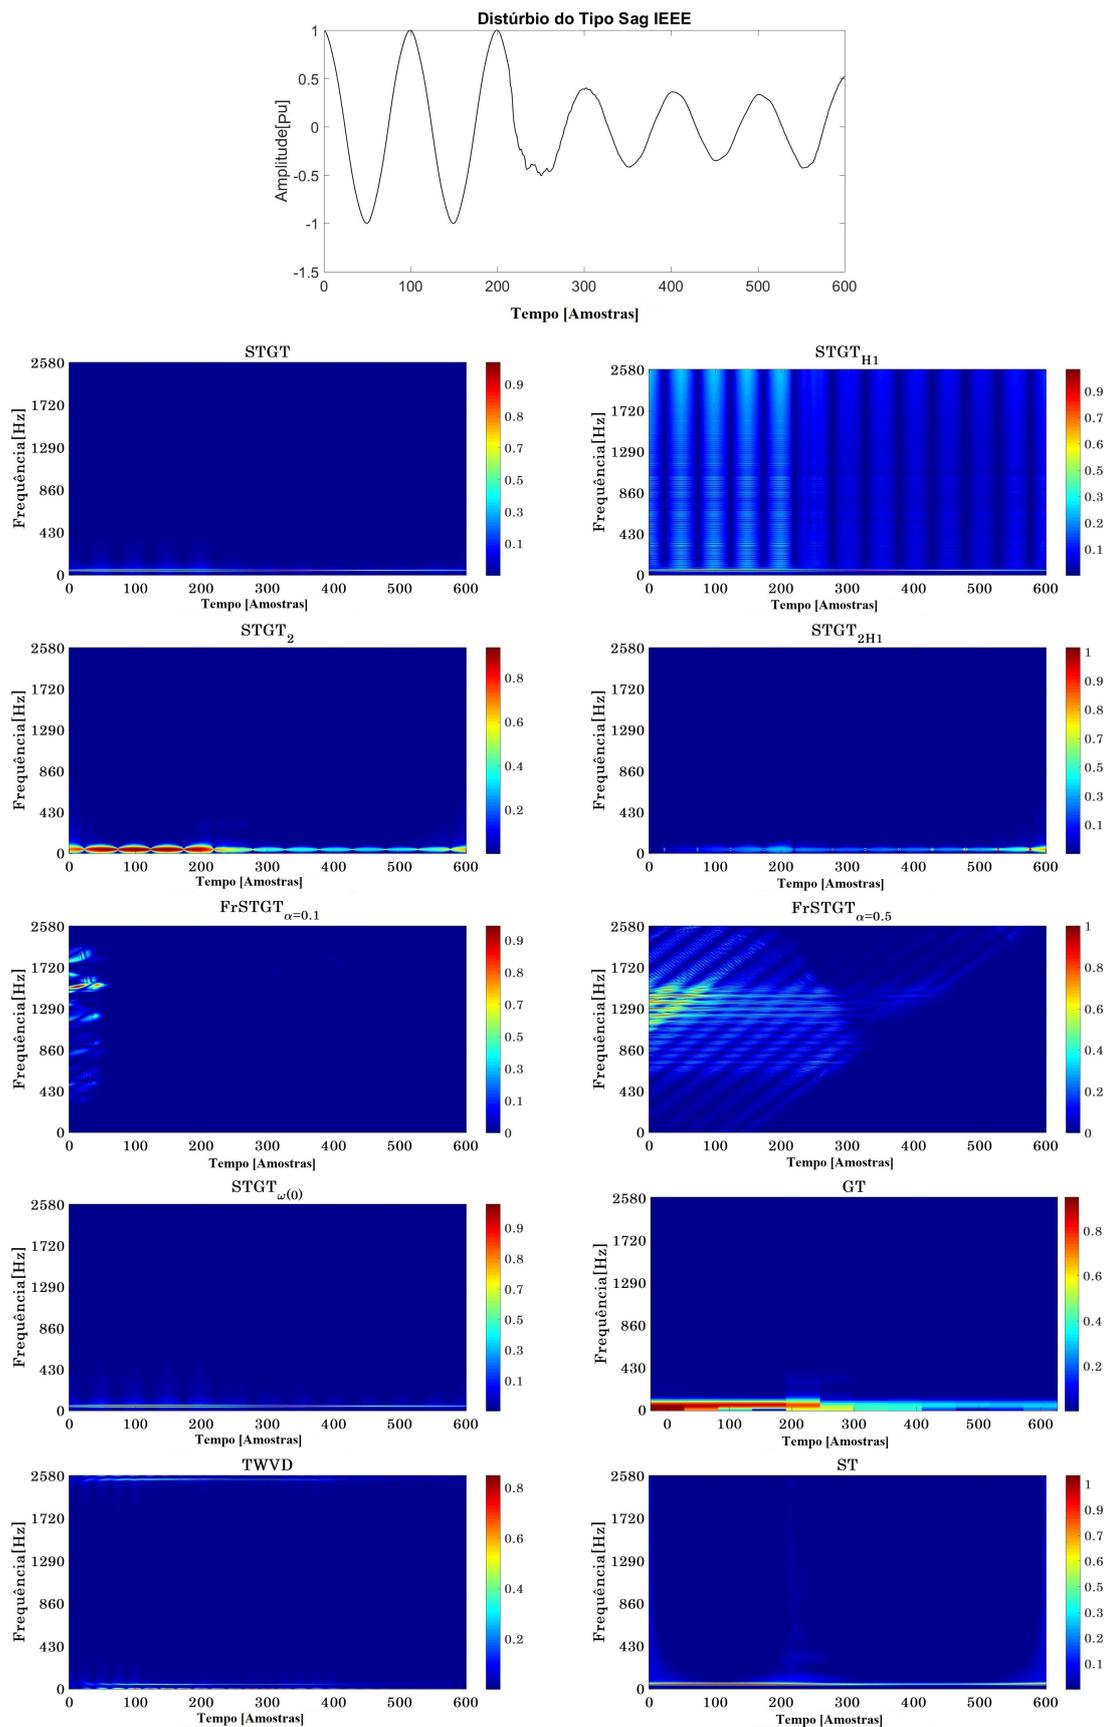


Figura 4.15: Aplicação das Transformadas a um Distúrbio tipo Sag - IEEE e PSCOPE.

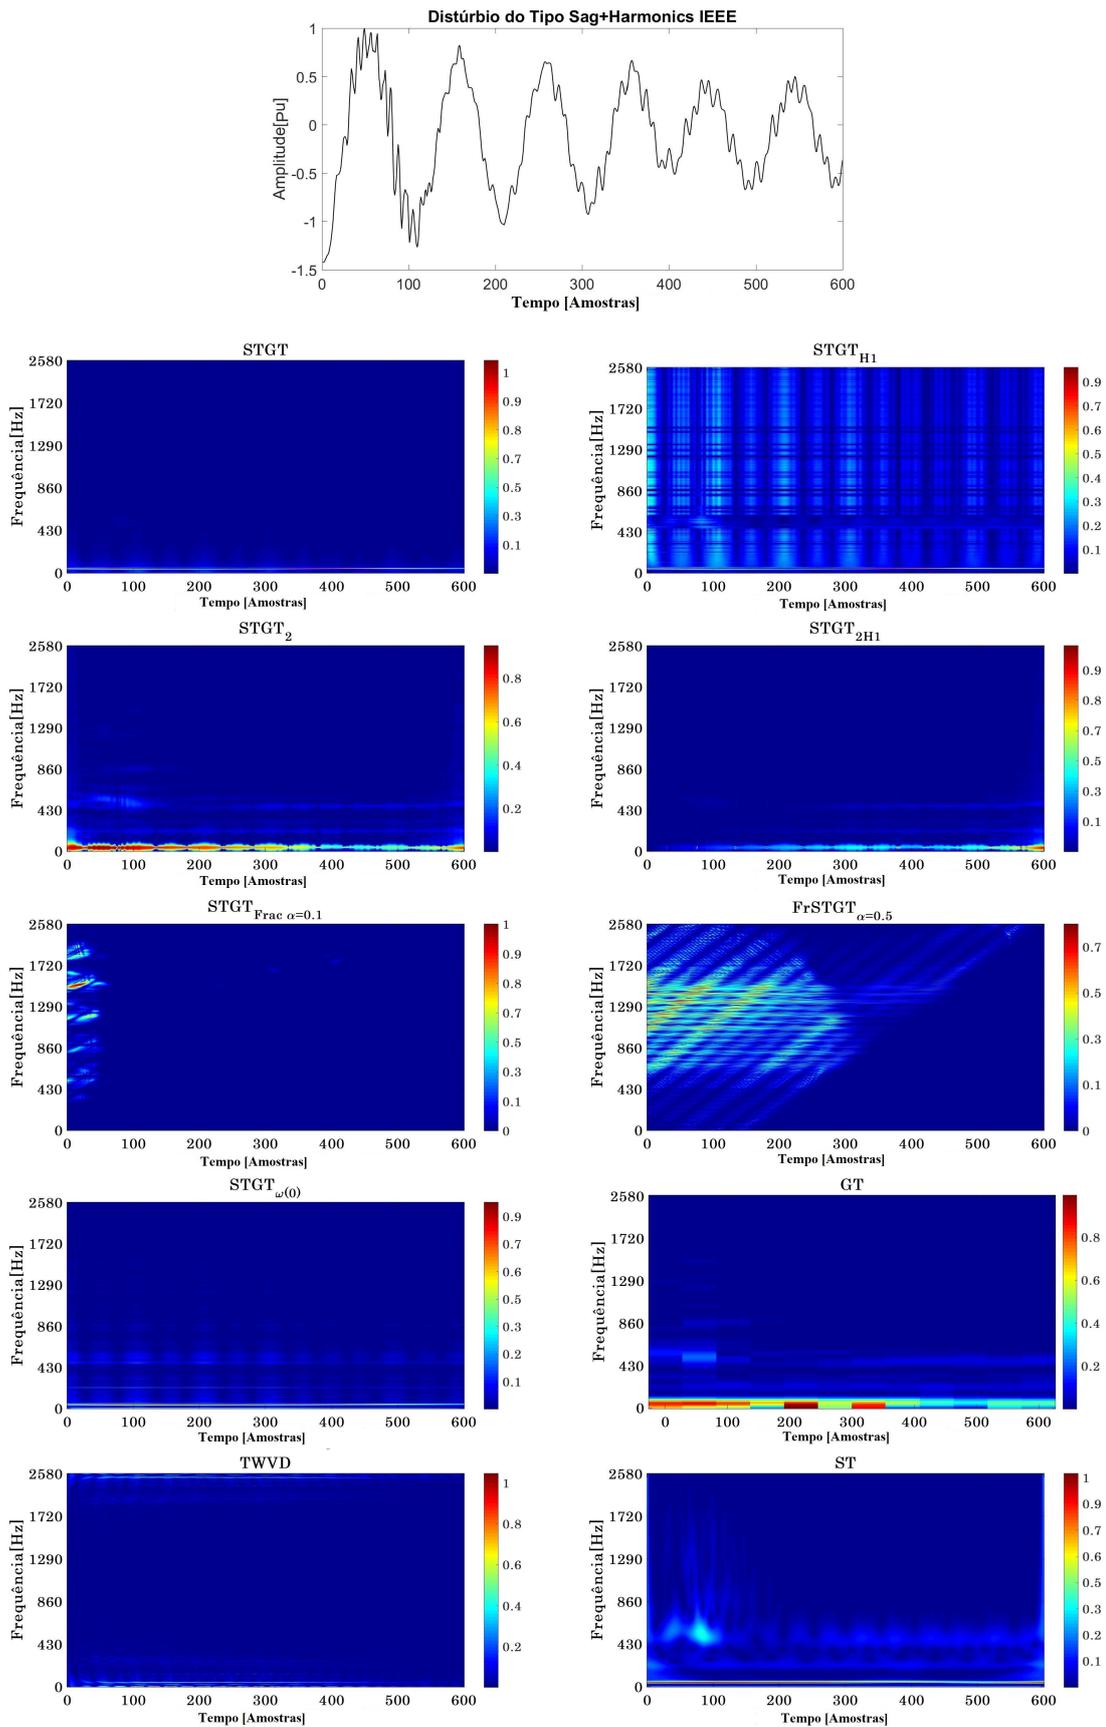


Figura 4.16: Aplicação das Transformadas a um Distúrbio tipo Sag+Harmônico - IEEE e PSCOPE.

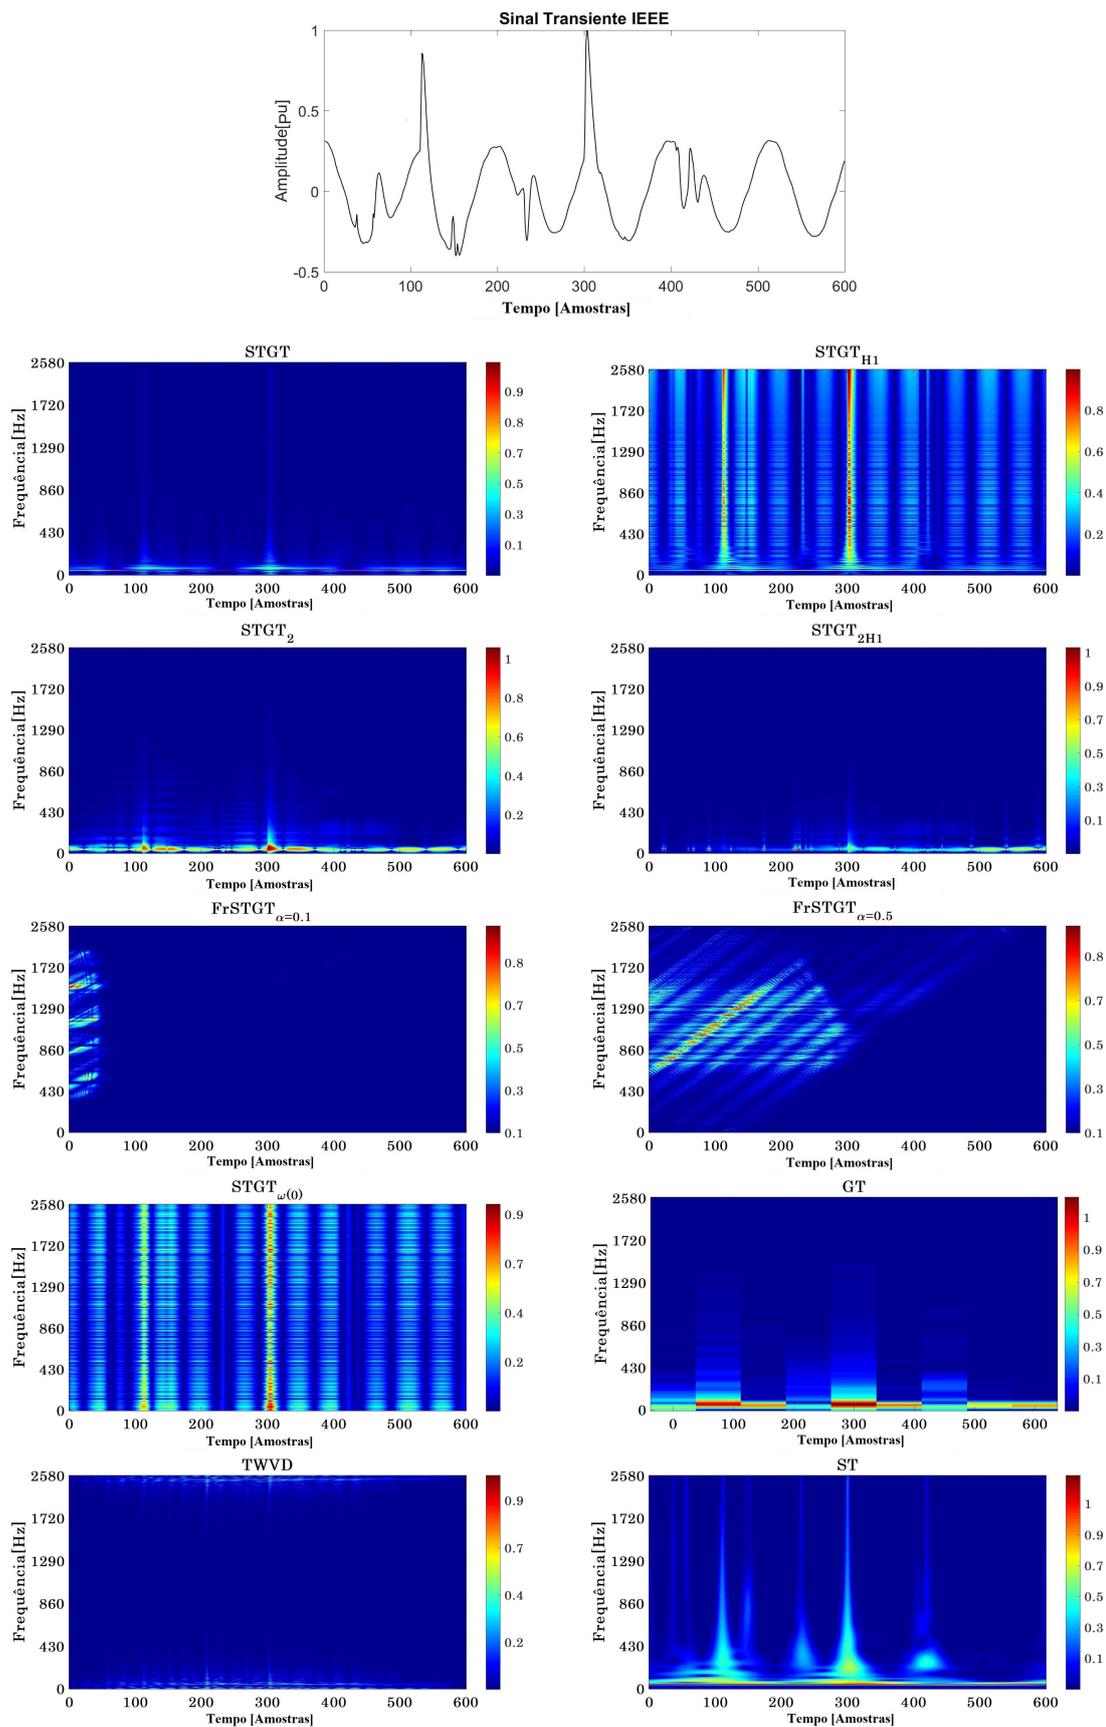


Figura 4.17: Aplicação das Transformadas em um distúrbio tipo Transiente - IEEE e PSCOPE

4.4 Sinais de Laboratório

Finalmente, com o objetivo de corroborar os resultados obtidos com os sinais sintéticos, nós utilizamos o Kit Educacional QEE2910, da empresa Datapool,⁴ para gerar sinais que ilustram situações semelhantes às ocorridas em sistemas elétricos reais. No laboratório do IFTM, foram gerados dez sinais de cada tipo de distúrbio, a saber: *Sags*, *Swells*, *Interrupts*, *Notches*, *Spikes*, *Transients*, *Harmonics*, *Sags + Harmonics*, *Swells + Harmonics* e *Interrupts + Harmonics*, totalizando cem tipos distintos de sinais gerados em laboratório. As Figs. 4.21 a 4.22 exemplificam tais sinais.

A apresentação dos resultados segue o mesmo formato das seções anteriores. Na Tabela 4.4 temos o resumo geral da classificação obtida por cada transformada TF, quando utilizada com cada um dos classificadores (*Similaridade*, *ANN*, *SVM*, *DT*), para cada tipo de distúrbio analisado. A última coluna da tabela mostra o índice médio de desempenho de cada transformada, de acordo com cada classificador, destacando-se em negrito os melhores resultados gerais, obtidos pela $STGT_2$ (índice de 91,9% para o classificador DT, e 91,8% para o classificador ANN), seguindo-se a $STGT_{H1}$, com 91,8% para o classificador DT e 91% para a ANN.

A Figura 4.19 apresenta histogramas de dados retirados da Tabela 4.4, permitindo avaliar o desempenho individual de cada transformada quando associada a cada tipo de classificador. De modo semelhante, a Figura 4.18 permite avaliar o desempenho geral das transformadas na classificação dos dez tipos de distúrbios considerados, cabendo destacar como distúrbios mais difíceis os *Notches* (índice de 68,8%) e os distúrbios múltiplos do tipo *Interrupt+Harmônico* (índice de 70,5%), no outro extremo encontrando-se os distúrbios do tipo *Harmônico*, para os quais se obteve a maior porcentagem de classificação correta (79,6%).

⁴Datapool Eletrônica é uma empresa nacional fundada em 1984 com vistas a atender à demanda por Kits didáticos confiáveis para aulas de eletroeletrônica. É a pioneira do Brasil no desenvolvimento e fabricação de Módulos Didáticos para a difusão de conhecimento técnico em diversas áreas, tais como eletroeletrônica digital e de potência, comunicação, micro-controladores, controle e automação industrial. O Kit QEE2910 encontra-se disponível em <http://eletronica.datapool.com.br/produtos/electricidade/modulo-qee-2910-qualidade-de-energia-eletrica/> (Acessado em 06/10/2017).

Tabela 4.4: Classificação de Distúrbios - Lab. do IFTM.

Transformadas	Classificadores	Distúrbios Analisados										Performance Total
		Sags	Swells	Interrupts	Harmonics	Transients	Spikes	Notches	Sags+Harmonics	Swells+Harmonics	Interrupt+Harmonics	
STGT	Sim	77	78	74	80	79	73	69	74	84	85	77,3
	ANN	86	87	91	96	91	77	74	79	76	76	83,3
	SVM	80	79	76	83	84	76	72	77	78	86	79,1
	DT	90	88	91	93	92	78	77	81	78	81	84,9
STGT _{H1}	Sim	89	93	96	93	89	77	83	94	84	74	87,2
	ANN	96	99	100	98	90	80	84	97	93	73	91
	SVM	85	75	78	93	90	75	74	82	78	83	81,3
	DT	94	100	97	99	92	83	85	93	90	81	91,4
STGT ₂	Sim	90	88	95	97	92	83	80	89	83	81	87,8
	ANN	95	91	96	98	93	88	84	94	91	88	91,8
	SVM	92	90	96	98	94	86	81	92	85	84	89,8
	DT	95	93	96	98	89	86	89	94	88	91	91,9
STGT _{2H1}	Sim	86	75	71	93	78	78	84	69	53	73	76
	ANN	95	88	84	98	57	83	55	90	55	86	79,1
	SVM	95	77	85	91	81	79	78	75	54	72	78,7
	DT	95	79	75	98	82	74	79	71	55	77	78,5
STGT _{ω_0}	Sim	89	85	96	83	82	83	89	90	84	76	85,7
	ANN	95	88	100	98	92	76	73	99	94	76	89,1
	SVM	83	80	96	88	79	72	78	89	83	87	83,5
	DT	95	88	100	89	92	83	88	90	84	76	88,5
FrSTGT _{$\alpha=0,1$}	Sim	80	76	81	73	59	72	67	69	74	71	72,2
	ANN	71	79	93	98	85	83	64	45	63	76	75,7
	SVM	85	95	85	81	85	74	67	42	70	63	74,7
	DT	86	79	93	98	56	83	79	43	84	76	77,7
FrSTGT _{$\alpha=0,5$}	Sim	90	77	81	78	69	72	64	83	81	78	77,3
	ANN	79	89	84	98	74	83	71	99	84	76	83,7
	SVM	90	93	90	86	79	78	64	42	76	68	76,6
	DT	95	79	75	98	82	74	79	71	55	77	78,5
GT	Sim	90	93	95	93	78	72	74	69	67	63	79,4
	ANN	95	89	100	98	83	83	88	90	76	69	87,1
	SVM	85	69	76	98	75	68	73	79	70	76	76,9
	DT	95	89	93	98	74	83	88	90	94	86	89
TWVD	Sim	90	93	94	83	69	72	77	83	73	79	81,3
	ANN	87	89	67	98	69	75	81	90	94	86	83,6
	SVM	95	78	100	98	92	83	88	79	74	76	86,3
	DT	86	89	100	98	83	83	88	99	84	76	88,6
ST	Sim	85	90	96	92	94	86	84	79	81	82	86,9
	ANN	95	95	96	98	95	83	79	82	82	88	89,3
	SVM	83	95	94	98	94	80	77	85	83	84	87,3
	DT	95	95	96	98	83	83	88	84	84	90	89,6
Total		88,97	86,3	89,55	93,1	82,4	79	77,9	80,55	77,97	78,65	

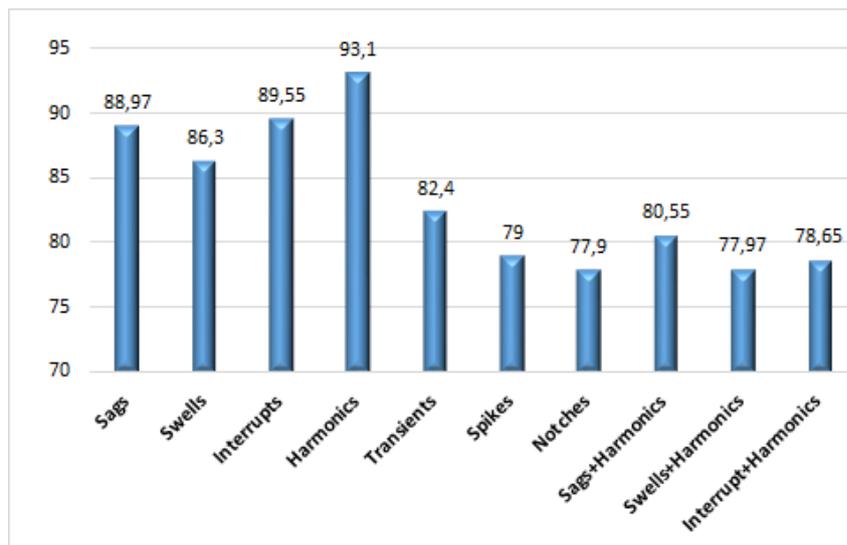


Figura 4.18: Nível de Classificação dos Distúrbios Analisados - Lab. do IFTM.

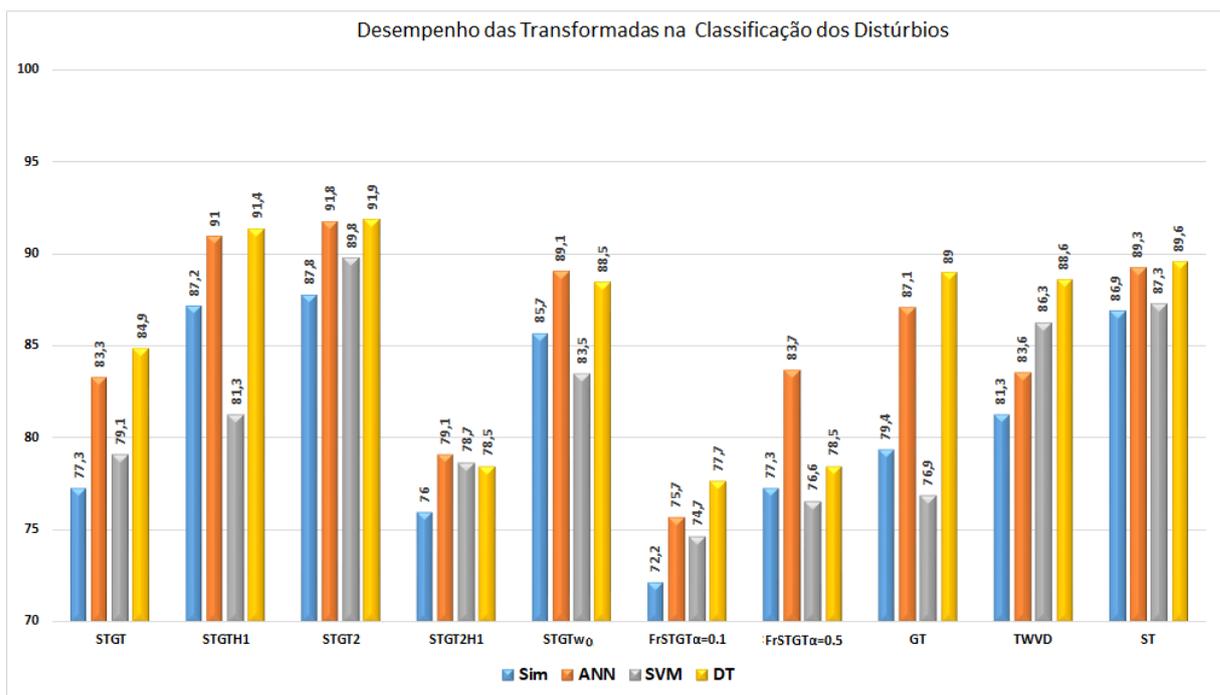


Figura 4.19: Desempenho das Transformadas na Classificação dos Distúrbios - Lab. do IFTM.

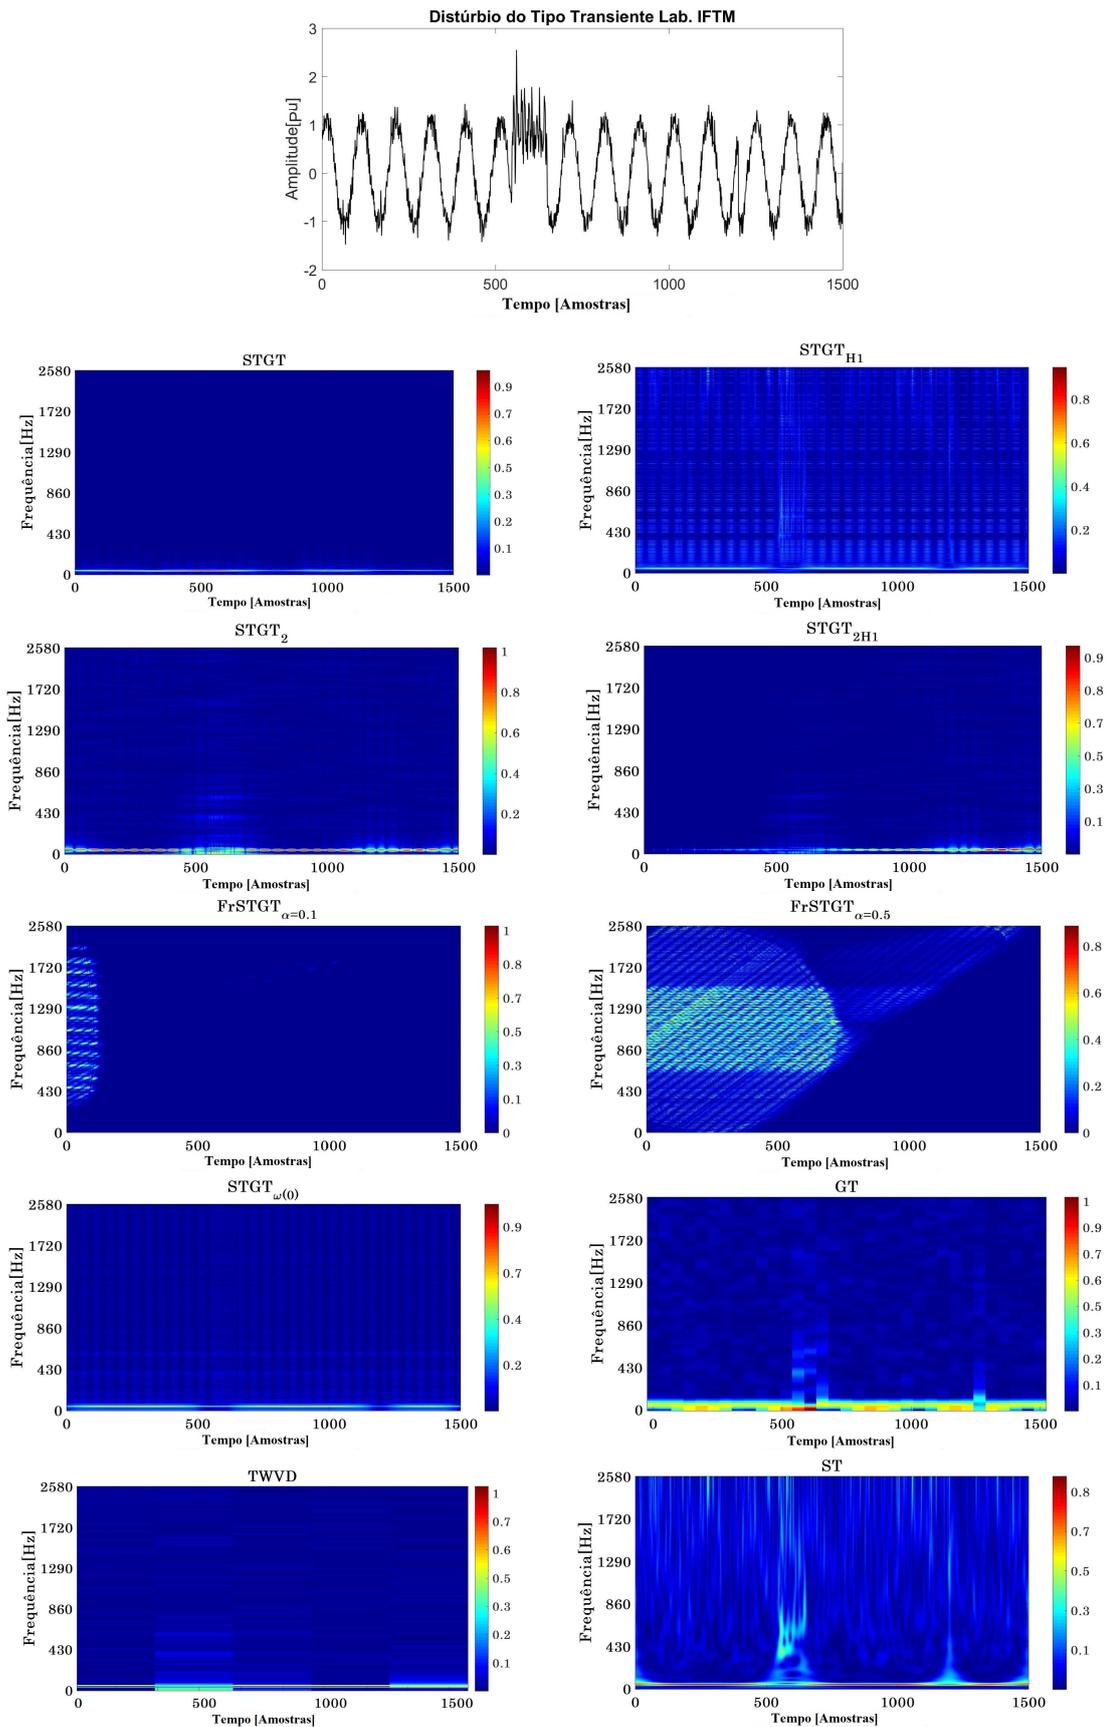


Figura 4.20: Aplicação das Transformadas a um Distúrbio tipo Transiente criado no Laboratório do IFTM.

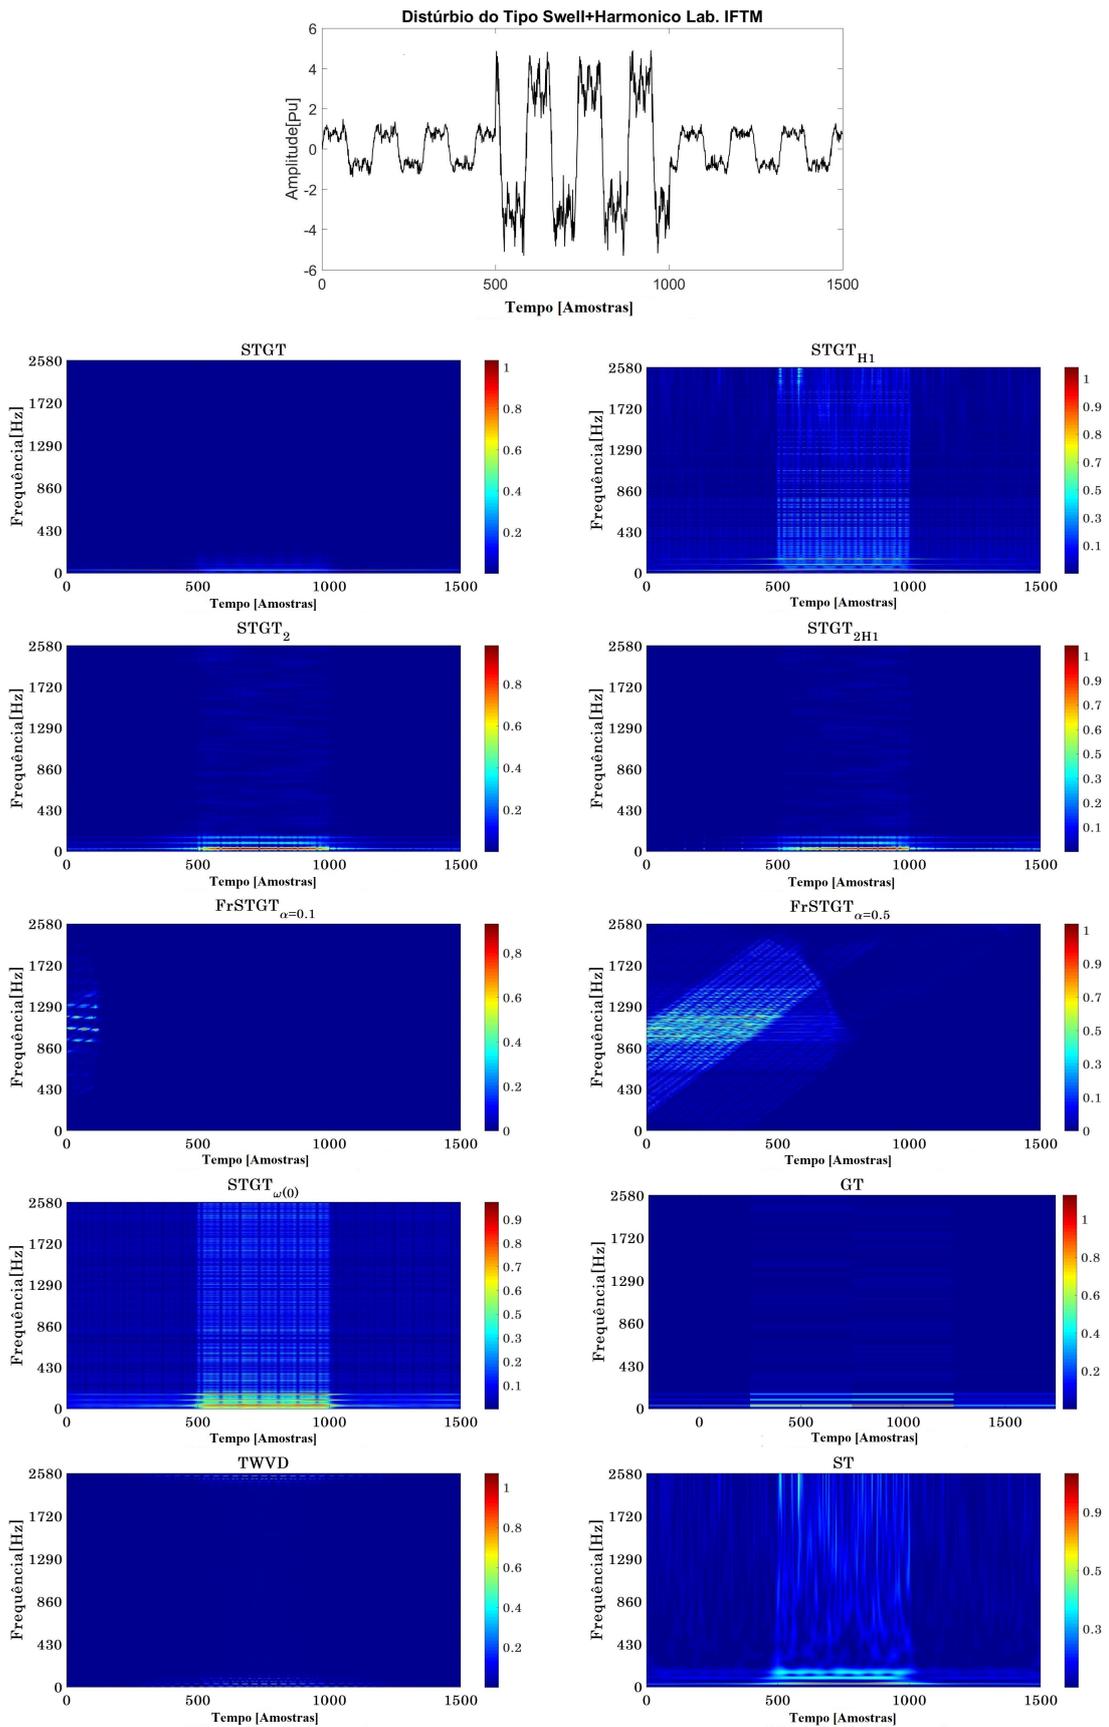


Figura 4.21: Aplicação das Transformadas a um Distúrbio tipo Transiente criado no Laboratório do IFTM.

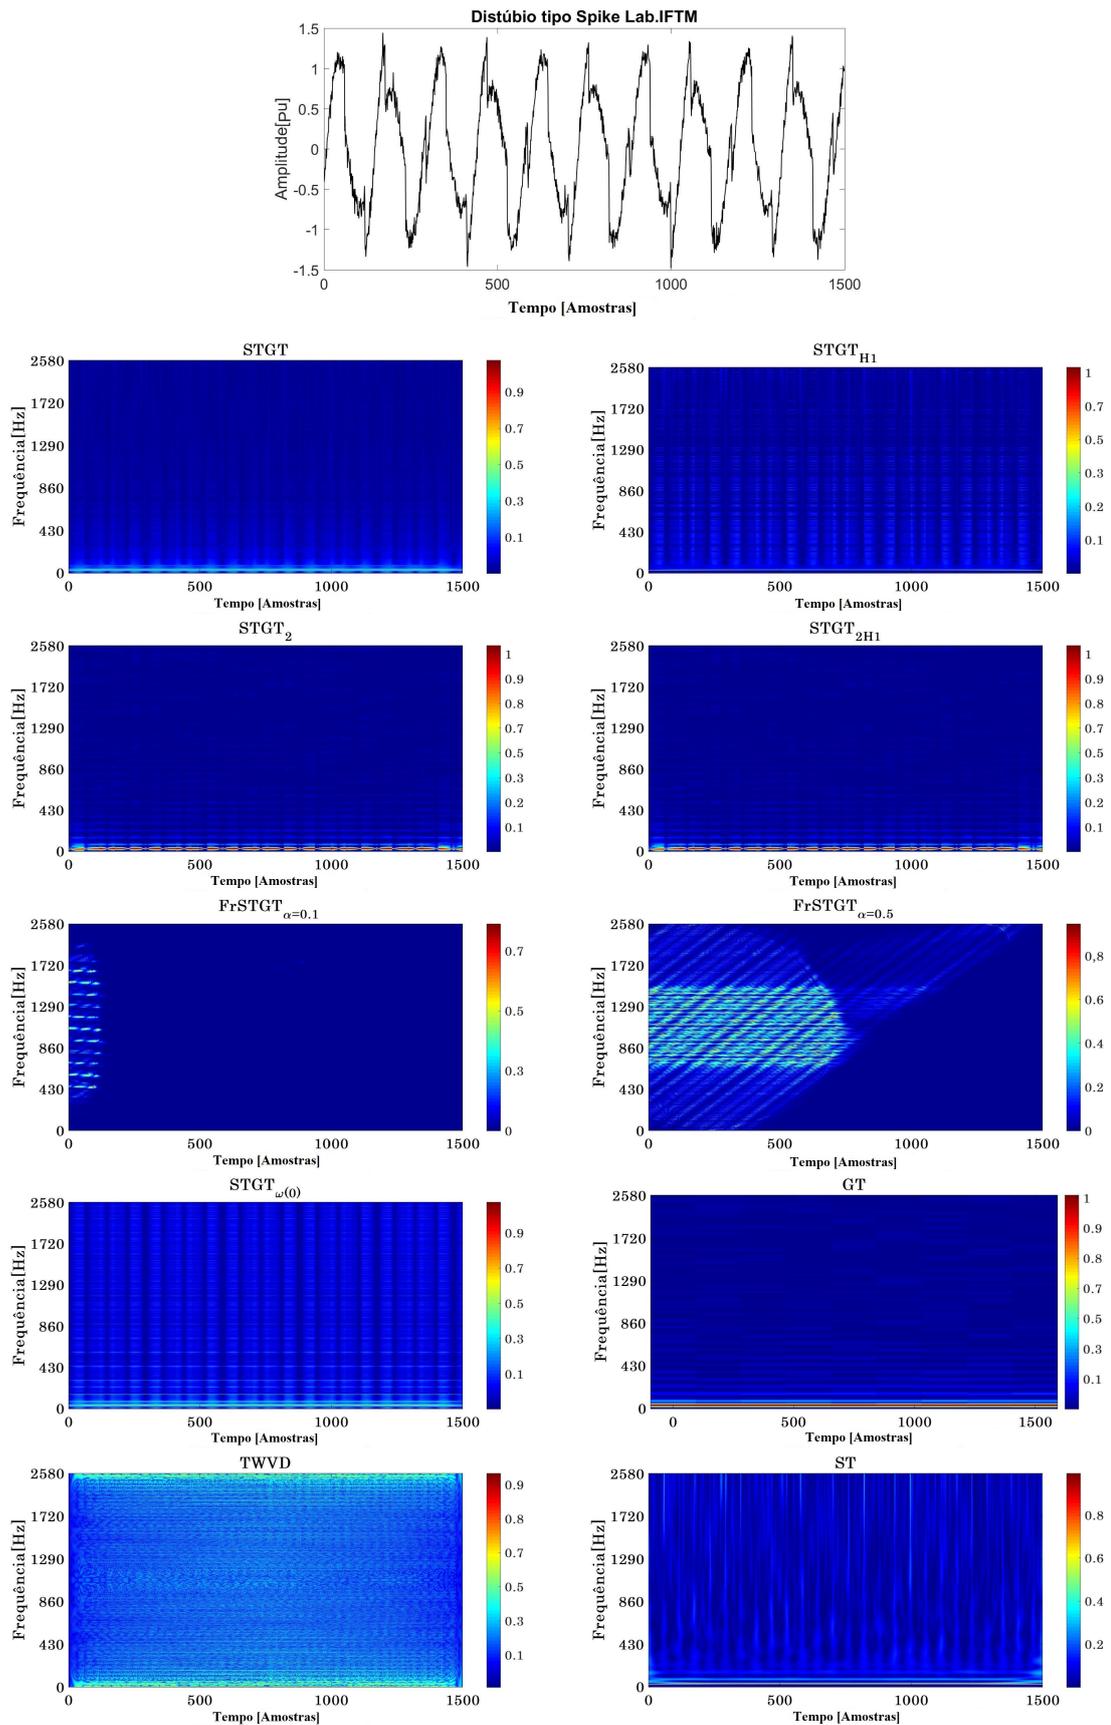


Figura 4.22: Aplicação das Transformadas a um Distúrbio tipo Spike criado no Laboratório do IFTM.

4.5 Classificação Geral

Para a análise do desempenho geral das abordagens consideradas, o gráfico da Fig. 4.23 apresenta os resultados do cálculo da média dos índices de classificação obtidos com as quatro transformadas TF que obtiveram maior índice de classificação nas três bases de dados utilizadas – Sintéticos, IEEE-PSCOPE e Lab. IFTM – totalizando 5200 sinais com distúrbio. Observa-se, pelos dados, o bom desempenho das transformadas $STGT_2$ e $STGT_{H1}$, com os maiores índices de classificação geral, entre 89,87% a 98,08%. Ressalta-se ainda o desempenho da transformada $STGT_{\omega_0}$, que obteve índices de classificação maiores que a tradicional ST – exceto para a base do IFTM –, com valores entre 86,10% a 96,47%. Para verificar o grau de dispersão, em torno da média, dos índices de desempenho das quatro transformadas em questão, calculou-se o desvio padrão (σ) para o conjunto de dados do gráfico da Fig. 4.23, obtendo-se os seguintes valores: $\sigma = 3,65$ para $STGT_2$, $\sigma = 3,90$ para a $STGT_{H1}$, $\sigma = 4,74$ para a $STGT_{\omega_0}$ e $\sigma = 3,86$ para ST. Os baixos valores do desvio padrão indicam a uniformidade dos resultados obtidos.

No que se refere à precisão dos classificadores, a Tabela 4.5 apresenta três métricas de erro fornecidas pelo software de classificação *WEKA*: o erro médio absoluto, o erro quadrático médio e o coeficiente Kappa. A interpretação dos valores métricos do erro médio absoluto e do erro quadrático médio é clara – quanto mais próximo de zero, melhor. Já o coeficiente Kappa é uma métrica que avalia o nível de consistência de uma tarefa de classificação, indicando que os dados classificados têm uma certa coerência. Quanto mais o Kappa se aproxima de 1, mais a concordância entre as classes previstas tende a ser exata. Os valores da tabela demonstram a consistência dos dados obtidos, com o erro médio absoluto e o erro quadrático médio situando-se entre 0,085 e 0,010, e ente 0,210 e 0,551, respectivamente, enquanto o valor do coeficiente Kappa situa-se entre 0,890 e 0,970. A tabela também evidencia a superioridade do classificador DT.

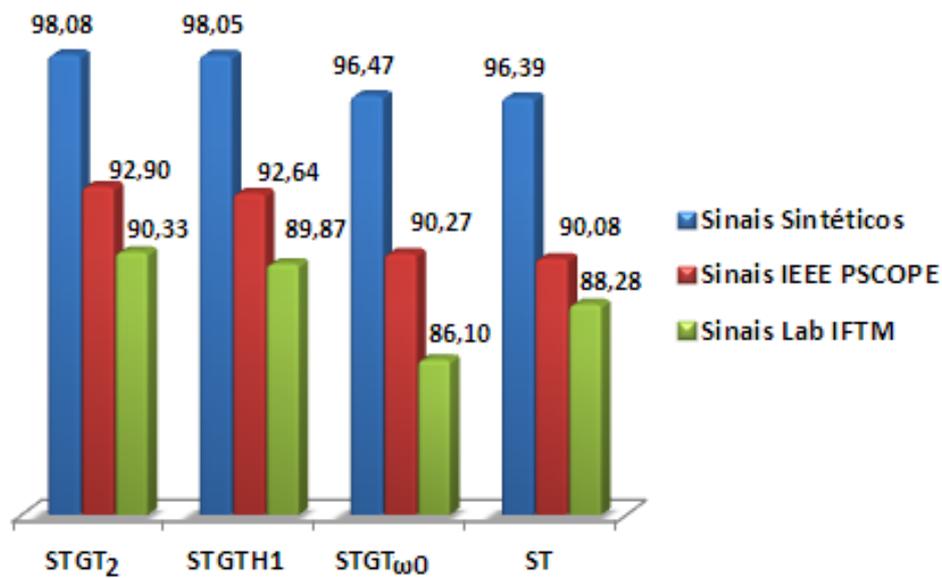


Figura 4.23: Desempenho das TF: Classificação Geral

Tabela 4.5: Métricas estatísticas dos classificadores

Classificadores	Erro Medio Absoluto	Erro Quadrático Médio	Coefficiente Kappa
DT	0,010	0,210	0,970
ANN	0,055	0,358	0,951
SVM	0,085	0,551	0,890

4.6 Análise de Variações de Tensão de Curta Duração (VTCD)

Nesta Seção, nós reportamos um estudo sobre a utilização das transformadas TF para a análise visual de Variações de Tensão de Curta Duração (VTCD). Os principais distúrbios caracterizados por VTCD são os distúrbios do tipo Sag e Sewell, já descritos no Capítulo 3 desta Tese. Visando estabelecer a aplicabilidade da Transformada Sintonizada também a sinais de tensão com representação *fatorial* no domínio do tempo, consideramos abaixo dois casos típicos de VTCD simulados com o toolbox SimPowerSystems, do software MATLAB, utilizando-se um modelo de sistema com 29 barras e rede de transmissão de 735 kV, com sete usinas de 13,8 kV (geração total disponível de 26200 MVA), incluindo turbinas hidráulicas e um parque eólico de 9 MW. O modelo detalhado, incluindo valores de estabilizadores, tipos de cargas, fluxo de potência, impedâncias, etc., pode ser consultado no Apêndice C e na Ref. [102]. A Fig. 4.24 apresenta de forma didática uma ilustração do sistema utilizado, visando enfatizar o emprego da geração distribuída. Na figura, DG-01

representa as pequenas centrais hidrelétricas; DG-02 representa um parque eólico utilizando geradores assíncronos; DG-03 são as co-gerações de energia oriunda da gaseificação de biomassa, e DG-04 representa a geração de energia solar fotovoltaica. Os disjuntores de proteção são representados pelas chaves CB (*circuit breakers*), e as principais cargas estão conectadas ao sistema através dos barramentos Bus-04 e Bus-05.

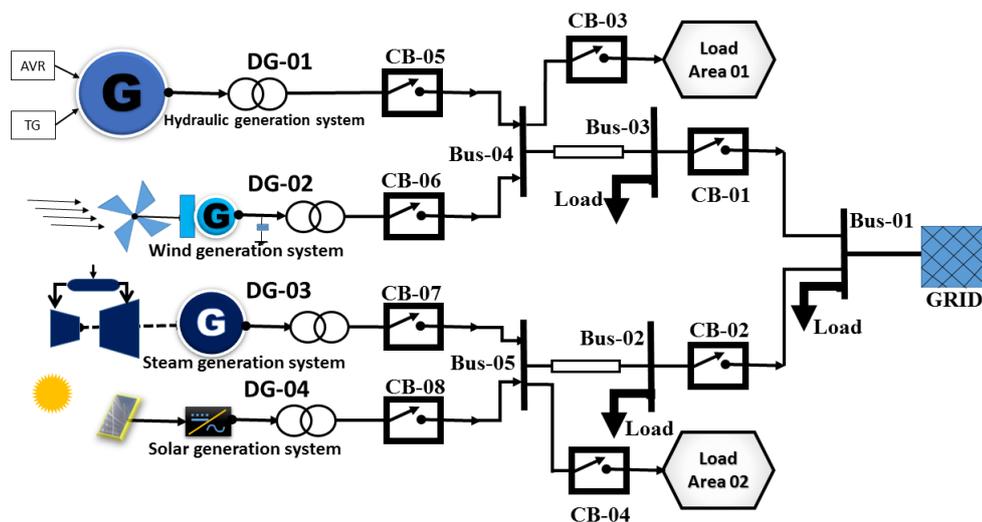


Figura 4.24: Sistema Híbrido de Geração Distribuída.

4.6.1 Simulação 1: VTCD devida a um Curto-Circuito

No presente caso, simulou-se a ocorrência de um curto-circuito trifásico, com duração de 15 ms. Verifica-se na Fig. 4.25 que a tensão sofre uma variação abrupta e oscilações transitórias, na sequência de um aumento devido ao isolamento dos sistemas ligados àquele barramento. Com a ação dos reguladores, a tensão tende a se estabilizar em 1,38 pu. O tempo de simulação no MATLAB foi de 1 s, equivalente a 1200 amostras, com a ocorrência do distúrbio em 0,5 s (amostra 500, na figura). Os espectrogramas resultantes da aplicação, ao sinal de tensão, das transformadas $STGT_2$, $STGT_{H1}$, $STGT_{\omega(0)}$ e ST , aparecem na Fig.4.25. Por inspeção visual, verifica-se que a ocorrência do distúrbio no instante 500 (amostras), é registrada com maior precisão pelas transformadas sintonizadas, em comparação com a ST .

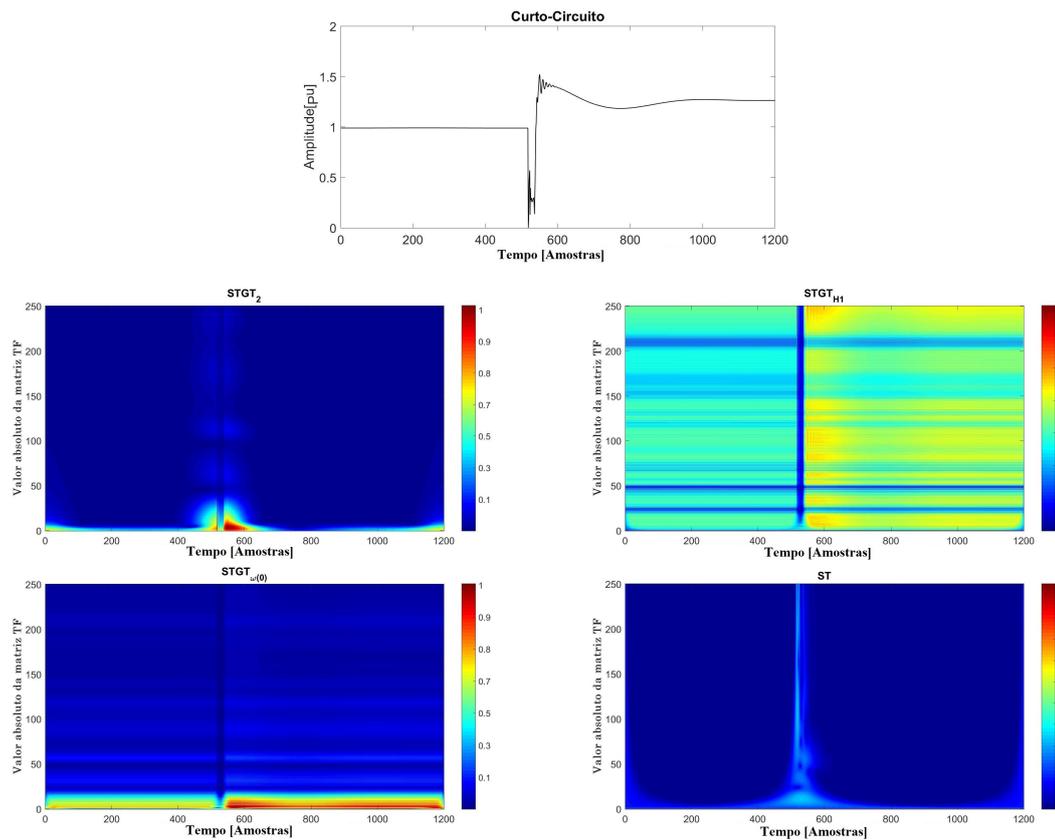


Figura 4.25: VTCD devido a um curto-circuito. Aplicação das Transformadas TF no sinal de Tensão para detecção do distúrbio.

4.6.2 Simulação 2: VTCD devida a uma Rejeição de Carga

Uma rejeição de carga intencional é uma manobra técnica a ser utilizada em situações não convencionais. O objetivo da rejeição de cargas é a eliminação gradativa de um conjunto de cargas por ordem de prioridade, visando permitir o retorno das variáveis de tensão e frequência a patamares admissíveis, e também possibilitar uma análise do fluxo de carga. Diversos parâmetros e critérios devem ser considerados antes da implantação de uma rejeição de carga, mas no presente estudo não se levaram em consideração tais primícias, já que a finalidade é a verificação da dinâmica do sinal de tensão. Supondo que o desligamento provoca uma rejeição de carga considerável, observa-se uma elevação de tensão, ocorrendo um súbito pico de tensão com amplitude máxima de 2,1 pu, como se vê na Fig. 4.26, e, após o transitório, a tensão se estabiliza em 1,4 pu. A figura também apresenta os espectrogramas resultantes da aplicação das transformadas TF ao sinal de tensão, evidenciando que a definição do instante do distúrbio fica mais precisa com a utilização da abordagem sintonizada.

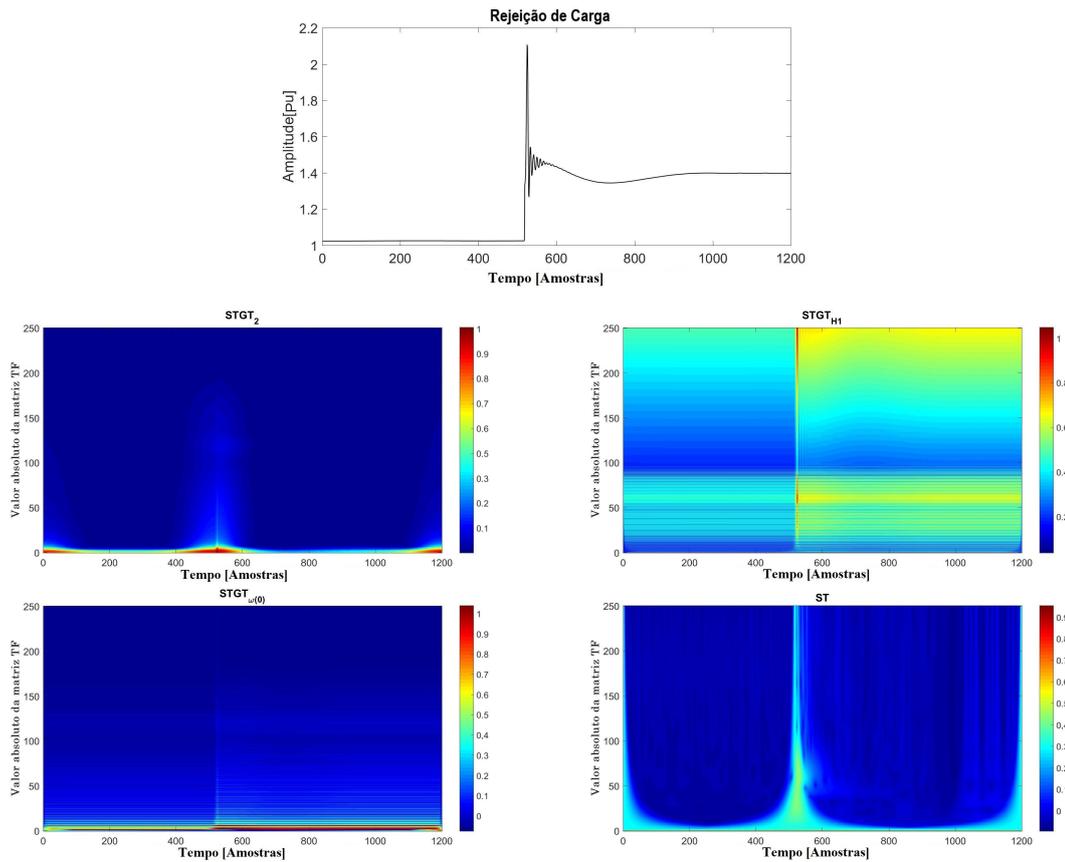


Figura 4.26: VTCD devido a uma rejeição de carga. Aplicação das Transformadas TF ao sinal de tensão para detecção do distúrbio.

4.7 Considerações Finais

O presente Capítulo apresentou os resultados da aplicação das Transformadas Sintonizadas a sistemas elétricos de potência, considerando tanto sinais sintéticos como sinais reais, o que permitiu avaliar o seu desempenho comparativo com o de outras abordagens tempo-frequência. Verificou-se que os espectrogramas fornecidos pela abordagem sintonizada tendem a ser mais informativos, e a proporcionar melhor resolução conjunta tempo-frequência do que os das transformadas tradicionais. Na classificação de distúrbios, em particular a $STGT_2$ e a $STGT_{H1}$, além de proporcionar a visualização mais clara e completa das assinaturas espectro-temporais dos distúrbios, proporcionaram as melhores taxas de acerto na sua classificação, atingindo precisão superior a 99%, para sinais com SNR de 40 db. Tais resultados indicam que as transformadas sintonizadas podem vir a se mostrar uma ferramenta vantajosa em outras aplicações a sistemas de potência, conforme sugerimos no próximo capítulo.

Capítulo 5

Conclusões e Trabalhos Futuros

5.1 Conclusões

Como mencionado na introdução a esta Tese, os estudos aqui reportados dão sequência ao trabalho de pesquisa que vem sendo conduzido no IC-UFF, desde 2012, sobre a abordagem de Gabor sintonizada enquanto ferramenta de uso geral para a análise de sinais. As transformadas sintonizadas são mapeamentos de sinais unidimensionais efetuados por meio de núcleos analisadores bidimensionais (funções de Gabor generalizadas) cujos parâmetros são fornecidos por transformadas unidimensionais (transformadas generalizadas de Fourier) do sinal analisado. Elas constituem, portanto, uma classe de transformadas *tempo-frequência* generalizadas que admitem diversas variantes, algumas das quais foram aqui introduzidas, ou avaliadas experimentalmente pela primeira vez.

Em certas aplicações específicas, algumas das versões das transformadas sintonizadas – que também se caracterizam pelo fato de os seus núcleos analisadores constituírem funções de representação do sinal analisado – já se haviam mostrado superiores a abordagens tempo-frequência tradicionais, como as transformadas de Gabor, S , e de Wigner. Este é o caso, por exemplo, da análise de eletroencefalogramas de pacientes epiléticos [163]. O trabalho aqui reportado apontou uma outra área de aplicação em que variantes da abordagem sintonizada se apresentam como potencialmente vantajosas: a análise de distúrbios em sistemas elétricos de potência (SEP). A seguir nós apresentamos um breve resumo do conteúdo desta Tese, destacando as principais contribuições do nosso trabalho.

- No Capítulo 1, reportou-se o resultado de um levantamento bibliográfico sobre o emprego das abordagens tempo-frequência ou tempo-escala (*wavelets*) na análise da qualidade da energia em sistemas de potência, em que se destacaram as transfor-

madadas S , de Gabor e Fourier Fracionária, além das *wavelets*. O nosso levantamento bibliográfico também contemplou as principais abordagens empregadas para a classificação de distúrbios nos SEP, destacando-se dentre estas as redes neurais artificiais (ANN) e as máquinas de vetor de suporte (SVM), seguidas pelas árvores de decisão (DT). Ressalta-se que, como resultado dessa revisão bibliográfica, foi possível compilar um banco de dados sobre os principais métodos tempo-frequência e abordagens de classificação empregados na análise de distúrbios em sistemas de potência, o que pode vir a se tornar uma ferramenta relevante para futuros pesquisadores.

- No Capítulo 2, além da apresentação da formulação matemática de três abordagens tempo-frequência tradicionais – as transformadas de Gabor, S , e de Wigner –, e da abordagem sintonizada de Gabor em suas versões originais, temporal e espectral – STGT e STGT₂, respectivamente –, foram expostas duas propostas recentes de extensão da abordagem sintonizada, até aqui ainda não estudadas sistematicamente: uma delas incorpora os polinômios de Hermite às funções analisadoras de Gabor, enquanto a outra se baseia na transformada de Fourier fracionária como generalização da transformada de Fourier tradicional. Com a incorporação das funções de Hermite aos núcleos de Gabor da STGT e da STGT₂, a abordagem sintonizada passa a utilizar funções analisadoras que correspondem a funções de codificação das derivadas, em qualquer ordem inteira, do sinal analisado. Isto confere a esta abordagem uma flexibilidade que se mostra vantajosa em certas situações. Por exemplo, a abordagem baseada na transformada STGT_{H1}, que incorpora um fator de Hermite à STGT, mostrou-se eficaz na detecção de mudanças bruscas, como ilustrado nos casos dos sinais associados a curto-circuitos em sistemas elétricos, a ECGs e a EEGs (ver Figs. 2.5 a 2.14).

Além destas duas variantes da abordagem sintonizada, uma nova versão da transformada sintonizada temporal foi também introduzida, a STGT_{ω₀}, em que os parâmetros do núcleo analisador de Gabor são sintonizados em uma componente de frequência determinada, ω_0 , do sinal analisado. Como os sinais elétricos ideais devem manter uma frequência padrão constante, esta aproximação da STGT se mostrou promissora para o tipo de aplicações consideradas aqui.

- O Capítulo 4 reportou uma análise do desempenho da abordagem sintonizada na classificação de distúrbios dos SEP, com base nas técnicas apresentadas no Capítulo 3. Ao lado do conjunto das transformadas sintonizadas – STGT, STGT_{H1}, STGT₂, STGT_{2H1}, STGT_{ω₀} FrSTGT_{α=0,5}, FrSTGT_{α=0,1} – foram consideradas,

para efeito comparativo, as tradicionais transformadas S , de Gabor e de Wigner — ST , GT , $TWVD$. Para efetuar a classificação de dez tipos de distúrbios típicos dos SEP, utilizaram-se os classificadores de redes neurais (ANN), máquina de vetores de suporte (SVM), árvore de decisão (DT) e de Similaridade. Como demonstrado pelos resultados do nosso estudo comparativo, a $STGT_{H1}$ e a $STGT_2$, além de proporcionar melhor qualidade de visualização gráfica (resolução espectral), superou as abordagens tradicionais, por exemplo na classificação de distúrbios em sinais sintéticos, em que obteve taxas de classificação variando de 97,87% (10 dB) a 100% (∞ dB), quando empregada em associação com o classificador ANN. A mesma superioridade foi constatada quando considerados os demais classificadores (ver Tabela 4.2), e na classificação dos sinais reais gerados no laboratório do IFTM (Tabela 4.4) e dos sinais obtidos dos grupos de pesquisa IEEE e PSCOPE (Tabela 4.3). Por outro lado, verificou-se o baixo desempenho da $FrSTGT_{\alpha=0,5}$ e da $FrSTGT_{\alpha=0,1}$, o que já era esperado devido à descaracterização do espectro que se verifica com tais transformadas.

- Com relação aos classificadores, os experimentos permitem concluir que as árvores de decisão (DT) apresentam o melhor desempenho, atingindo, nos melhores casos (classificação com a $STGT_2$), taxas de acerto de 91,9%, 94% e 99,4% — respectivamente para os sinais sintéticos, os sinais do Laboratório do IFTM, e os sinais do IEEE-PSCOPE (ver as Figs. 4.2, 4.14, 4.19). Em seguida, aparecem os classificadores por redes neurais (ANN), com 91,8%, 94% e 99,25%; por máquinas de vetores de suporte (SVM), com 89%, 92% e 98,35%, e o classificador por Similaridade, com taxas de 87,8%, 90,2% e 95,3%. Ressalta-se aqui que o desempenho dos classificadores ANN e SVM pode ser melhorado por meio de ajustes em sua configuração interna (*kernels* Polinomial ou RBF, redes feedforward, perceptron e outras). Por outro lado, um fator externo que influencia diretamente na classificação é a quantidade de amostras utilizadas para o treinamento dessas redes.

Os resultados, de forma geral, comprovam que a abordagem sintonizada é apropriada para o desenvolvimento de aplicações em qualidade da energia elétrica, conforme demonstrado pelo seu desempenho em termos tanto da análise visual dos espectrogramas associados, como do seu emprego como base para algoritmos de classificação de distúrbios. Os espectrogramas obtidos com as transformadas sintonizadas tendem a ser mais informativos, e a proporcionar melhor resolução conjunta tempo-frequência do que os das transformadas tradicionais analisadas. Tais resultados indicam que as transformadas sin-

tonizadas se mostram promissoras para outras aplicações em sistemas de potência, e, de modo geral, como ferramenta para o processamento de sinais.

5.1.1 Artigos Publicados

Até o momento, o trabalho aqui reportado deu origem às seguintes publicações:

- *Signal-tuned Gabor approach for power disturbance classification*. In 17th International Conference on Harmonics and Quality of Power (ICHQP) (Oct 2016), pp. 42-47, Belo Horizonte, Brazil.
- *Signal-Tuned Gabor Application in Islanding Detection in Distributed Generation at the Power System*. In XII Conferência Brasileira sobre Qualidade da Energia Elétrica - CBQEE2017 volume único, 1 (2017).
- *Signal-Tuned Spectral Gabor Transform as a Tool for Power Quality Monitoring*. In 18th International Conference on Harmonics and Quality of Power (ICHQP) (May 2018), Ljubljana, Slovenia.

5.2 Trabalhos Futuros

Face às evidências produzidas pela nossa pesquisa, diversas vertentes para trabalhos futuros podem ser identificadas, conforme a seguir:

- Aplicação da abordagem sintonizada à análise do espectro das componentes harmônicas dos SEP: As transformadas TF tradicionais possuem um limite de resolução espectral, que deve ser otimizado por meio da seleção de valores ideais de seus parâmetros, de modo que a análise proporcione qualidade suficiente para uma detecção e uma classificação eficazes. Na maioria dos casos, as medições de frequência continuam a ser realizadas por meio da FFT, contudo este método não proporciona resultados positivos face a alterações temporais dos valores de frequência, o que limita a sua aplicabilidade. Os esforços prosseguem, portanto, para o desenvolvimento de métodos alternativos que permitam obter um espectro de medições tempo-frequência com resolução plausível. Sendo assim, apresenta-se como alternativa natural o emprego das STGTs para a identificação e a análise de distúrbios, como os harmônicos e inter-harmônicos, que afetam os SEP.

- Com relação aos Classificadores, com o objetivo de obter resultados ainda melhores, é possível: utilizar outros tipos de classificadores, selecionar os atributos mais relevantes, testar outros atributos.
- Aplicação da abordagem sintonizada à análise e classificação de sinais modulados, por exemplo, sob as modulações AM, FM, BPSK, BFSK, QPSK e 16-QAM, entre outras [48] [81] [94][95]. O objetivo seria promover um estudo comparativo entre os diferentes classificadores disponíveis na literatura e a abordagem sintonizada, já que a identificação precisa do tipo de modulação proporciona eficácia na demodulação do sinal gerado.
- Análise da aplicação das STGTs, principalmente as Fracionárias, para a identificação de patologias em sinais de voz, visto que tais sinais têm características fractais, e os espectros a serem obtidos podem conter informações diferenciáveis.
- Em uma vertente mais teórica, nós pretendemos continuar a exploração de variantes da transformada sintonizada de Gabor, por exemplo com a introdução de uma abordagem baseada no logaritmo do sinal analisado ($STGT_{log}$). Uma análise preliminar já permite identificar vantagens em tal abordagem, conforme ilustrado a seguir:

Nas figuras abaixo, nós consideramos dois sinais já anteriormente analisados nesta Tese, para os quais os espectrogramas associados à $STGT_{log}$ são agora apresentados. Na Fig. 5.1, em comparação com a transformada S e outras versões da abordagem sintonizada, ressalta-se a grande precisão, tanto temporal quanto espectral, da $STGT_{log}$ na detecção das variações bruscas no sinal analisado. Do mesmo modo, na Fig. 5.2, em que se considera um sinal elétrico com distúrbio do tipo *Interrupt + Harmônicos*, sob SNR de 10 dB, fica evidente a maior precisão da $STGT_{log}$ na detecção do início e do fim do distúrbio, em comparação com a $STGT_{H1}$, a $STGT_2$ e a ST.

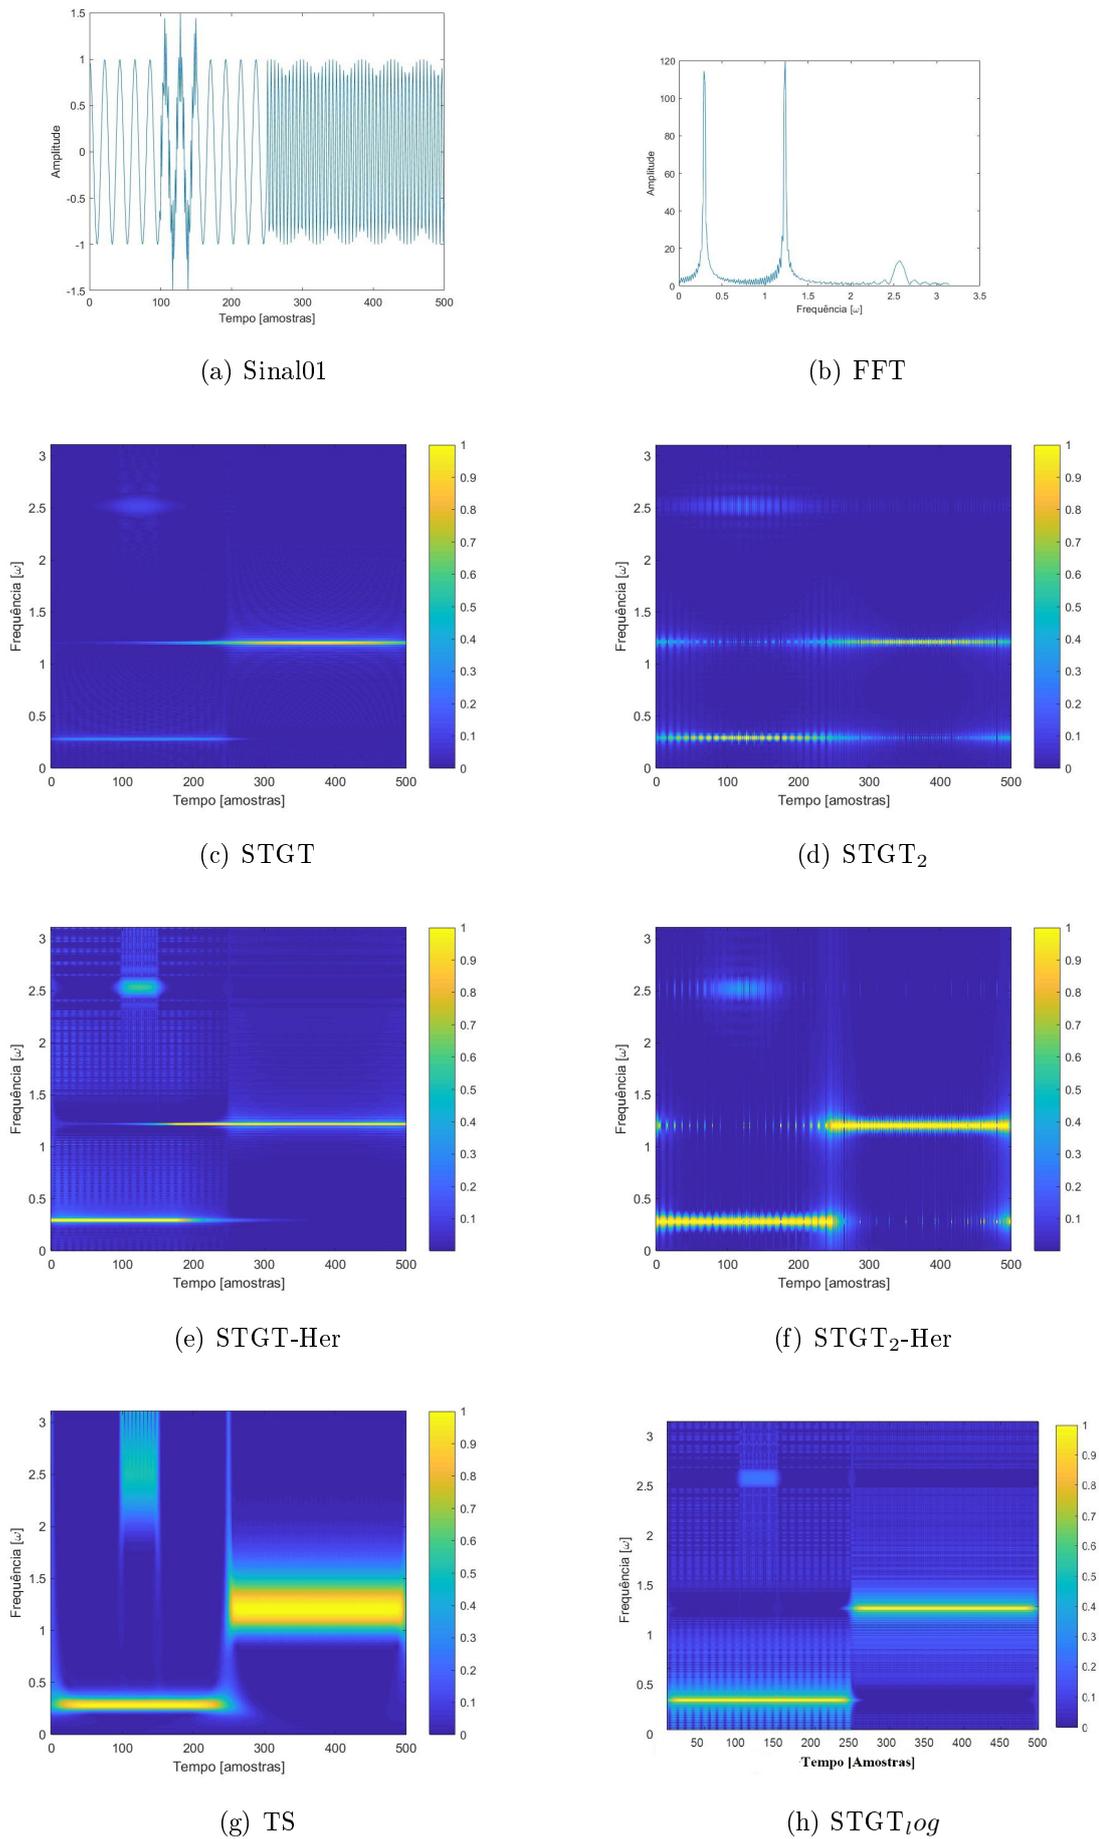


Figura 5.1: Aplicação da STGT_{log} ao Sinal I_1 da Eq. (2.53).

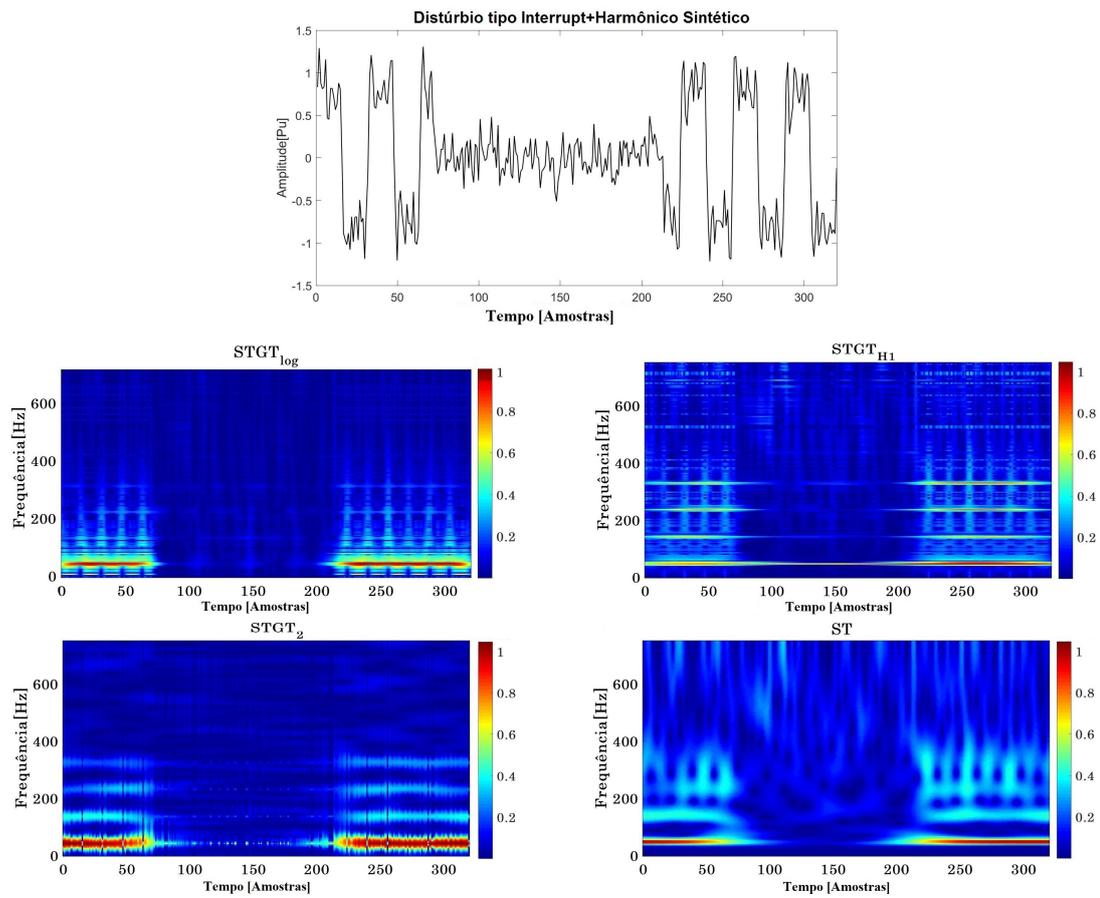


Figura 5.2: Aplicação da $STGT_{log}$ a um Sinal Elétrico sob Distúrbio Sintético do Tipo Interrupt+Harmônicos (10 dB).

APÊNDICE A - Pesquisa Bibliográfica

Neste Apêndice, nós apresentamos o resultado do levantamento bibliográfico mencionado no Capítulo 1, que visou contextualizar a aplicação das transformadas tempo-frequência (TF) a sistemas elétricos de potência, em particular na área de qualidade da energia elétrica.

Nas tabelas abaixo, as seguintes abreviações são empregadas: Wavelet Transform (WT), Hilbert-Huang Transform (HHT), Modified *S*-Transform (MST), Fractional Fourier Transform (FrFT), Fractional Wavelet Transform (FrWT), Time-Time Transform (TTT); Artificial Neural Network (ANN), Support Vector Machine (SVM), Radial Basis Function (RF), Decision Tree (DT), Probabilistic Neural Network (PNN), Base Chupakhina base (Chupakhina). Os artigos que utilizaram as transformadas TF visando representação ou análise visual aparecem sob a categoria Análise/Gráfico.

Tabela A.1: Aplicação das Transformadas TF a Sistemas Elétricos

Ano	Autores	Transformada	Análise	Ref
2017	A. Chupakhina, <i>et al</i>	HHT WT TS	ANN	[38]
2017	M. J. U. Bhuiyan, <i>et al</i>	TS	Euclidean SVM	[16]
2017	U. Singh and S. N. Singh,	TFScale	DTree SVM	[152]
2017	U. Singh and S. N. Singh,	TFScale	Gráficos	[151]
2017	J. A. Bosnic, <i>et al</i>	WT	SVM	[25]
2017	D. Wei, Y.-M. Li, e R. Wang,	FrFT	Gráficos	[177]
2017	N. R. Nashad, <i>et al</i>	HHT WT	Gráficos	[116]
2017	S. Raj, <i>et al</i>	MTS	Gráficos	[130]
2017	U. Singh e S. N. Singh,	TTT	SVM	[150]
2017	C. Jettanasen, <i>et al</i>	WT	ANN	[74]
2017	F. Z. Dekhandji,	WT	Gráficos	[41]
2017	M. Markovska e D. Taskovski,	WT	RF	[101]
2017	M. Markovska e D. Taskovski,	WT	SVM	[100]
2017	M. Sadeghhelfroush, <i>et al</i>	WT	ANN	[121]
2017	P. R. Kamthekar,	WT	Gráficos	[79]
2017	P. R. Kamthekar, <i>et al</i>	WT	Fuzzy	[78]
2017	T. Chakravorti, <i>et al</i>	WT	Fuzzy	[32]
2017	A. Abdullah,	WT	ANN	[1]

Tabela A.2: Aplicação das TF em Sistemas Elétricos

Ano	Autores	Transformada	Análise	Ref
2016	S. J. Pinto,	FrWT	Gráficos	[126]
2016	S. Alshahrani, <i>et al</i>	HHT	ANN	[6]
2016	C. T. Man and J. T. Liang,	TS	Gráficos	[98]
2016	K. Kumari,	TS	Gráficos	[88]
2016	K. Thangaraj, <i>et al</i>	TS	Gráficos	[160]
2016	M.K.Elango, <i>et al</i> ,	TS	ANN	[47]
2016	S. R. Satao and R. S. Kankale,	TS	ANN	[141]
2016	O. P. Mahela and A. G. Shaik,	TS	Fuzzy	[97]
2016	F. Borges, <i>et al</i>	TS	ANN	[22]
2016	G. Lv, <i>et al</i>	TS	SVM ANN	[54].
2016	J. Li, <i>et al</i>	TS	SVM	[89]
2016	O. P. Mahela e A. G. Shaik,	TS	DTree	[97]
2016	M. K. Elango e K. Loganathan,	TS	ANN	[47]
2016	S. Shaik, U <i>et al</i>	Curvelet	SVM	[145]
2016	A. Manglik, <i>et al</i>	HHT	Gráficos	[99]
2016	T. Yalcin e M. Ozdemir,	HHT TS	SVM DTree	[185]
2016	E. M. P. Anissa, <i>et al</i>	MST	Gráficos	[11]
2016	E. M. Lima, <i>et al</i>	STFT	Gráficos	[92]
2016	J. C. Ferreira, <i>et al</i>	STGT	Similaridade	[51]
2016	L. Zhao, X. Liu, and G. Fu,	TTT	SVM	[195]
2016	S. Vergura, <i>et al</i>	WT	Gráficos	[173]
2016	F. A. S. Borges, <i>et al</i>	WT	DTree ANN	[22]
2016	A. K. Sharma e S. R. Ola,	WT	Gráficos	[146]
2016	J. F. Fernandes, <i>et al</i>	WT	ANN	[49]
2016	K. Thirumala, <i>et al</i>	WT	SVM	[161]
2016	Aravind e A. T. Mathew,	WT	Gráficos	[13]
2016	M. Sahani, <i>et al</i>	WT	SVM	[138]

Tabela A.3: Aplicação das TF em Sistemas Elétricos

Ano	Autores	Transformada	Análise	Ref
2016	R. Kumar, <i>et al</i>	WT	Algoritmo Proprio	[87]
2016	S. Divya, <i>et al</i>	WT	ANN	[43]
2016	S. Hossain-McKenzie, <i>et al</i>	WT	SVM	[63]
2016	S. Karasu e S. Baskan,	WT	ANN KNN SVM	[80]
2016	A. Shaik e A. S. Reddy,	WT	Gráficos	[144]
2016	M. D. Borrás <i>et al.</i> ,	WT	SVM	[24]
2016	S. Puthenpurakel, <i>et al</i>	WT	ANN	[127]
2016	S. Pereira e M. Moreto,	WT	Gráficos	[125]
2016	H. Jain and S. K. Gawre,	WT	ANN	[73]
2016	T. M. Cesar, <i>et al</i>	WT	Gráficos	[31]
2016	A. A. P. Biscaro. <i>et al.</i>	WT	ANN	[17]
2016	M. V. Subbarao <i>et al</i>	WT	Gráficos	[155]
2015	R. Kumar, <i>et al</i>	TS	ANN DTree	[86]
2015	X. Shicheng, <i>et al</i>	TS	SVM	[148]
2015	A. Amirou, <i>et al</i>	TS	Gráficos	[9]
2015	H. Guo, <i>et al</i>	TS	Gráficos	[58]
2015	M. Chun-Tao, L. Jian-Tong,	TS	Gráficos	[36]
2015	Z. Amirou, <i>et al</i>	TS	Gráficos	[10]
2015	R. Khan and S. K. Padhi,	TTT	Bayes	[82]
2015	R. Nandi and B. K. Panigrahi,	WT	Gráficos	[115]
2015	S. Khokhar, <i>et al</i>	WT	PNN	[83]
2015	K. Thirumala, <i>et al</i>	WT	Gráficos	[161]
2014	A. Amirou, <i>et al</i>	TS	Gráficos	[8]
2014	W. Yao, <i>et al</i>	TS	Gráficos	[189]
2014	Y. Onal, <i>et al</i>	HHT	Gráficos	[122]
2014	T. Sikorski and P. Kostyla,	HHT	Gráficos	[149]

Tabela A.4: Aplicação das TF em Sistemas Elétricos

Ano	Autores	Transformada	Análise	Ref
2014	H. Yong-hong, <i>et al</i>	MST	Gráficos	[191]
2014	Y. h. Huang, <i>et al</i>	MST	Gráficos	[68]
2014	C. A. Naik, P. Kundu,	WT	Gráficos	[112]
2014	V. Apetrei, <i>et al</i>	WT	Gráficos	[12]
2013	A. Rodriguez, <i>et al</i>	TS	DTree	[136]
2013	M. Biswal and P. K. Dash,	TS	Fuzzy DTree	[20]
2013	N. H. T. Huda, <i>et al</i>	TS	Gráficos	[69]
2013	M. Uyar, <i>et al</i>	TS	Gráficos	[166]
2013	M. J. Afroni, <i>et al</i>	HHT	Gráficos	[3]
2013	Z. Cai, <i>et al</i>	HHT	Gráficos	[27]
2013	W. Tao <i>et al.</i> ,	HHT TS	Gráficos	[159]
2013	S. M. Hosseini and S. Jalilzade,	WT TS	Gráficos	[64]
2012	D. Saxena, <i>et al</i>	TS	Gráficos	[142]
2012	C. A. Naik , P. Kundu,	TS	Gráficos	[114]
2012	F. Xu, Y. Wang,	TS	Gráficos	[184]
2012	F. Xu, Y. Zhang , X. Xiao,	TS	Similarity	[183]
2012	N. Eghtedarpour, E. Farjah,	TS	Gráficos	[46]
2012	R. Zhang, <i>et al</i>	TS	Euclidean	[194]
2012	M. Khosravi, <i>et al</i>	TS	Gráficos	[84]
2012	M. Biswal and P. K. Dash,	TS	Gráficos	[19]
2012	J. Barros, <i>et al</i>	WT	Review	[15]
2012	P. K. Ray, <i>et al</i>	WT TS	Gráficos	[133]

Tabela A.5: Aplicação das TF em Sistemas Elétricos

Ano	Autores	Transformada	Análise	Ref
2011	M. A. Mohamed,	TS	Gráficos	[105]
2011	C. A. Naik e P. Kundu,	TS	Gráficos	[113]
2011	F. M. A. Rodriguez, <i>et al</i>	TS	ANN	[135]
2011	G. Gasparesc	TS	Gráficos	[55]
2011	Z. Peng and L. Hong-bin,	WT	Gráficos	[193]
2011	Z. Rui, L. Nan, e M. Hui-jun,	WT	Gráficos	[137]
2011	I. D. Nicolae e P. M. Nicolae,	WT	Gráficos	[118]
2011	C. Chunling, W. Pengfei,	WT	Gráficos	[37]
2011	J. Barros, R. I. Diego,	WT	Gráficos	[14]
2011	D. Granados-Lieberman, <i>et al</i>	WT TS GT	Review	[56]
2010	C. F. Drummond e D. Sutanto,	HHT	Gráficos	[44]
2010	C. Venkatesh and M. Sydulu,	TS	ANN	[170]
2010	M. Yang, J. Hui, X. Liu,	TS	Similarity	[187]
2010	Y. Jia, Z. Y. He,	TS	Gráficos	[75]
2010	B. Biswal, M. Biswal,	TS	ANN	[18]
2010	J. W. Y. Weng,	TS	SVM	[178]
2010	S. H. Cho, G. Jang,	GT Wigner	Gráficos	[35]
2010	M. Szmajda, K. Górecki,	GT Wigner	Gráficos	[156]
2010	J. Yu and Y. Lai,	HHT	Gráficos	[192]
2010	L. Yang, J. Yu, e Y. Lai,	HHT	Gráficos	[186]
2010	N. Huang, D. Xu,	HST	chupakhina DTree	[67]
2010	G. Jing,	WT	Gráficos	[76]
2010	W. Morsi e M. El-Hawary,	WT	Gráficos	[107]
2010	L. S. Ortiz, <i>et al</i>	WT	Gráficos	[123]

Tabela A.6: Aplicação das TF em Sistemas Elétricos

Ano	Autores	Transformada	Análise	Ref
2010	W. G. Morsi,	WT	Gráficos	[108]
2010	X. G. X. Gu and K. L. Lo,	WT	Fuzzy	[57]
2010	Y. Zhao, <i>et al</i>	WT	Gráficos	[196]
2010	P. K. Ray, <i>et al</i>	WT TS	Gráficos	[132]
2009	J. Wang, <i>et al</i>	TS	SVM	[175]
2009	Jiliang Yi and Jianchun Peng,	TS	Gráficos	[190]
2009	N. Huang, <i>et al</i>	TS	Review	[66]
2009	Z. S. Z. Shi, <i>et al</i>	TS	Gráficos	[147]
2009	W. Jing, <i>et al</i>	TS	Gráficos	[77]
2009	I. Nicolae,	WT	Gráficos	[117]
2009	W. G. Morsi <i>et al</i>	WT	Gráficos	[111]
2008	C. Venkatesh, <i>et al</i>	TS	Gráficos	[169]
2008	Q. Huimin and D. Yuxing,	TS	DTree	[70]
2008	S. Liu and Y. Sun,	TS	SVM	[96]
2008	X. X. Member, <i>et al</i>	TS	Similarity	[188]
2008	K. Li <i>et al.</i> ,	TS	Fuzzy	[90]
2008	S. Mishra, <i>et al</i>	TS	PNN	[104]
2008	X. Xiao, <i>et al</i>	TS	Similarity	[181]
2008	S. K. Meher,	Slantlet	Algoritmo Proprio	[103]
2008	A. Rodríguez, <i>et al</i>	WT	Gráficos	[134]
2008	D. Devaraj and P. Rathika,	WT	ANN	[42]
2008	M. Uyar, <i>et al</i>	WT	SVM	[165]
2008	W. G. Morsi <i>et al</i>	WT	Gráficos	[110]
2007	A. Abdullah e A. Shaameri,	TS	SVM	[2]
2007	W. G. Morsi, <i>et al</i>	WT	Gráficos	[109]
2007	Z. L. Tadeusz and O. K. Wo,	WT	Gráficos	[157]

APÊNDICE B - Outros Resultados

Apresentamos aqui outros resultados obtidos no nosso estudo. Dividos em três seções, sinais experimentais IEEE e PSCOPE, sinais experimentais laboratório IFTM e sinais sintéticos.

B.1 Sinais Experimentais IEEE e PSCOPE

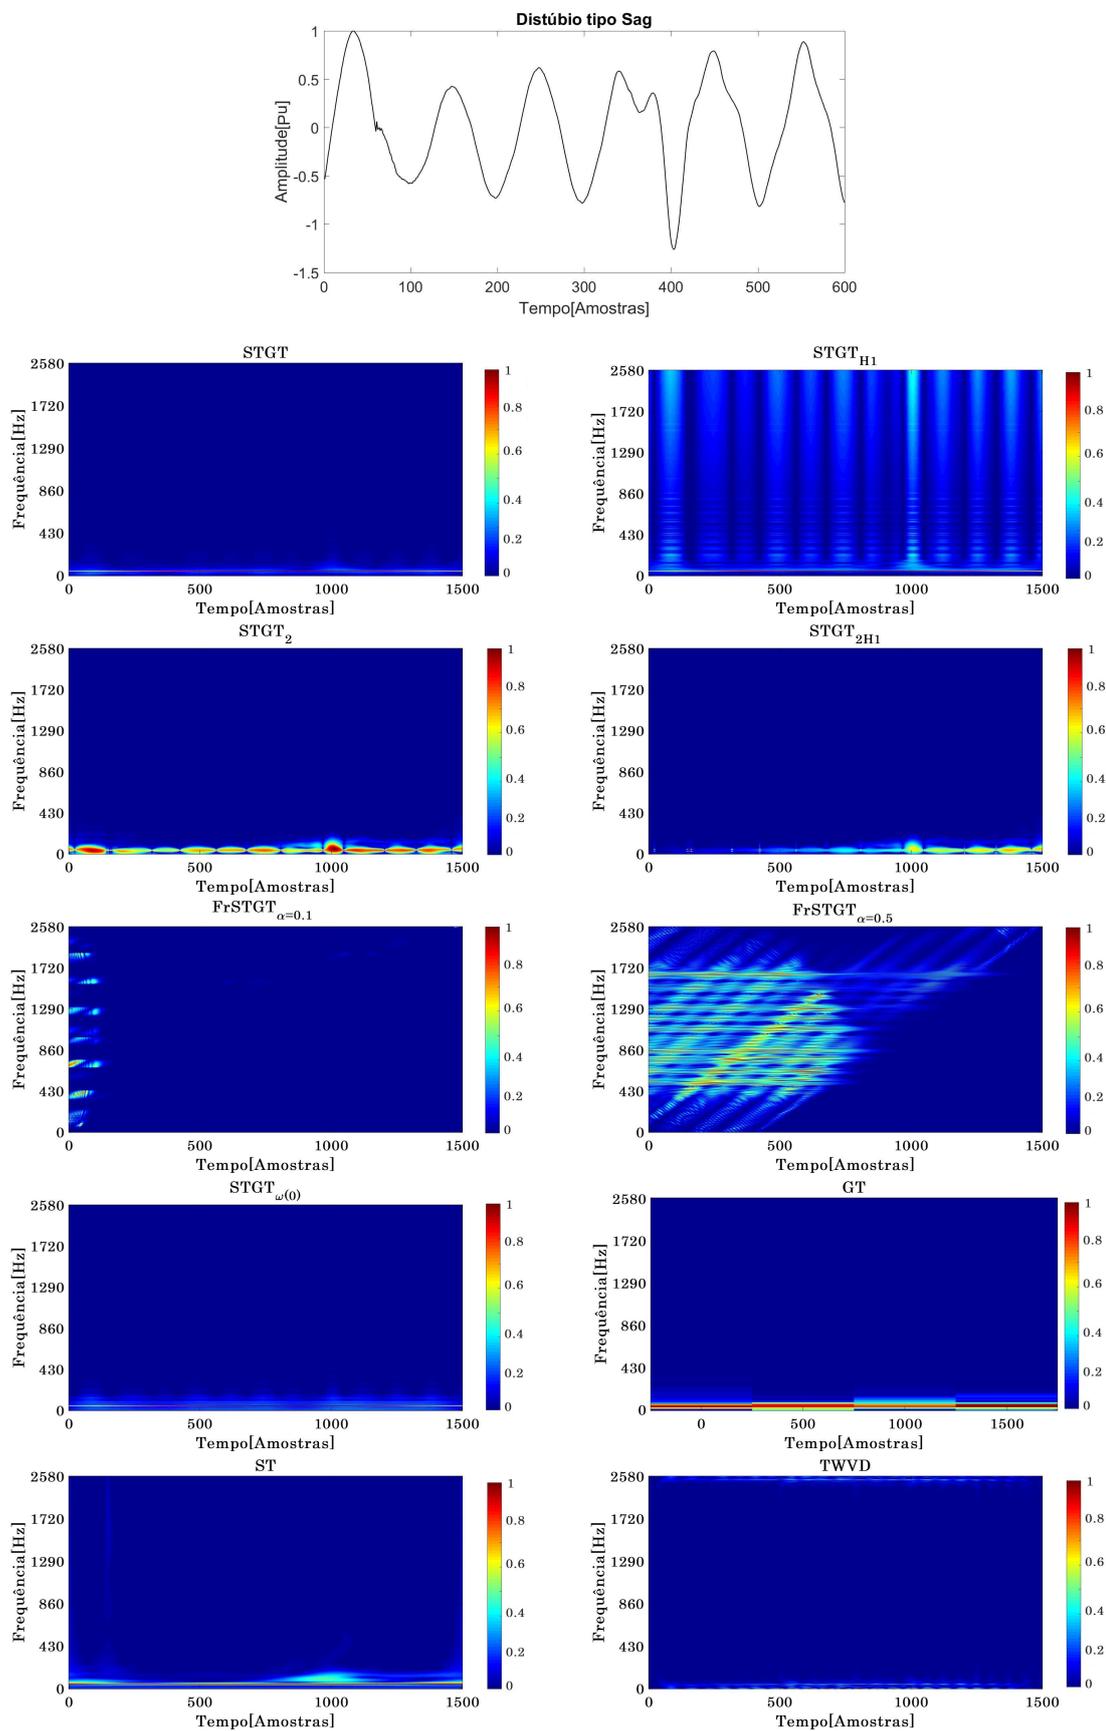


Figura B.1: Aplicação das Transformadas a um Distúrbio tipo Sag - IEEE e PSCOPE.

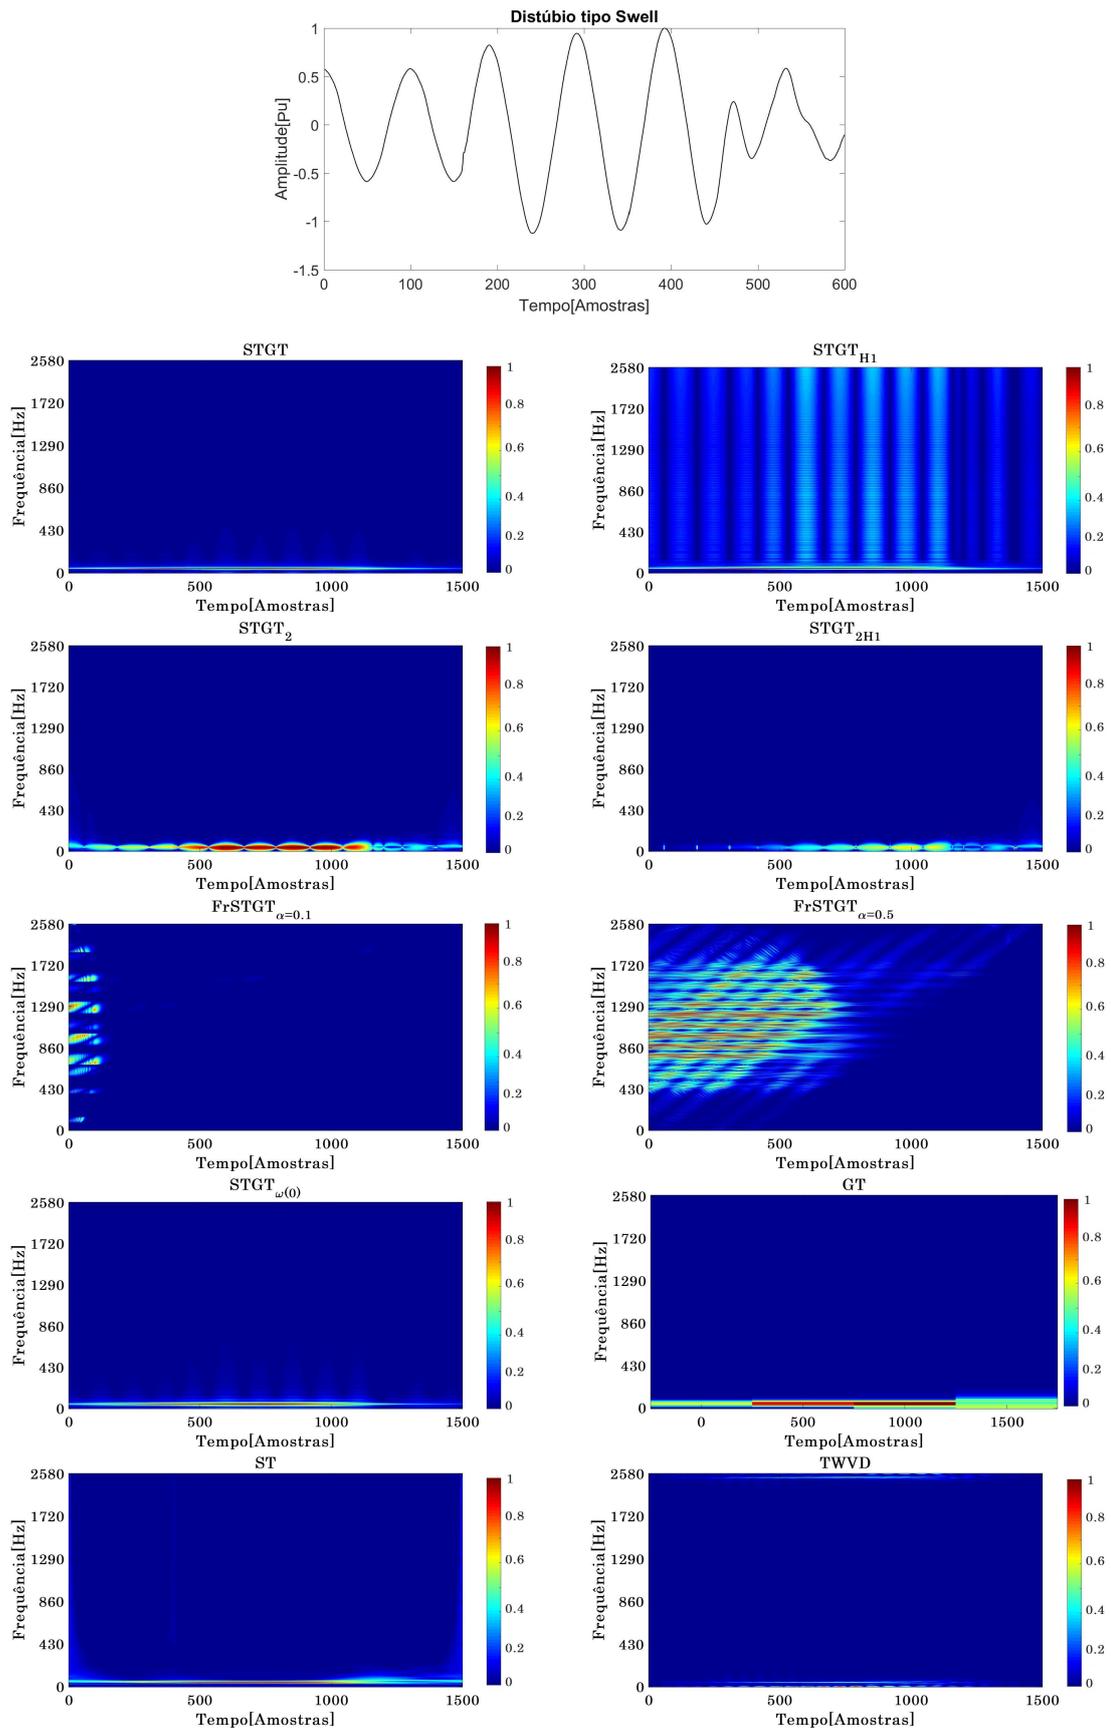


Figura B.2: Aplicação das Transformadas a um Distúrbio tipo Swell - IEEE e PSCOPE.

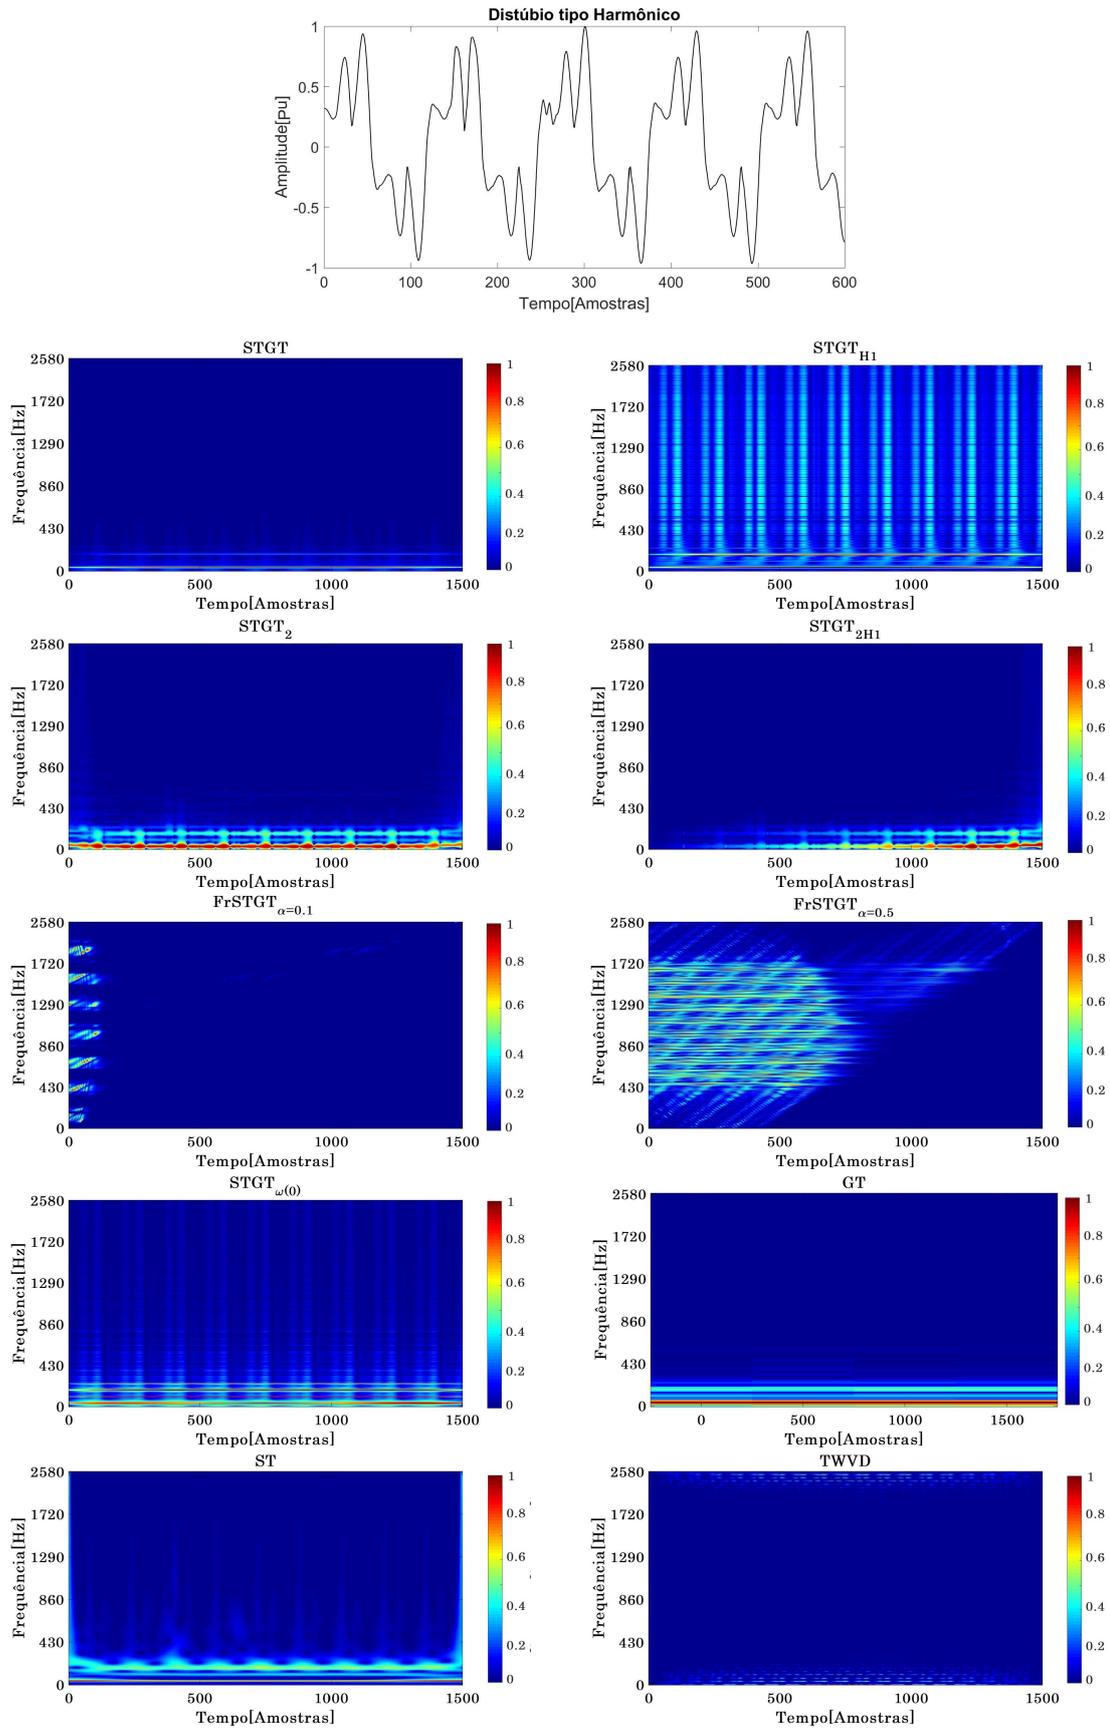


Figura B.3: Aplicação das Transformadas a um Distúrbio tipo Harmônico - IEEE e PSCOPE.

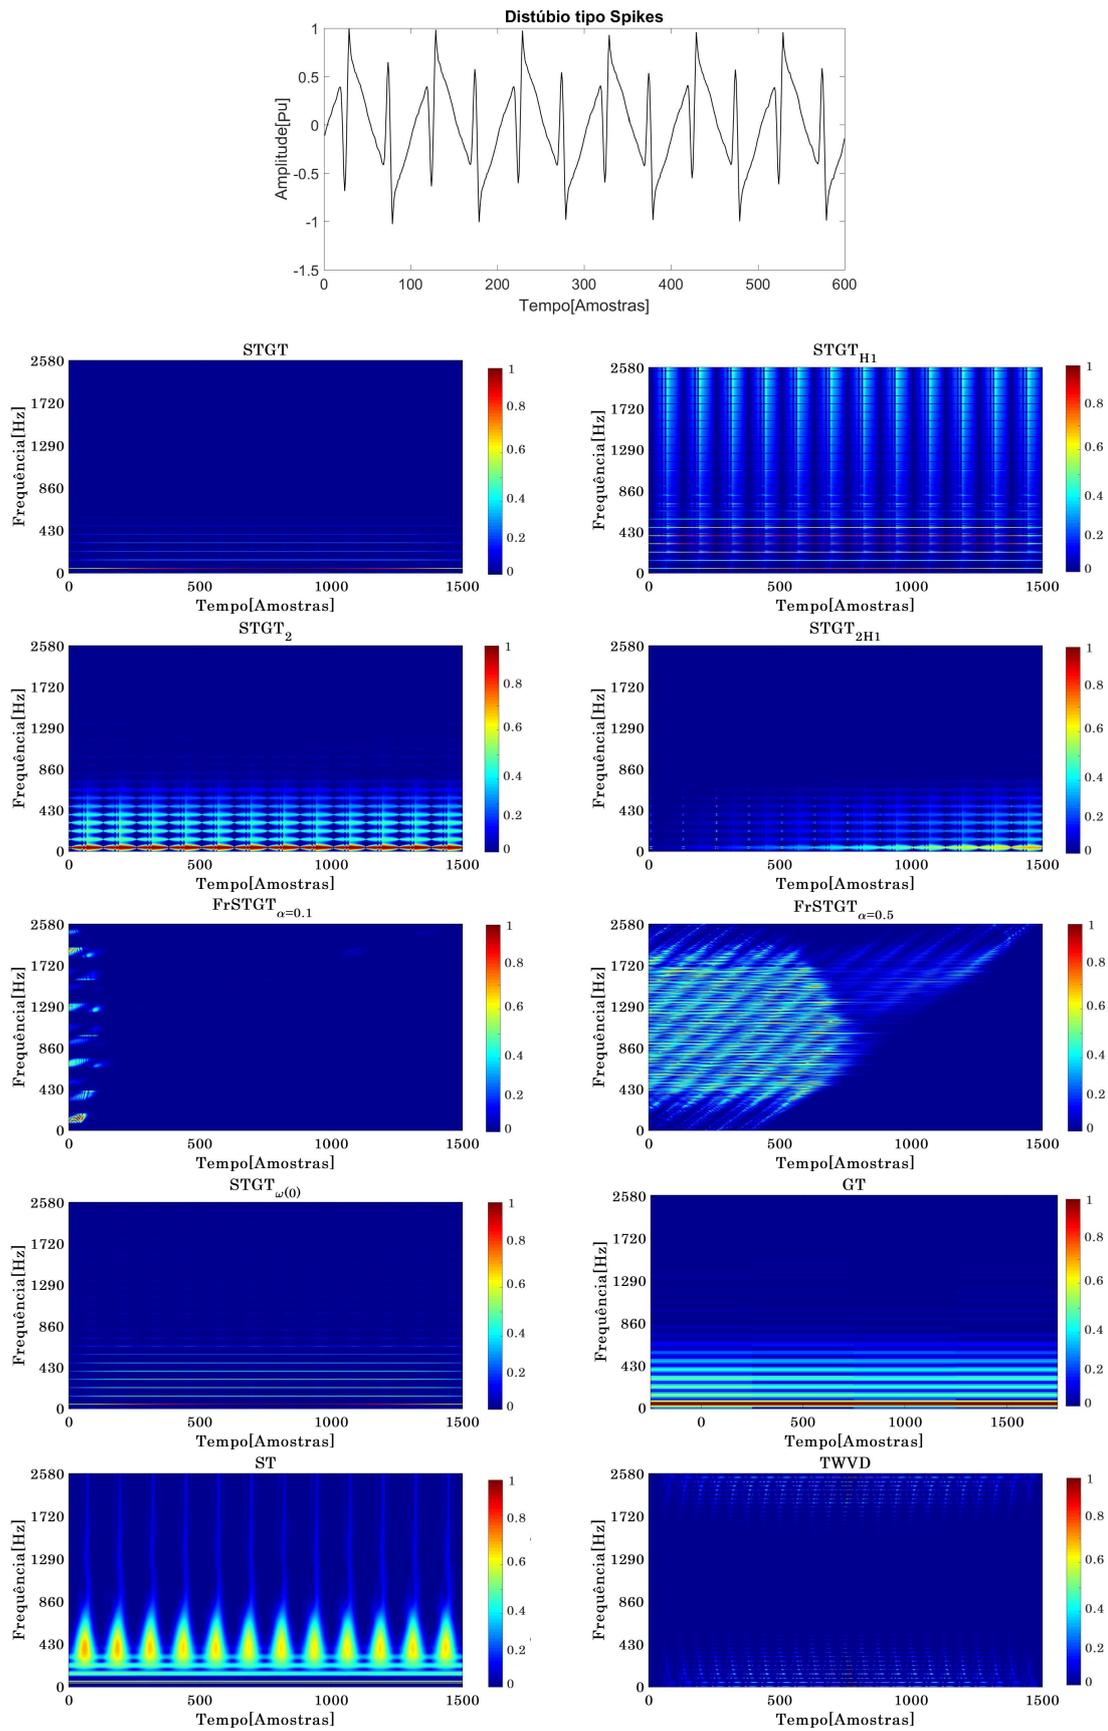


Figura B.4: Aplicação das Transformadas a um Distúrbio tipo Spikes - IEEE e PSCOPE.

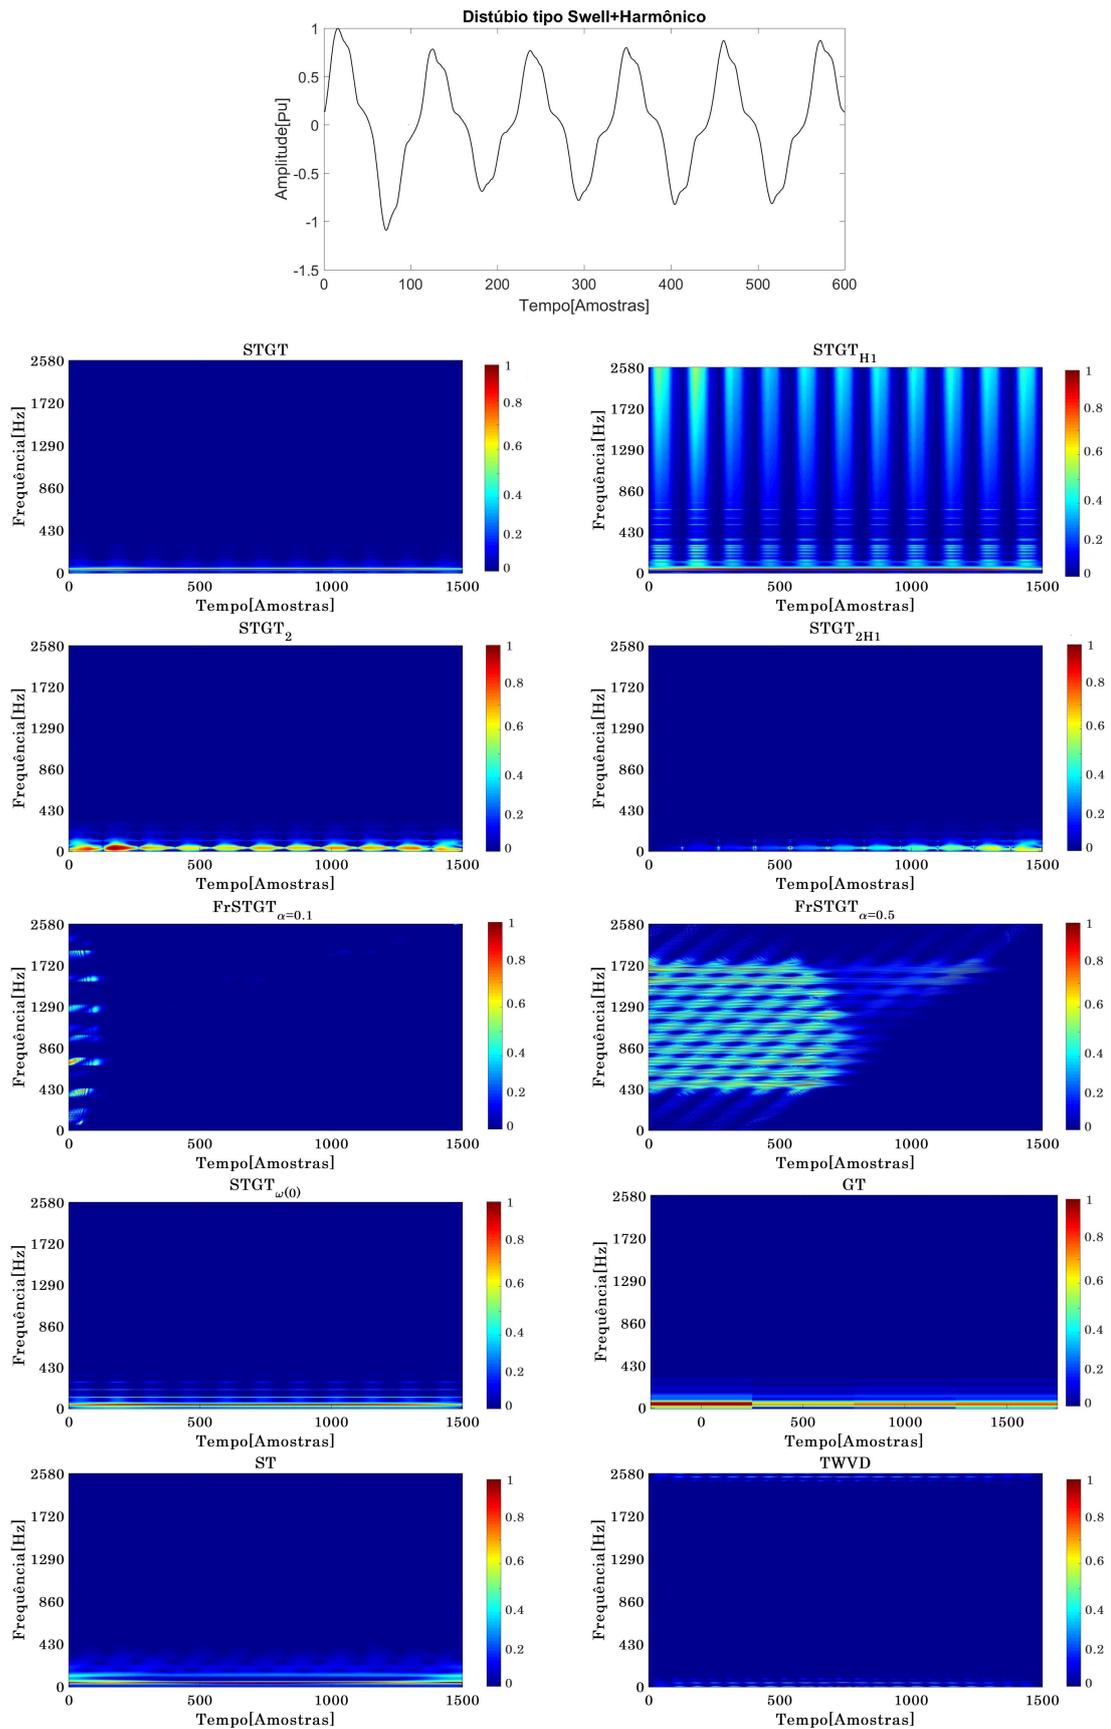


Figura B.5: Aplicação das Transformadas a um Distúrbio tipo Swell+Harmônico - IEEE e PSCOPE.

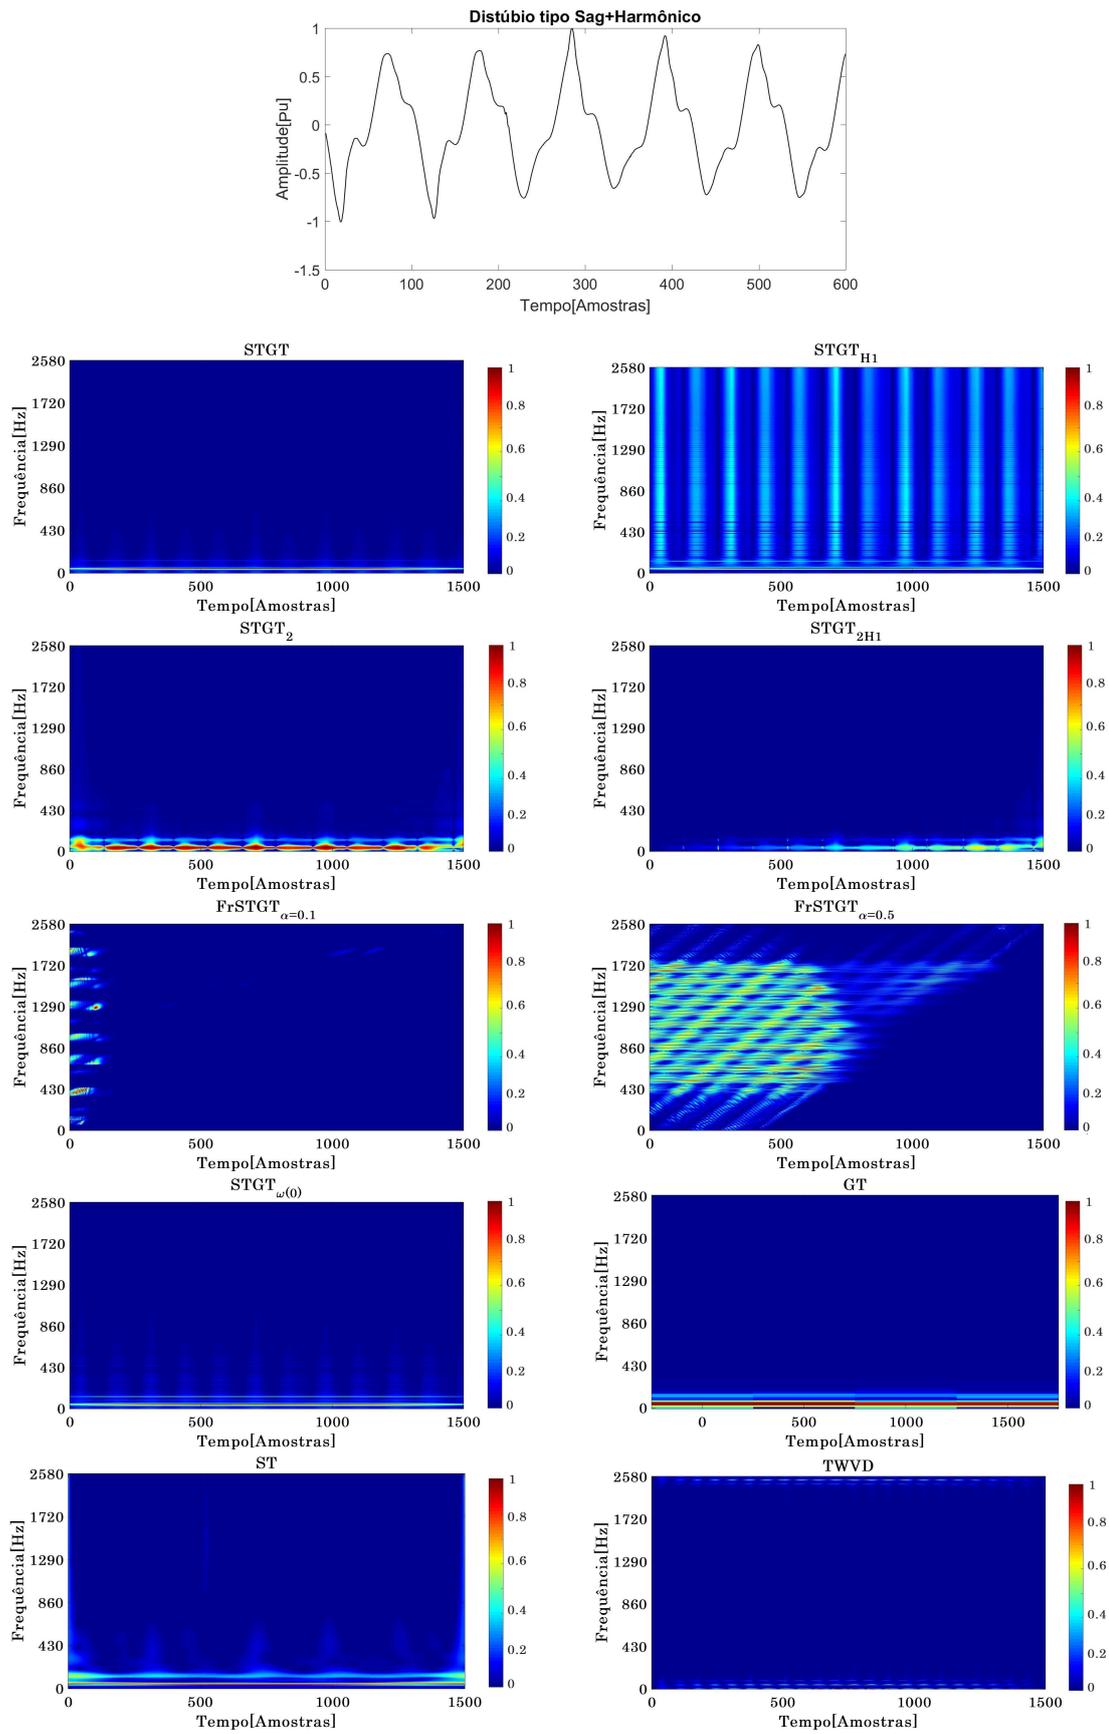


Figura B.6: Aplicação das Transformadas a um Distúrbio tipo Sag+Harmônico - IEEE e PSCOPE.

B.2 Sinais Experimentais Laboratório IFTM

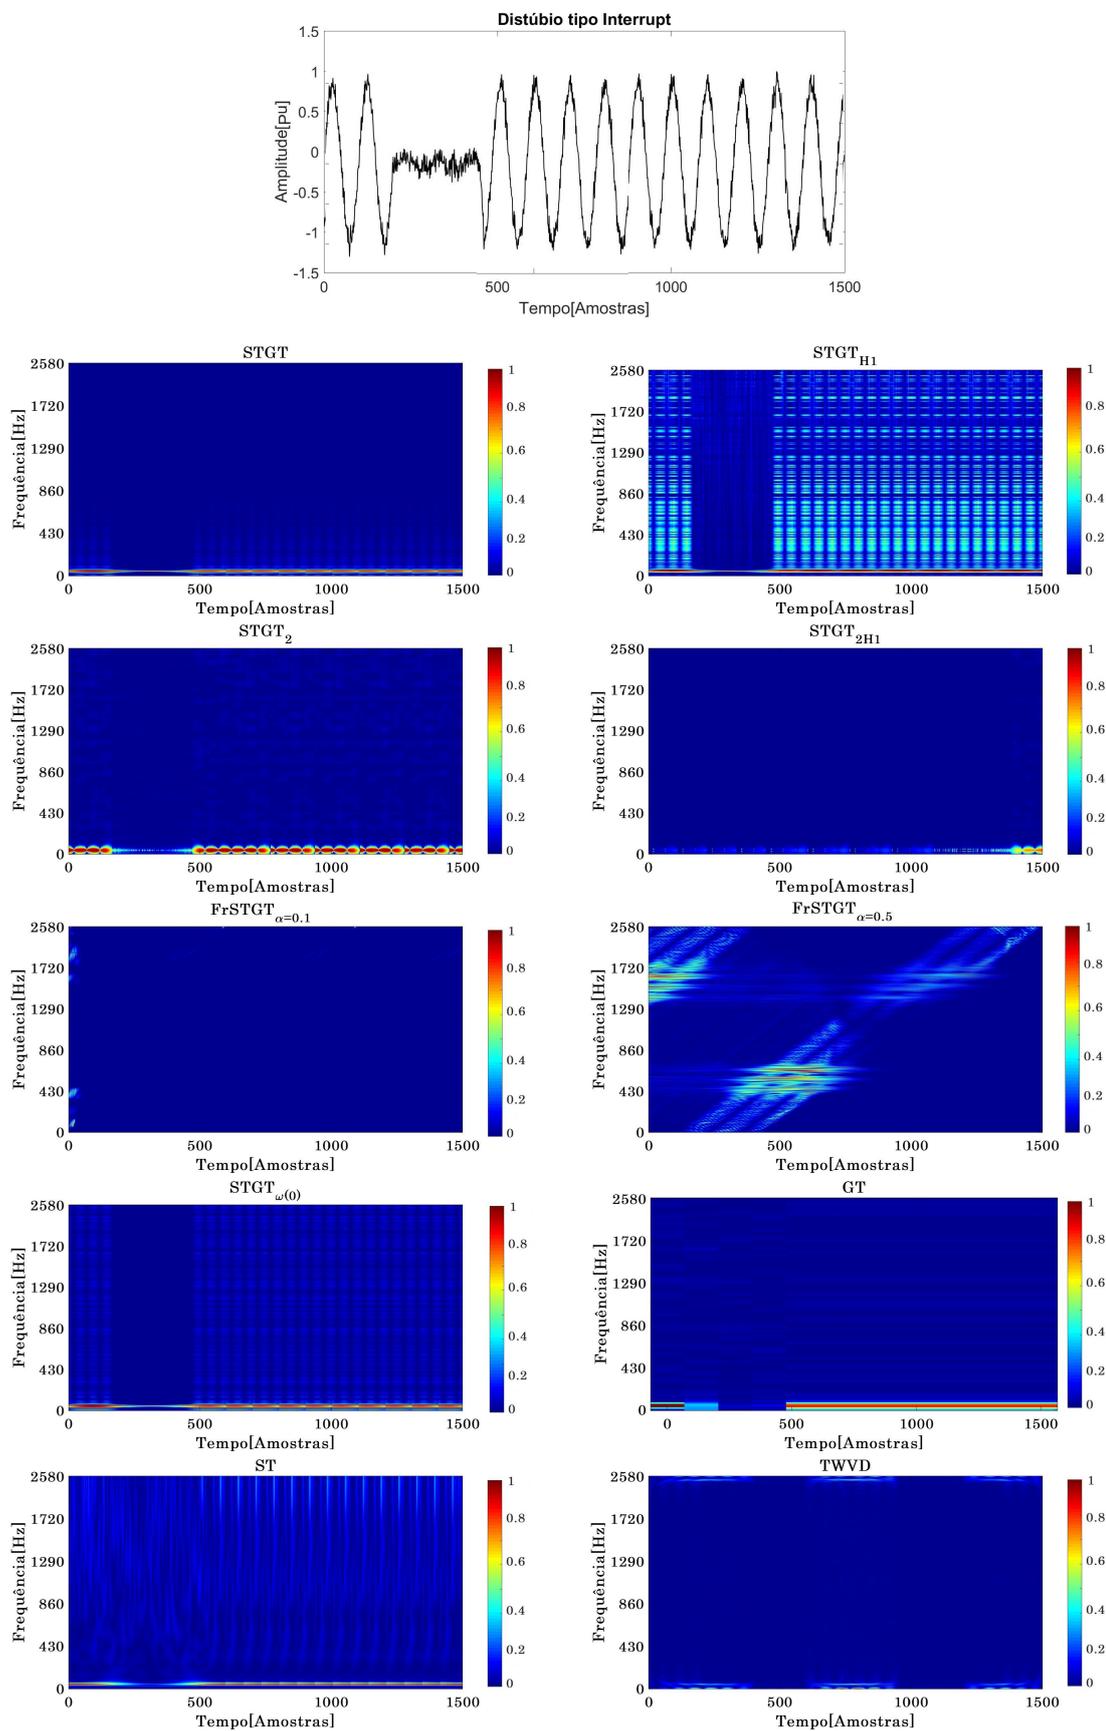


Figura B.7: Aplicação das Transformadas a um Distúrbio tipo Interrupt- IFTM

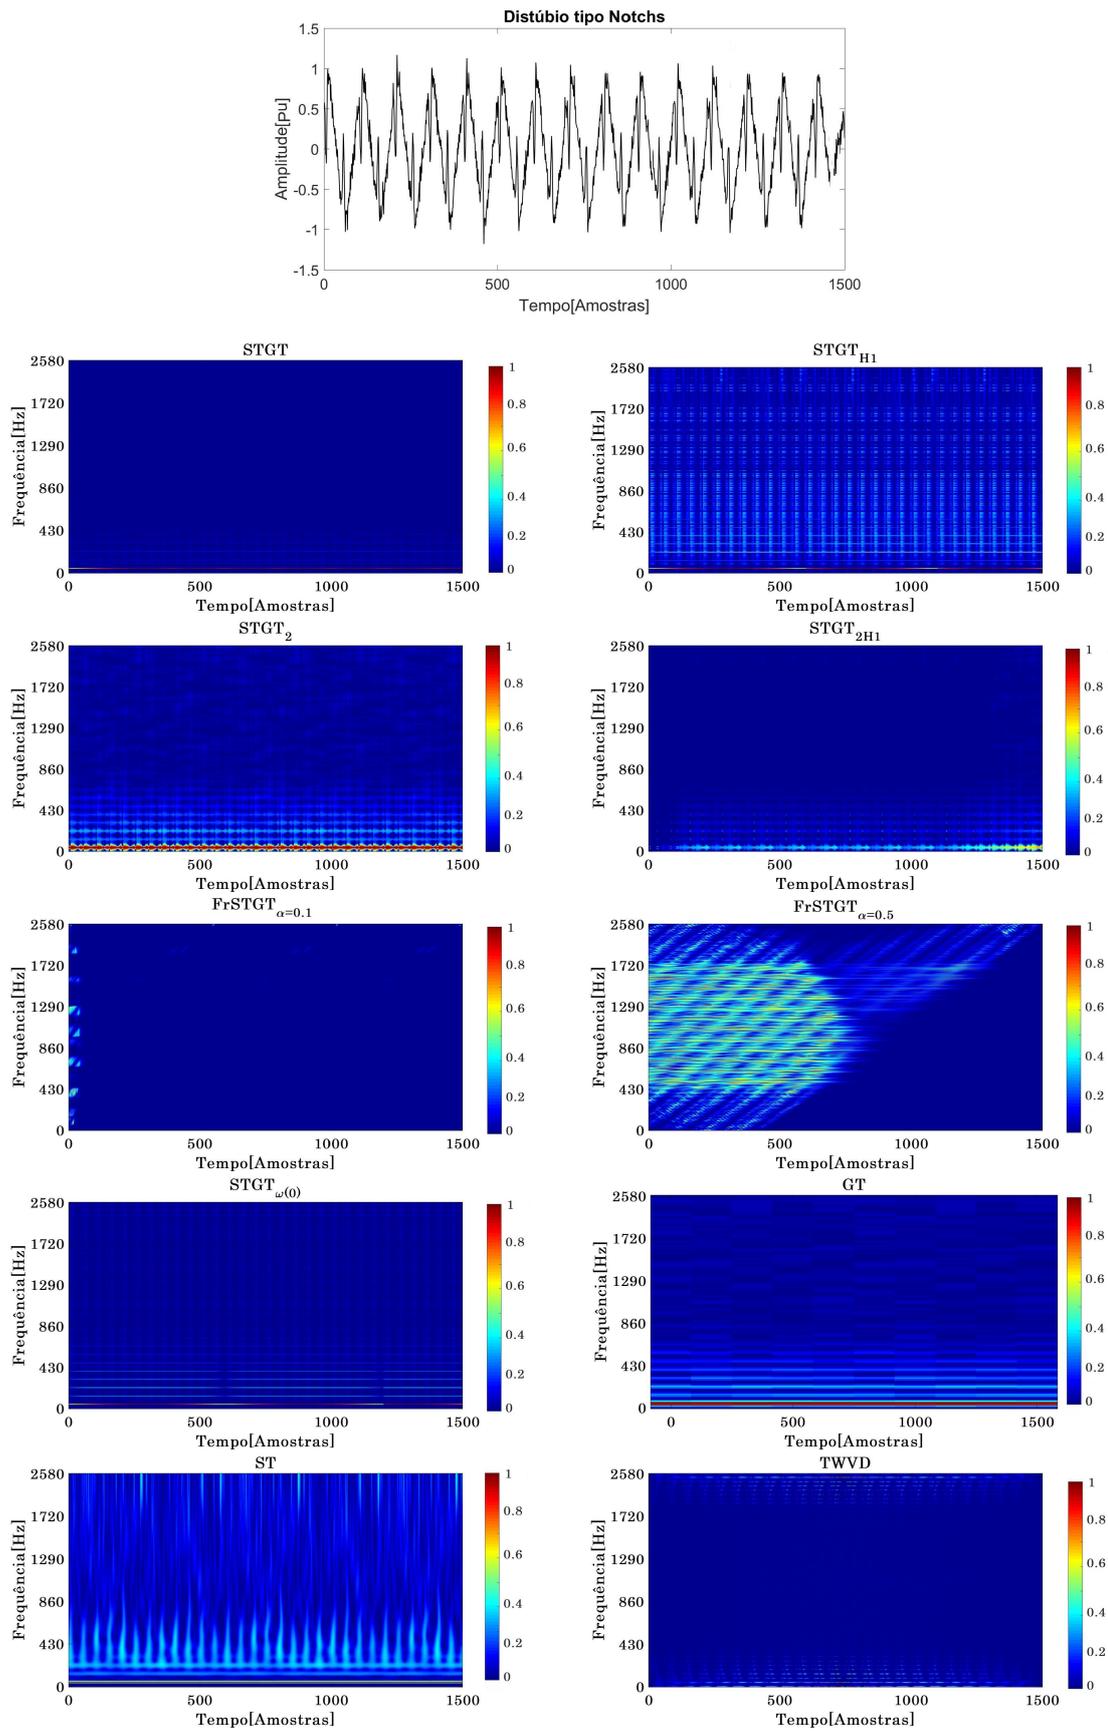


Figura B.8: Aplicação das Transformadas a um Distúrbio tipo Notchs - IFTM

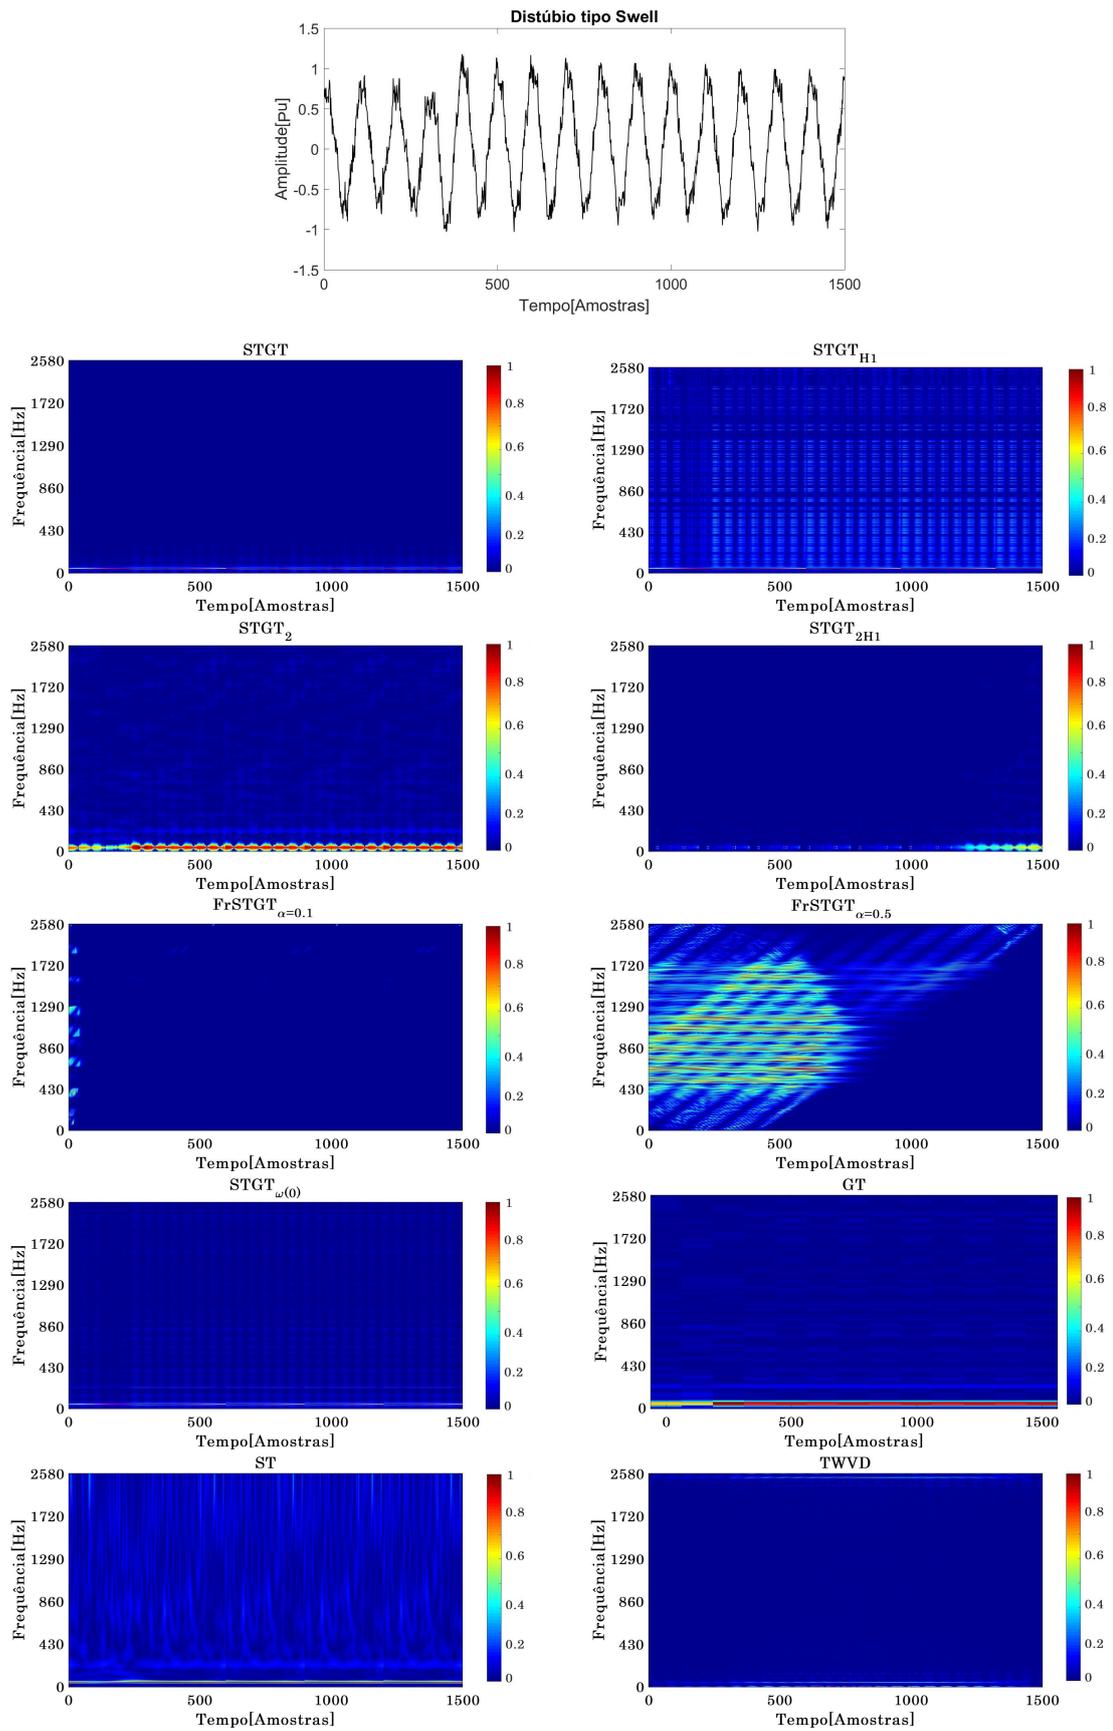


Figura B.9: Aplicação das Transformadas a um Distúrbio tipo Swell - IFTM

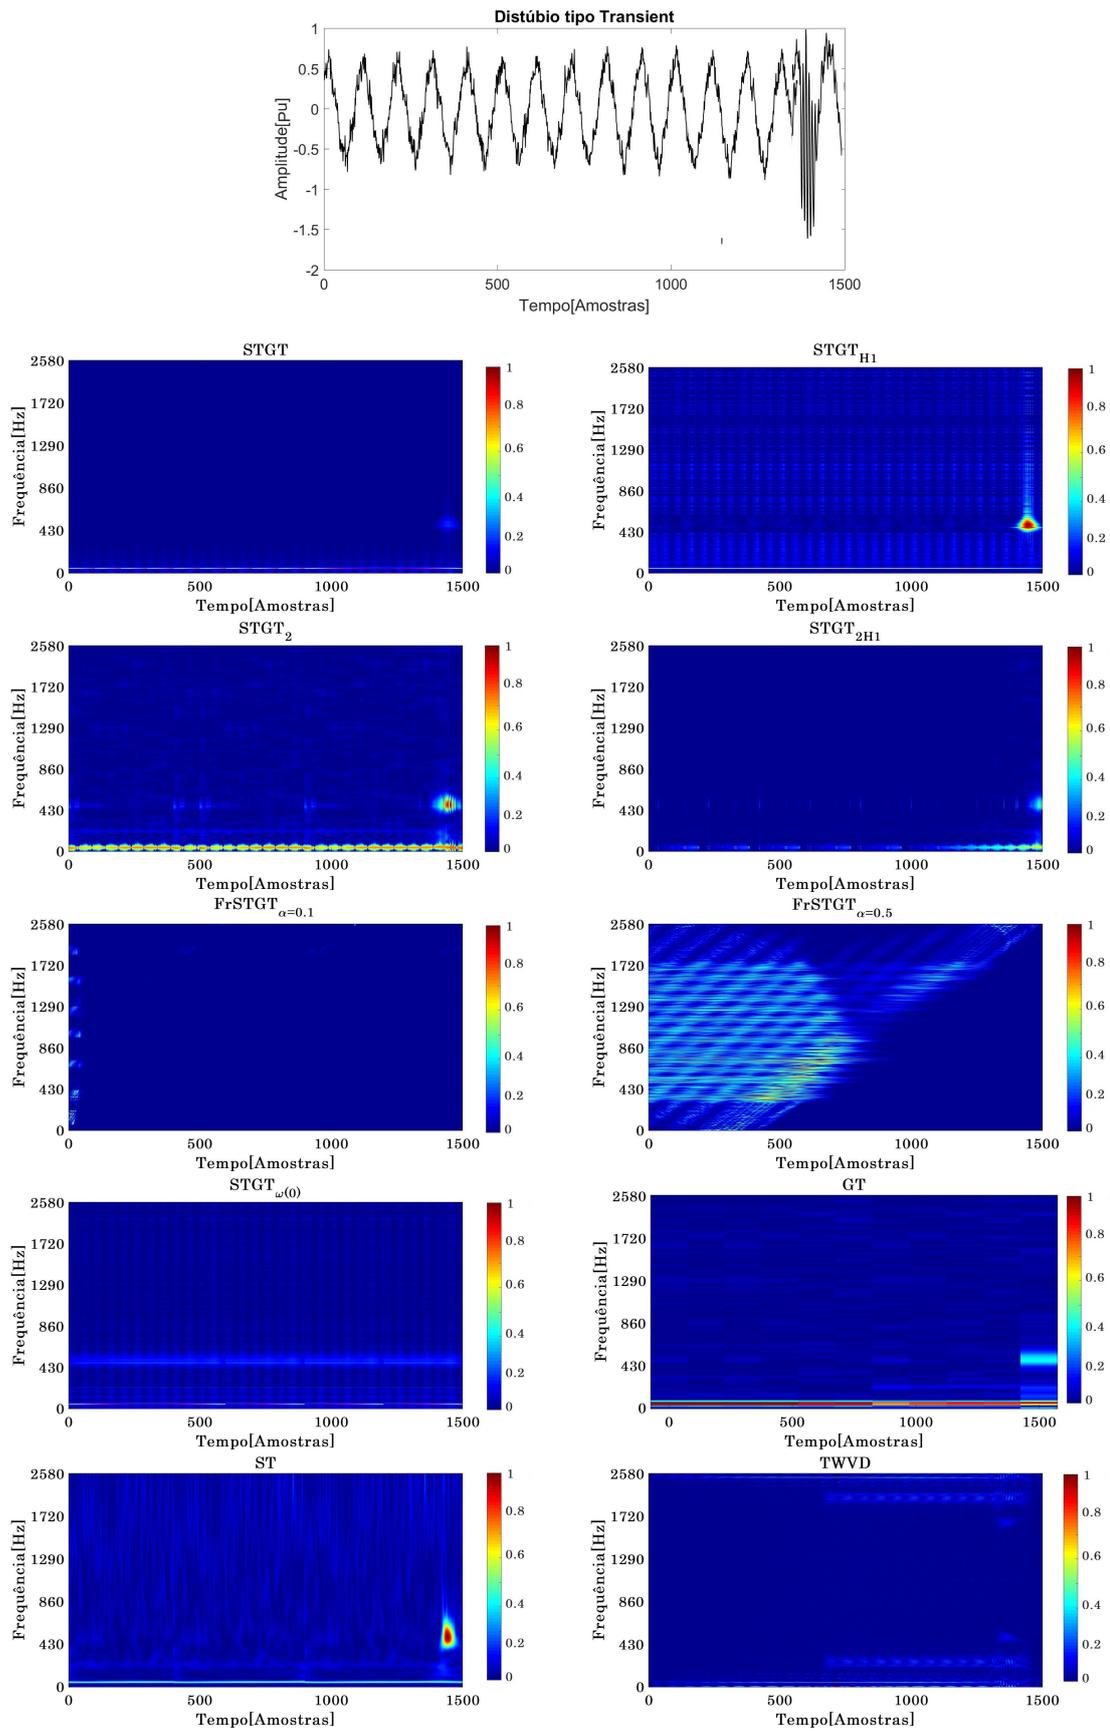


Figura B.10: Aplicação das Transformadas a um Distúrbio tipo Transient - IFTM

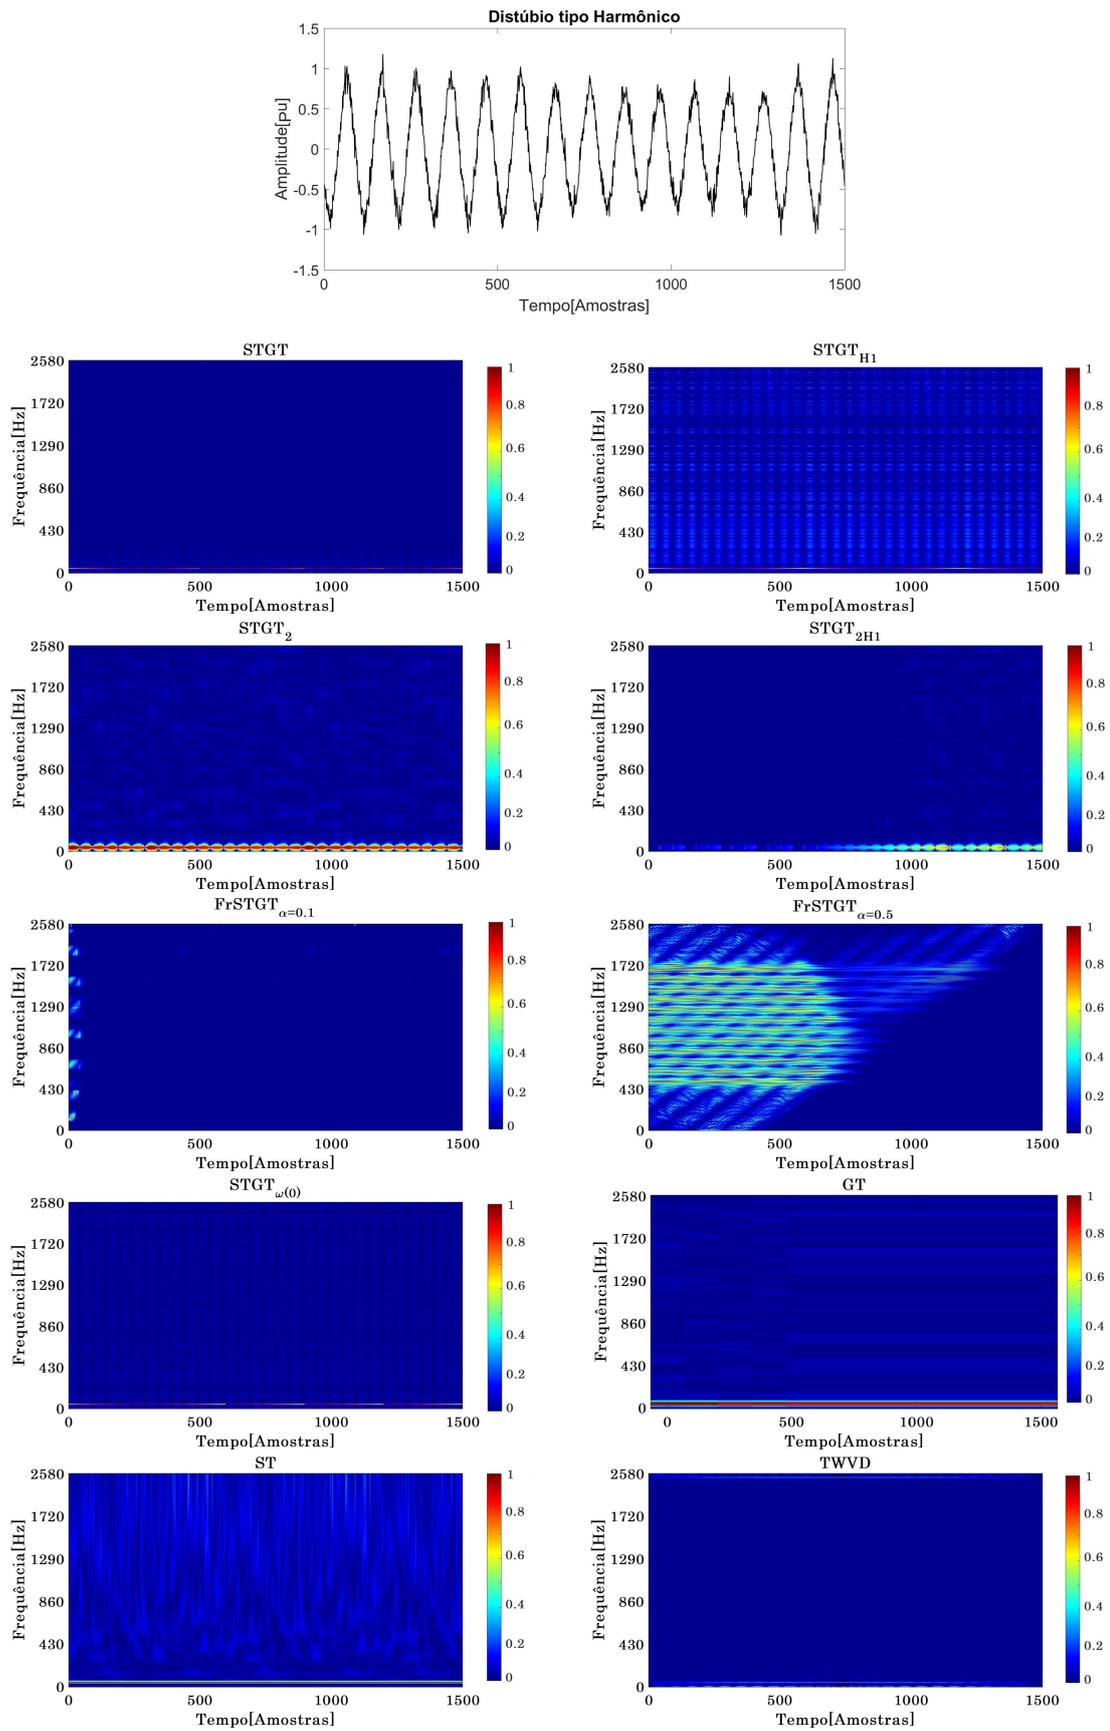


Figura B.11: Aplicação das Transformadas a um Distúrbio tipo Harmônico - IFTM

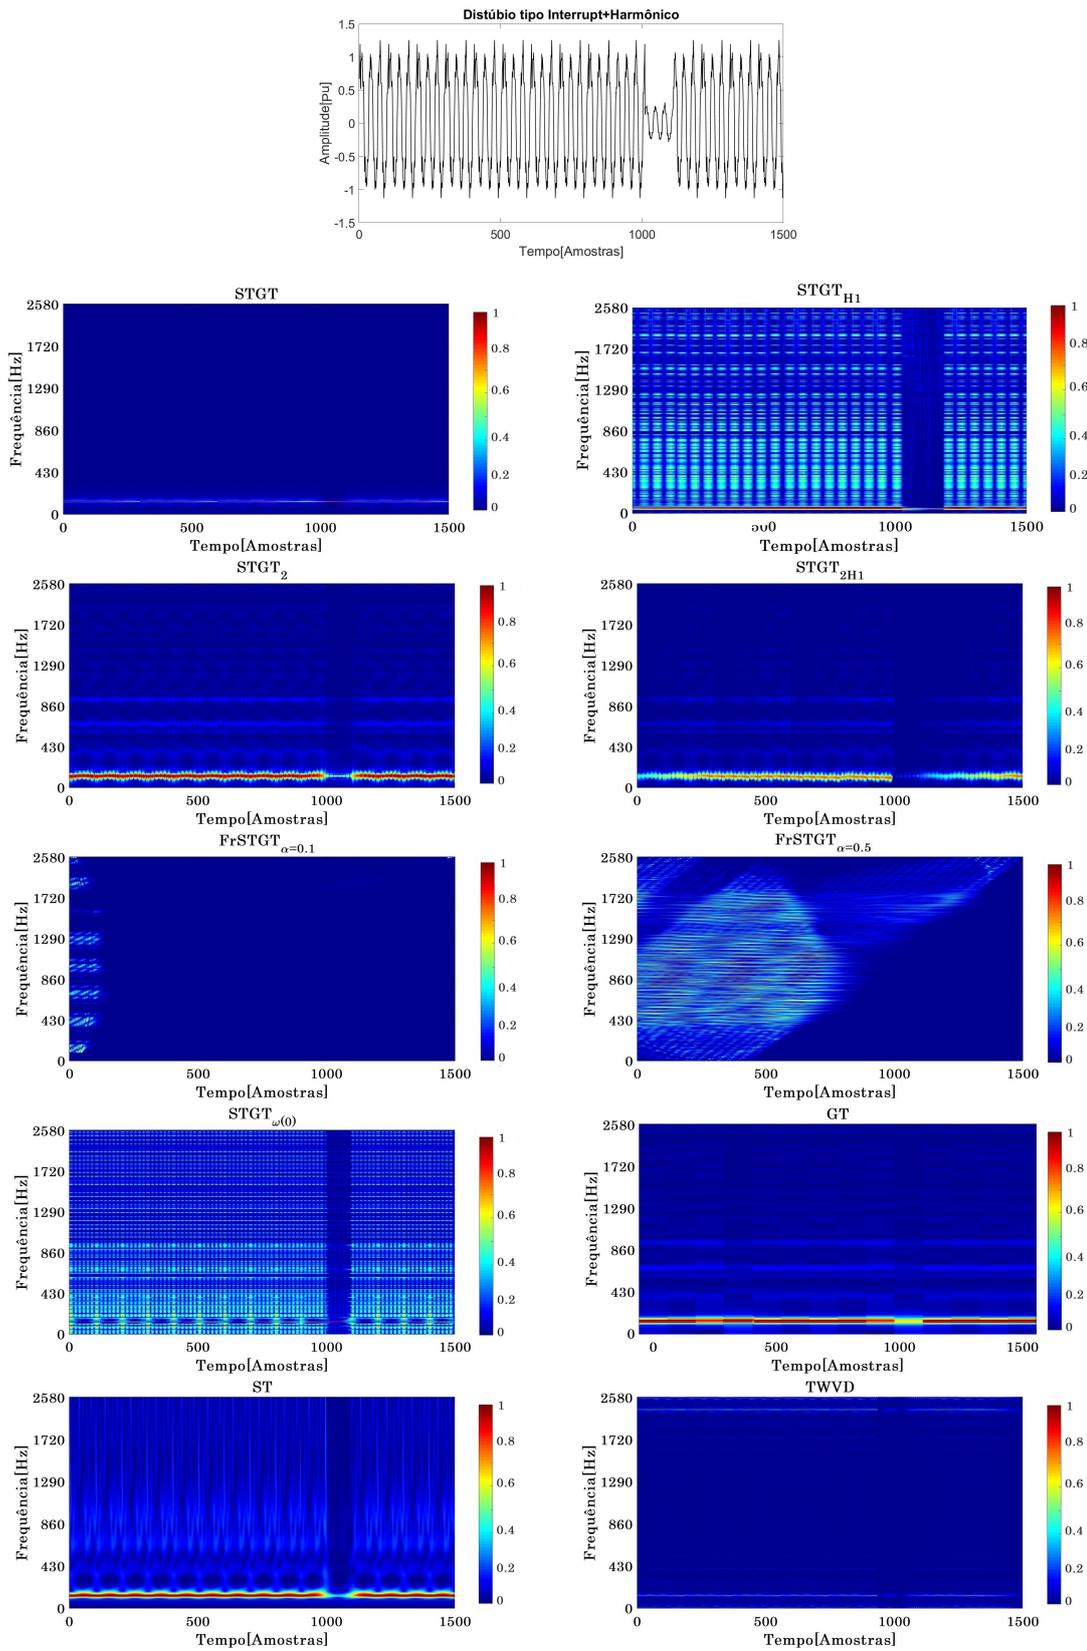


Figura B.12: Aplicação das Transformadas a um Distúrbio tipo Interrupt+Harmônico - IFTM

B.3 Resultados Experimentais Sintéticos

Por completeza, apresentamos aqui os resultados reportados no nosso artigo na ICHQP 2016 [51], em que foi considerada apenas a classificação, por Similaridade, de distúrbios simples a partir de sinais sintéticos sob ruído de 20 dB a 40 dB. O desempenho das transformadas STGT e STGT₂ foi comparado com o da transformada de Gabor e o da transformada S , conforme as tabelas abaixo. Os espectrogramas obtidos são apresentados em seguida.

Tabela B.1: Classificação - Sinais com 20db

Distúrbios	STGT	GT	ST	STGT₂
Sag	75,3	55,3	81,3	81
Swell	95	100	100	100
Interrupts	100	100	93	100
Harmonics	81	100	100	100
Transients	100	100	100	97
Spikes	100	100	100	100
Notches	90	100	98	100
Total	91,6	93,6	96	97

Tabela B.2: Classificação - Sinais com 30db

Distúrbios	STGT	GT	ST	STGT₂
Sags	80	70	88	83
Swells	97	100	100	100
Interrupts	100	95	100	100
Harmonics	83	98	100	100
Transients	100	100	100	97,7
Spikes	98	100	100	100
Notches	92	97	95	100
Total	93	95	97	97,2

Tabela B.3: Classificação - Sinais com 40db

Distúrbios	STGT	GT	ST	STGT₂
Sags	92	76	91,5	98
Swells	97,2	100	100	100
Interrupts	100	100	95,4	100
Harmonics	85	98	100	100
Transients	100	100	100	97
Spikes	100	100	100	100
Notches	95	97	97	100
Total	95,6	95,8	97,7	99,3

Em nossos experimentos, nós verificamos que certas condições dificultam a correta identificação de determinados distúrbios. Por exemplo, no caso de um distúrbio do tipo *Sag*, quando a amplitude cai para um valor próximo a 0.1 p.u., este pode ser classificado como um *Interrupt*, e, no caso de *Transients*, *Notches* ou *Spikes*, esses distúrbios tendem a ser confundidos quando possuem uma baixa amplitude (na faixa entre 0.1 e 0.2 p.u).

Para confirmar a influência do valor da amplitude do distúrbio na classificação obtida, nós modificamos este parâmetro em todos os sinais considerados, mantendo a forma de onda gerada sempre acima de 0.2 p.u. As Tabelas B.4 a B.6, a seguir, informam o

percentual de identificação obtido sob essas condições, em 1000 experimentos para cada nível de ruído. Verifica-se um substancial incremento nos índices de acerto de todas as transformadas, sendo que a $STGT_2$ atinge 100% de acurácia em todos os casos.

Tabela B.4: 2^a Classificação - Sinais com 20db

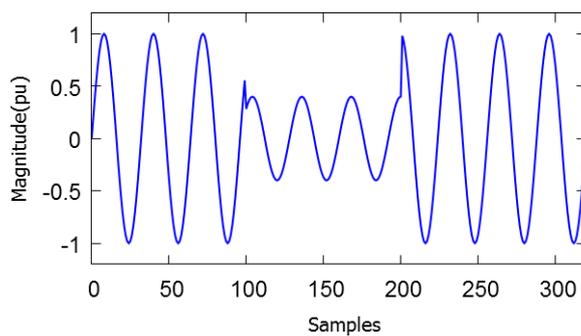
Distúrbios	STGT	GT	ST	STGT₂
Sags	89	92	98	100
Swells	100	100	100	100
Interrupts	100	100	100	100
Harmonics	90	92	100	100
Transients	100	100	100	100
Spikes	100	100	100	100
Notches	100	100	100	100
Total	97	97,7	99,7	100

Tabela B.5: 2^a Classificação - Sinais com 30db

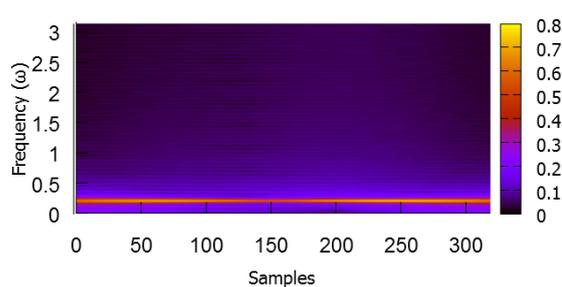
Distúrbios	STGT	GT	ST	STGT₂
Sags	95	94	100	100
Swells	100	100	100	100
Interrupts	100	100	100	100
Harmonics	93	95	100	100
Transients	100	100	100	100
Spikes	100	100	100	100
Notches	100	100	100	100
Total	98,1	98,4	100	100

Tabela B.6: 2^a Classificação - Sinais com 40db

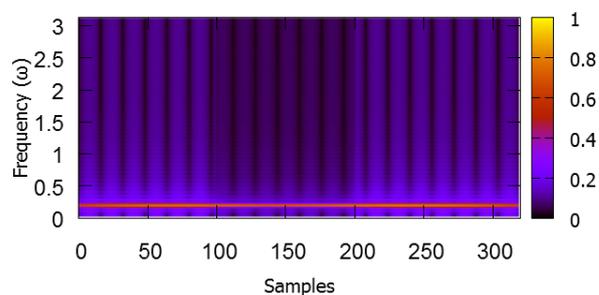
Distúrbios	STGT	GT	ST	STGT₂
Sags	95	96	100	100
Swells	100	100	100	100
Interrupts	100	100	100	100
Harmonics	95	97	100	100
Transients	100	100	100	100
Spikes	100	100	100	100
Notches	100	100	100	100
Total	98,5	99	100	100



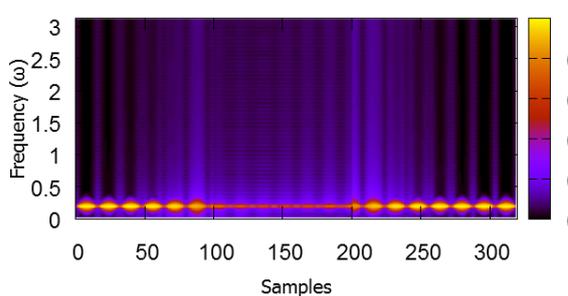
(a)



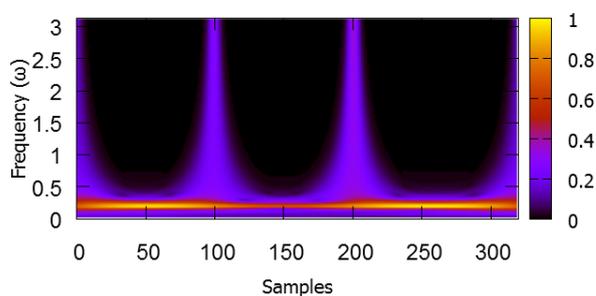
(b)



(c)



(d)



(e)

Figura B.13: (a) Sinal sem ruído com distúrbio tipo *Sag*, (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT₂, (e) Espectrograma ST.

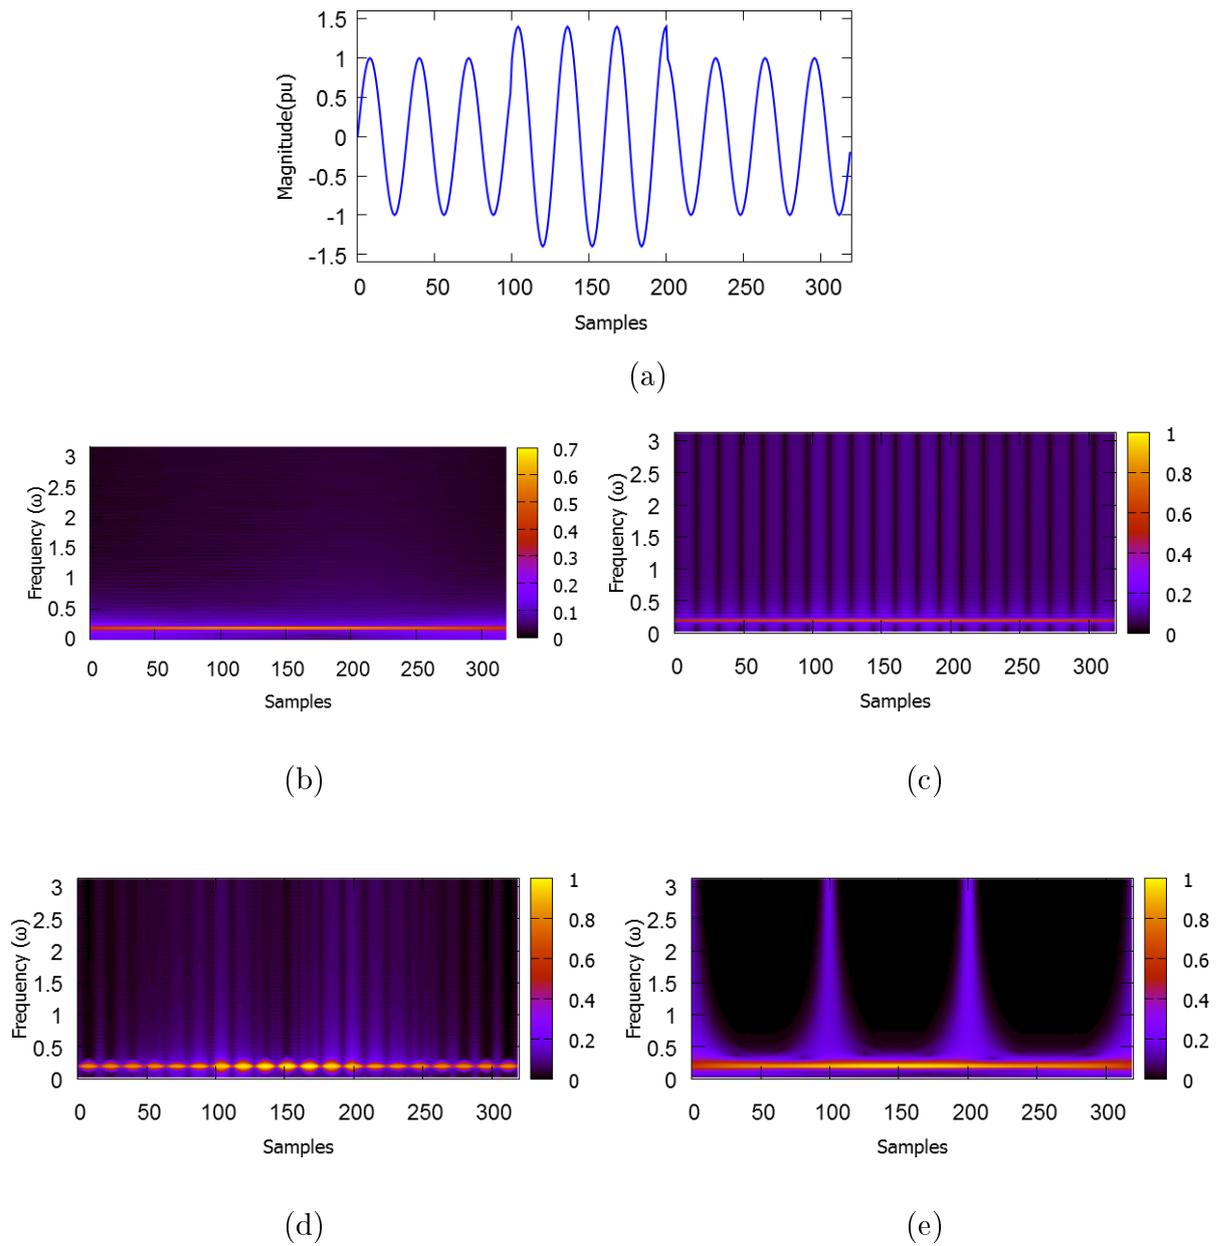


Figura B.14: (a) Sinal sem ruído com distúrbio tipo *Swell*, (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT₂, (e) Espectrograma ST.

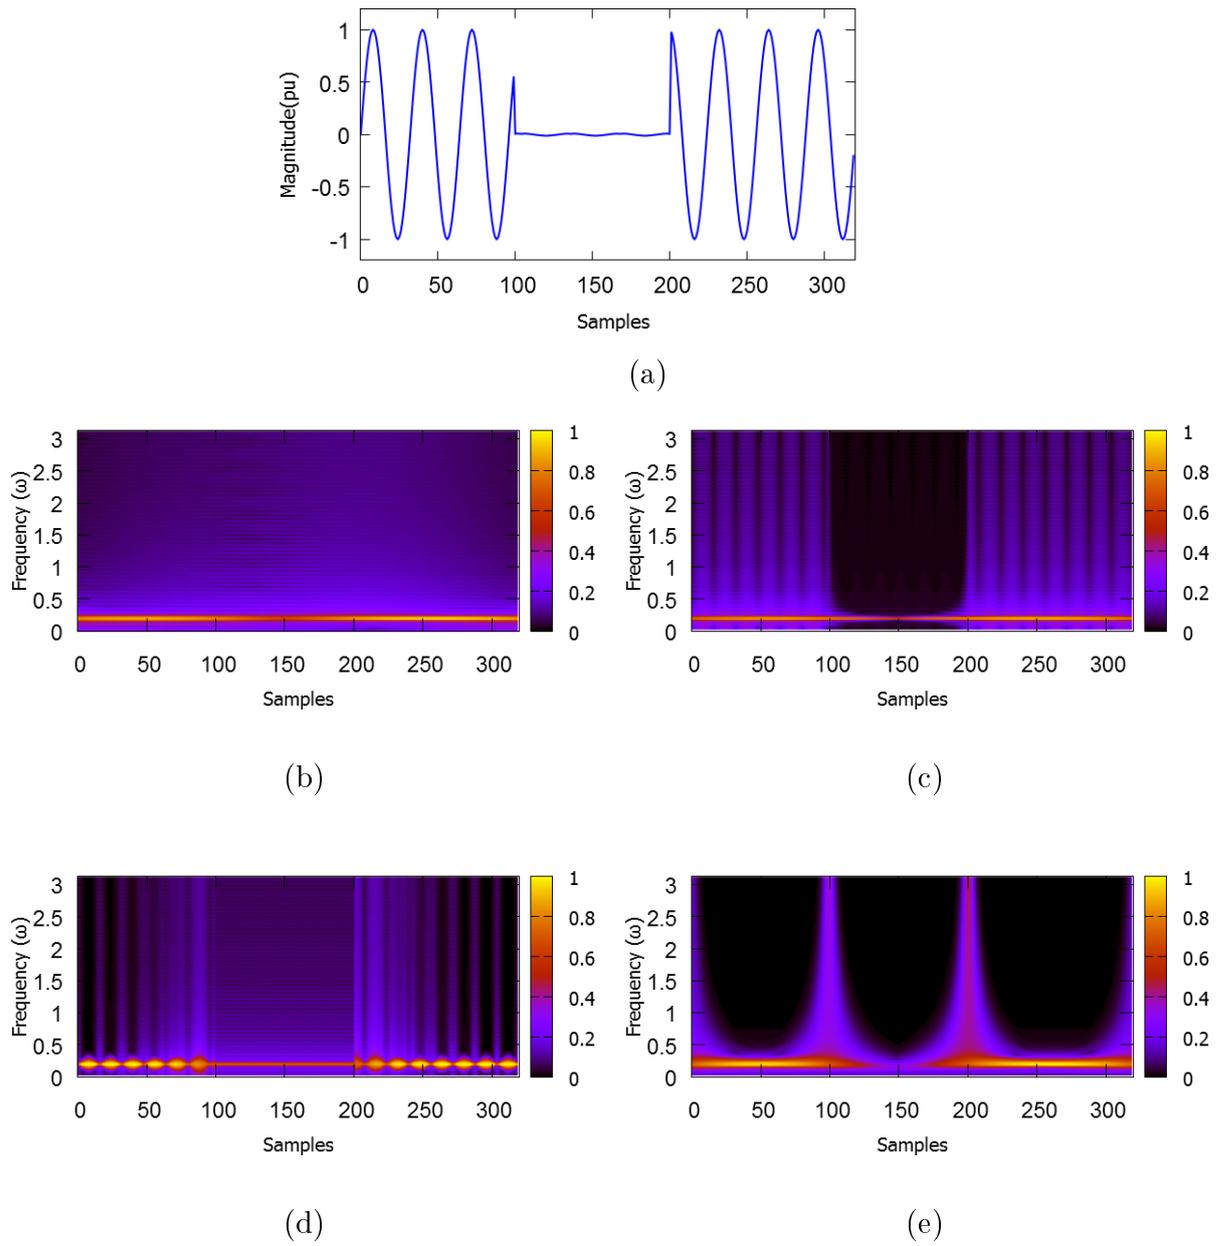


Figura B.15: (a) Sinal sem ruído com distúrbio tipo *Interrupt*, (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT₂, (e) Espectrograma ST.

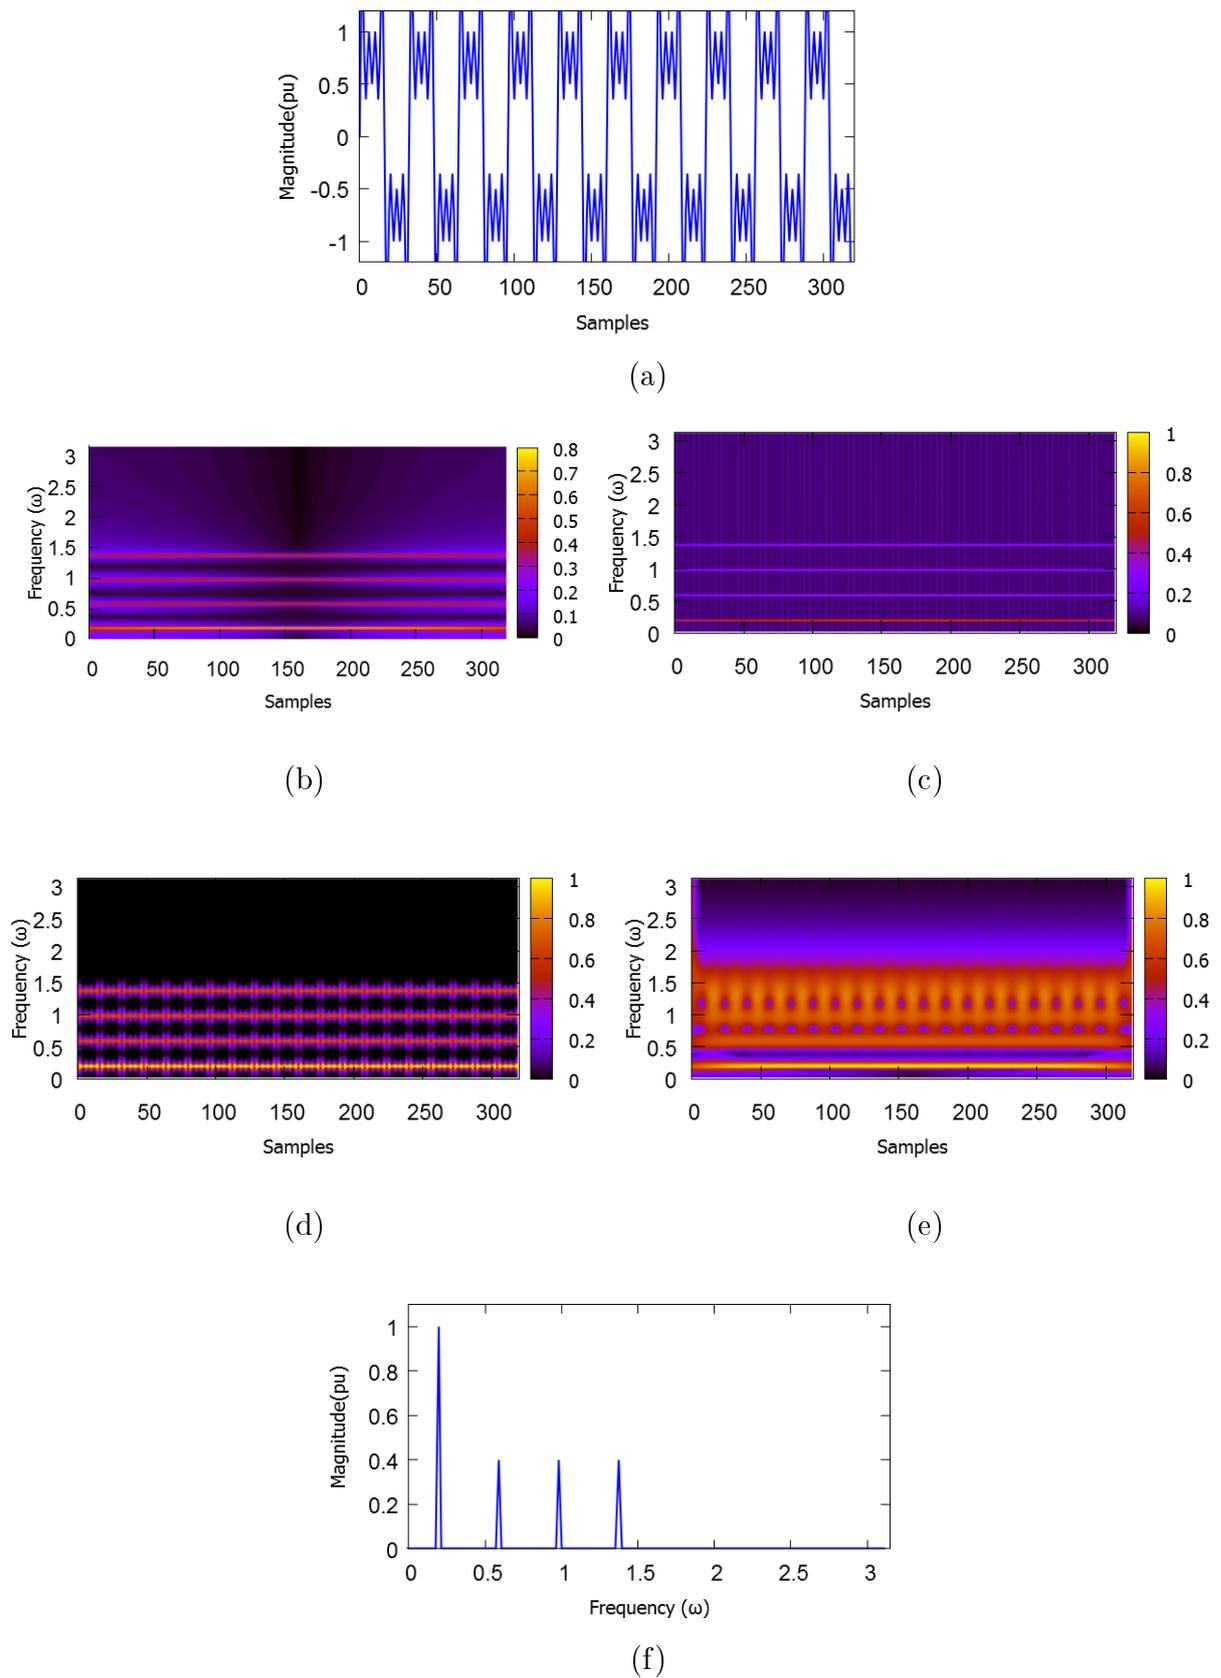


Figura B.16: (a) Sinal sem ruído com distúrbio tipo *Harmonics*, (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma $STGT_2$, (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).

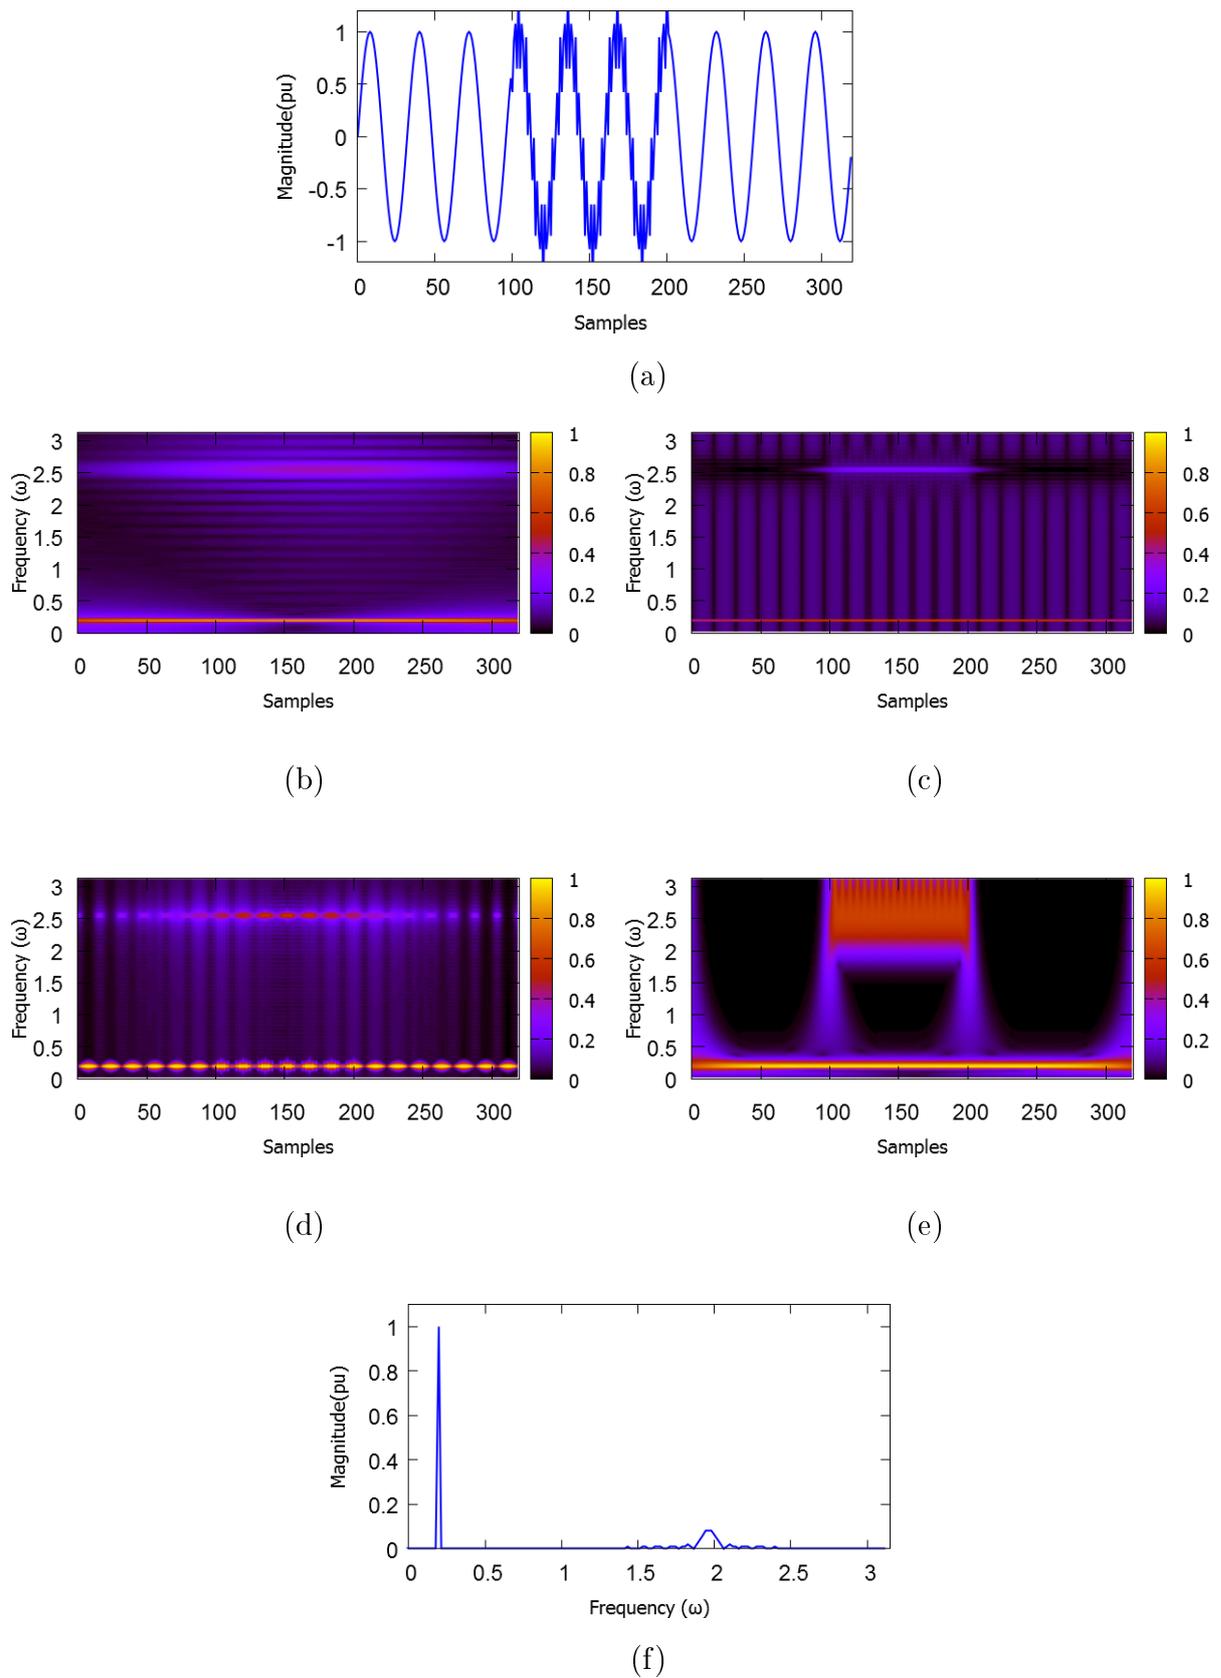


Figura B.17: (a) Sinal sem ruído com distúrbio tipo *Transient*, (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT₂, (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).

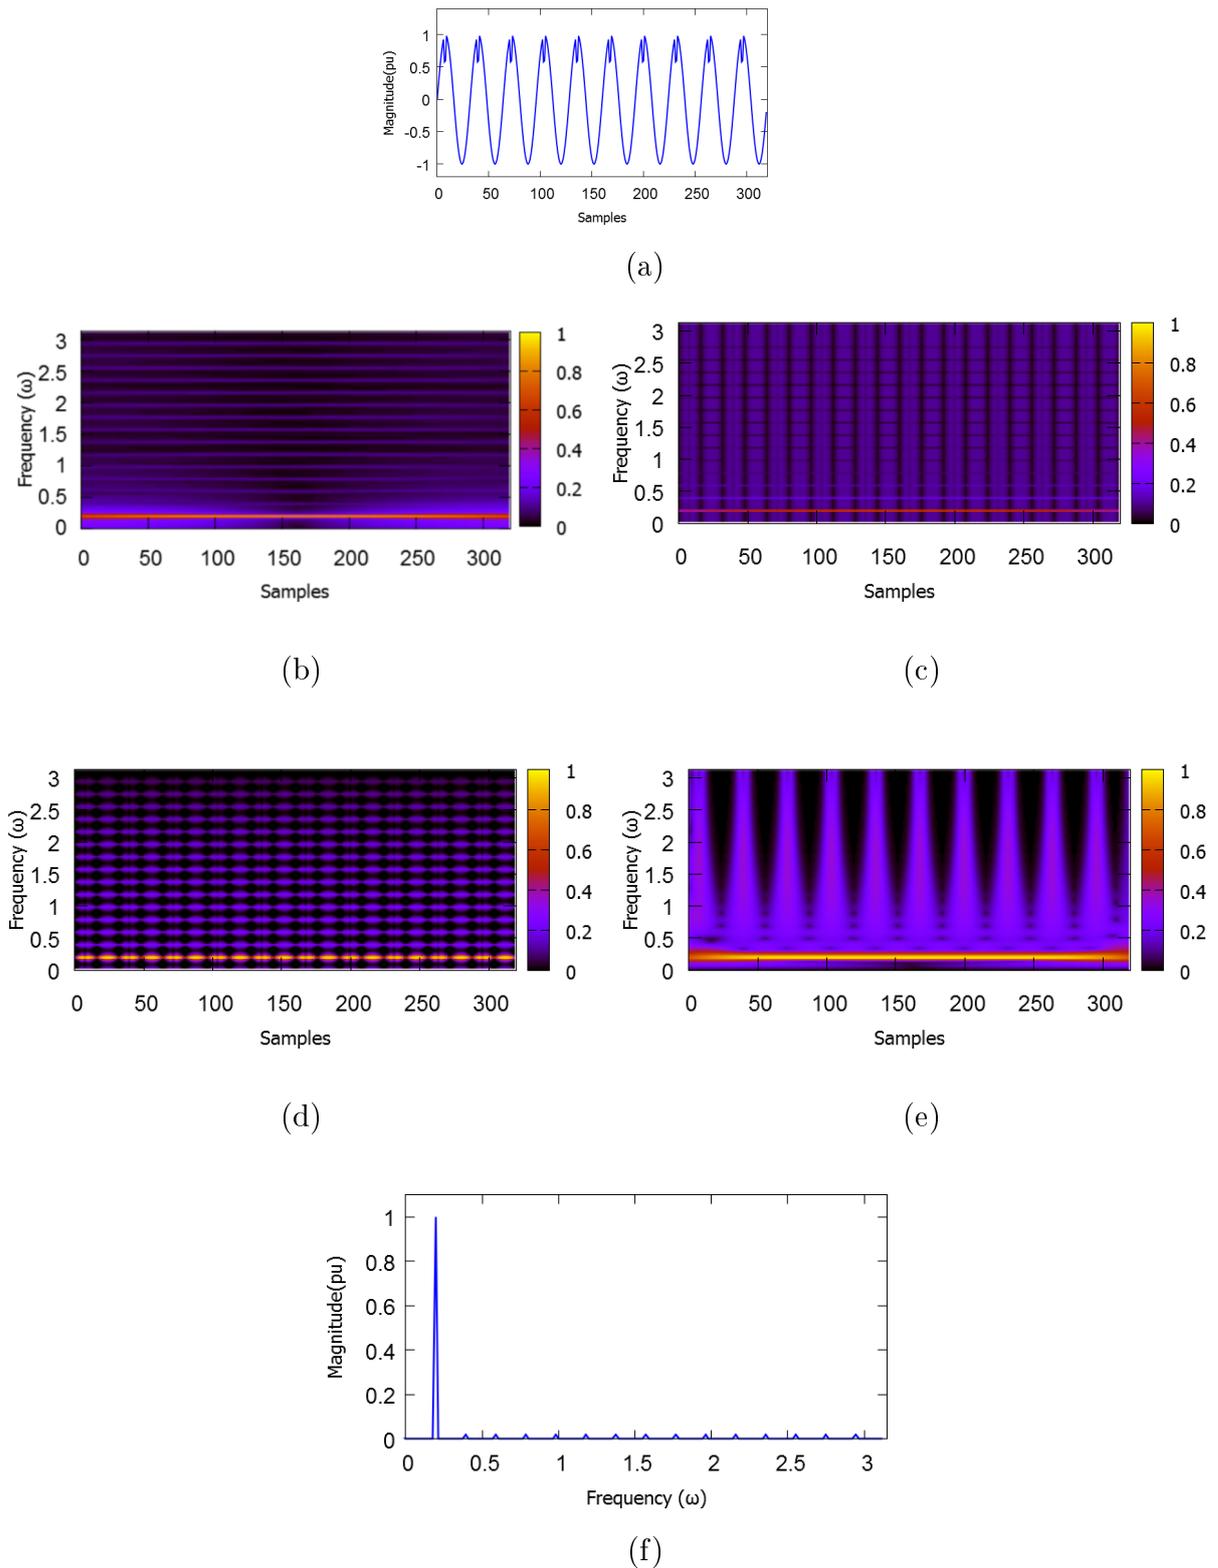


Figura B.18: (a) Sinal sem ruído com distúrbio tipo *Notches*, (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT₂, (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).

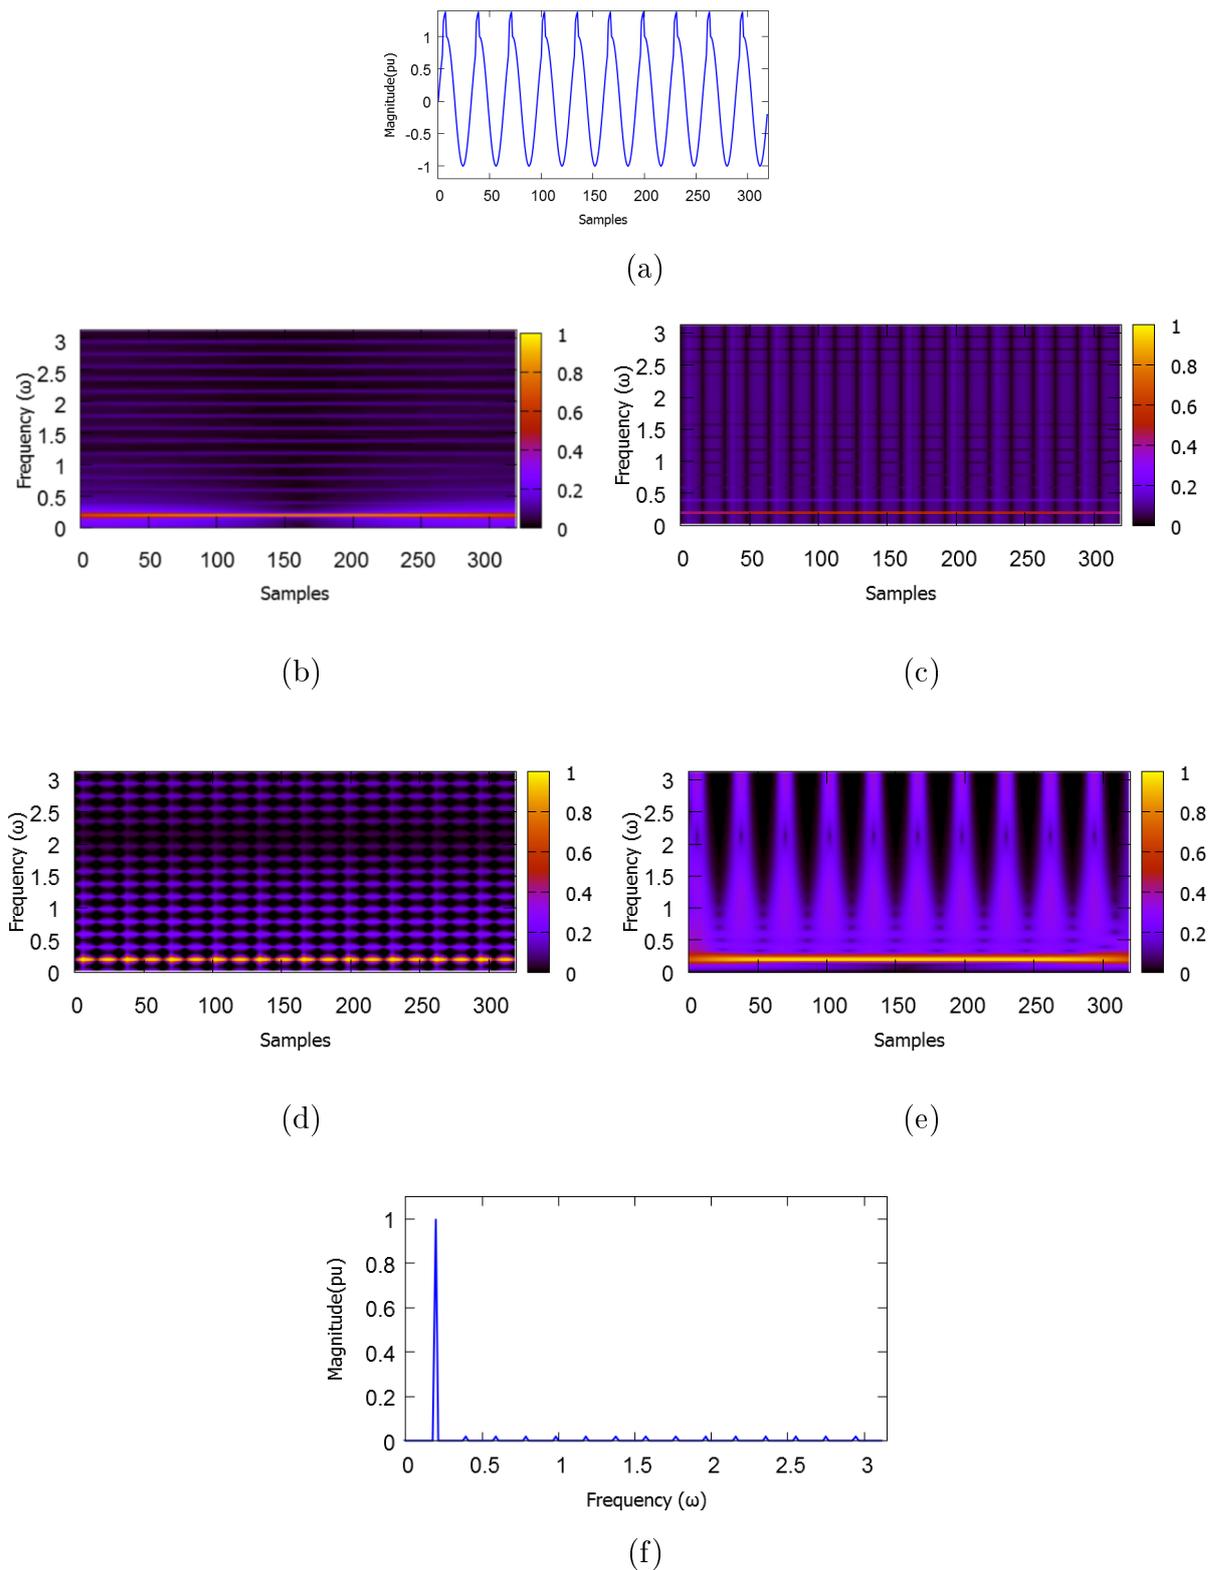


Figura B.19: (a) Sinal sem ruído com distúrbio tipo *Spikes*, (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT₂, (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).

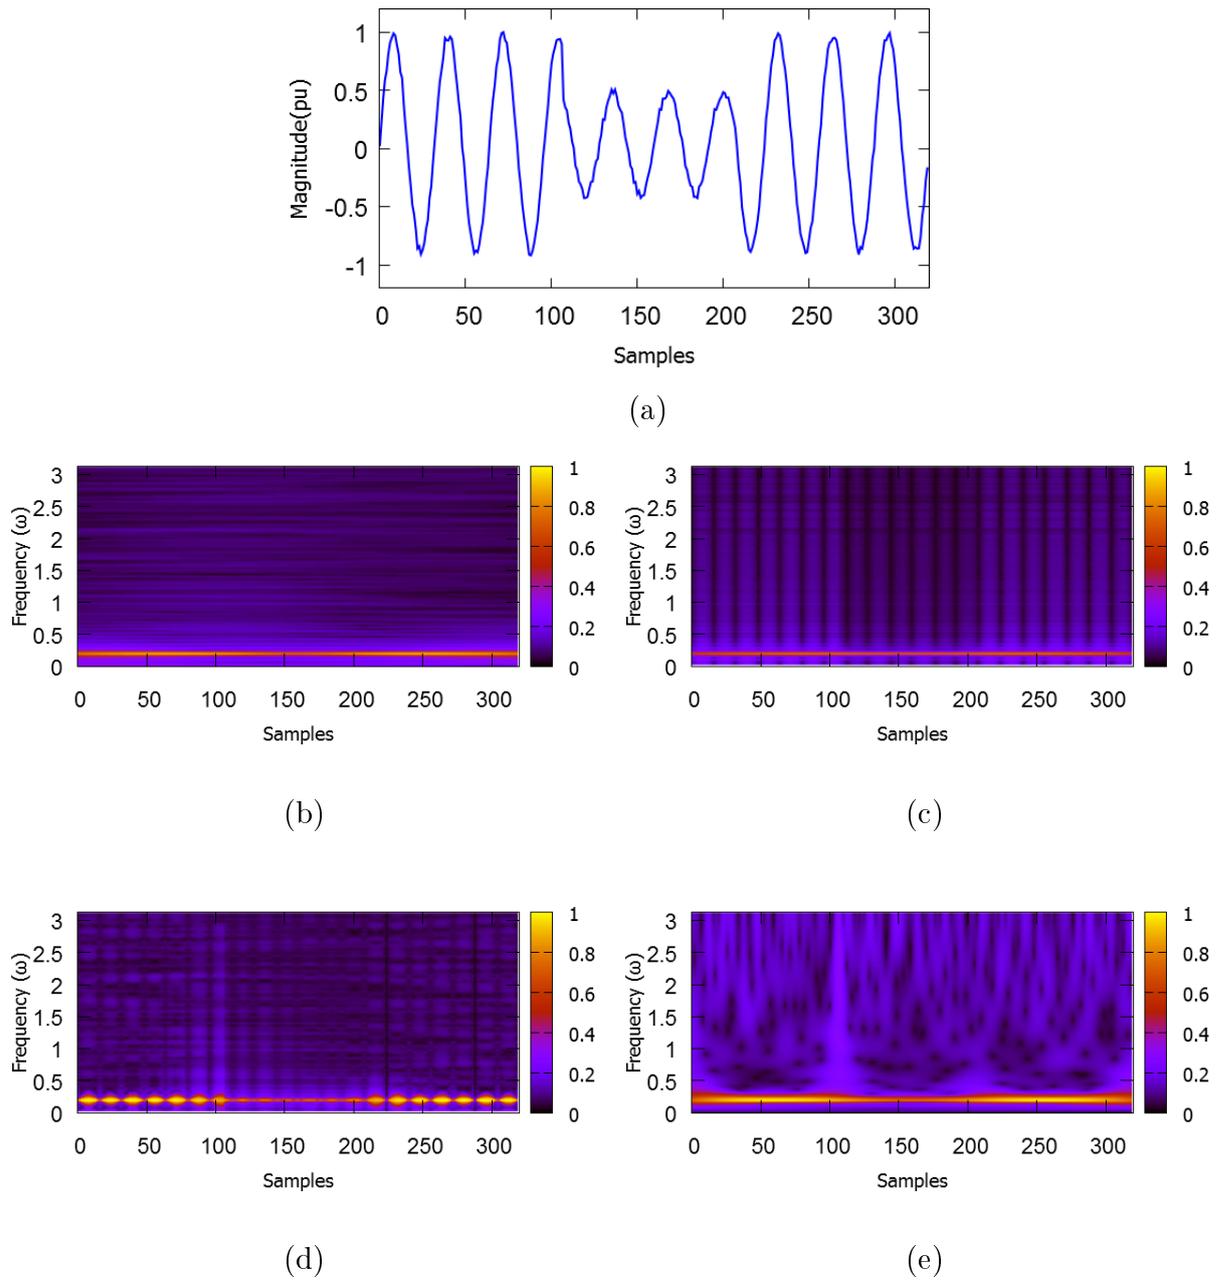


Figura B.20: (a) Sinal com ruído (20db) com distúrbio tipo *Sag*, (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT₂, (e) Espectrograma ST.

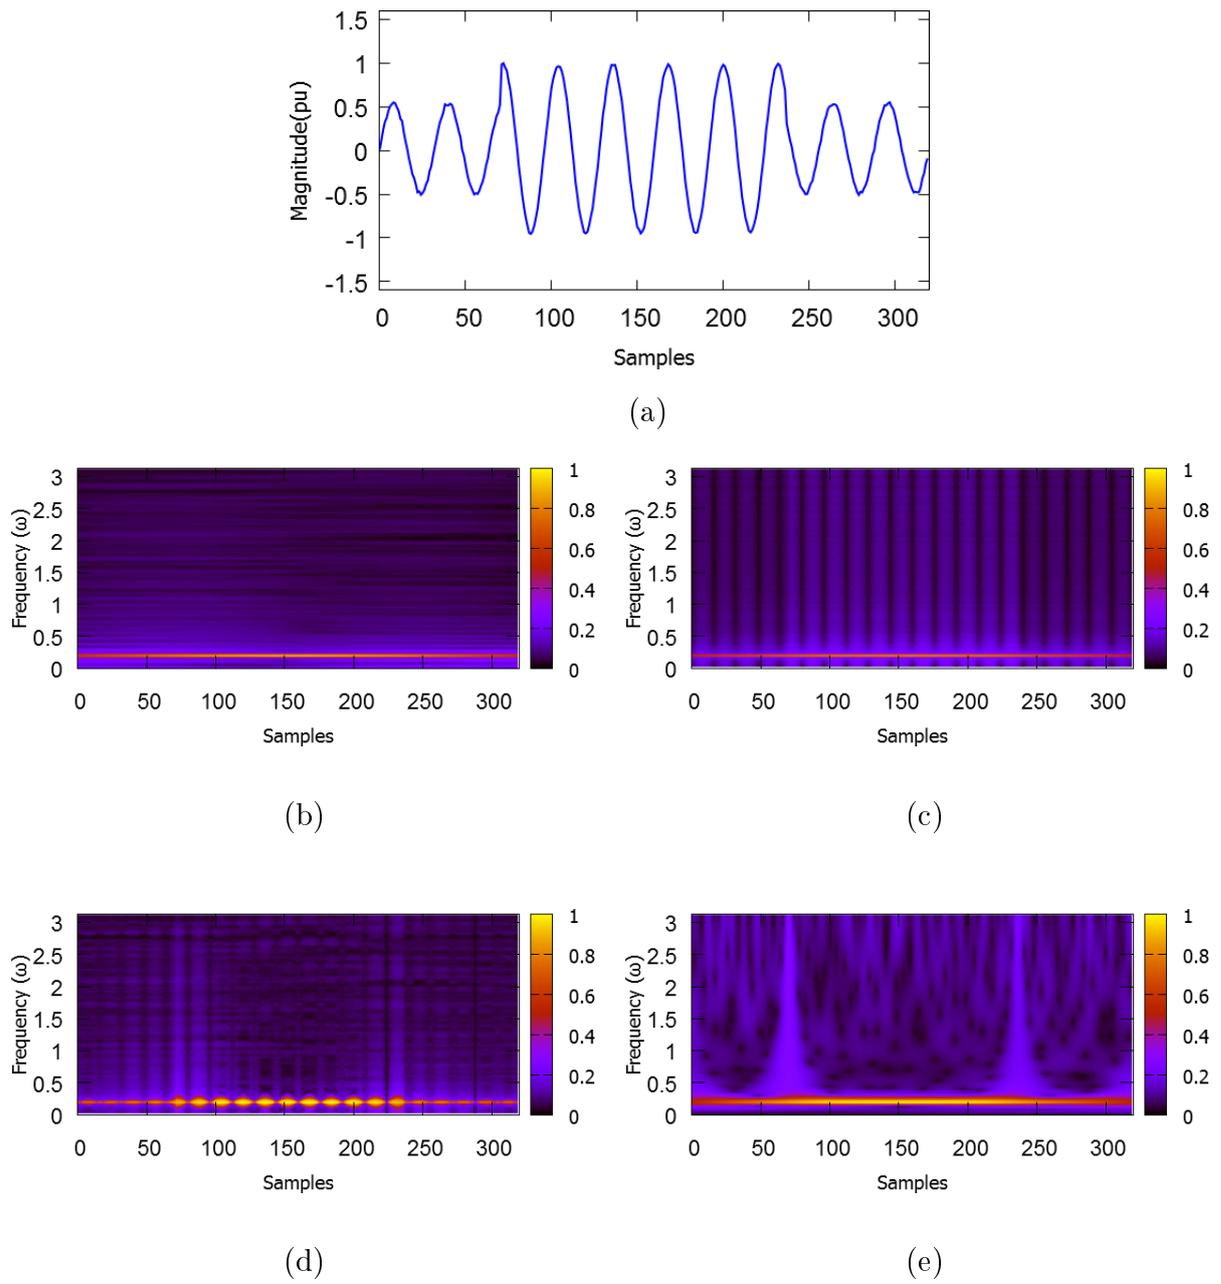


Figura B.21: (a) Sinal com ruído (20db) com distúrbio tipo *Swell*, (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT₂, (e) Espectrograma ST.

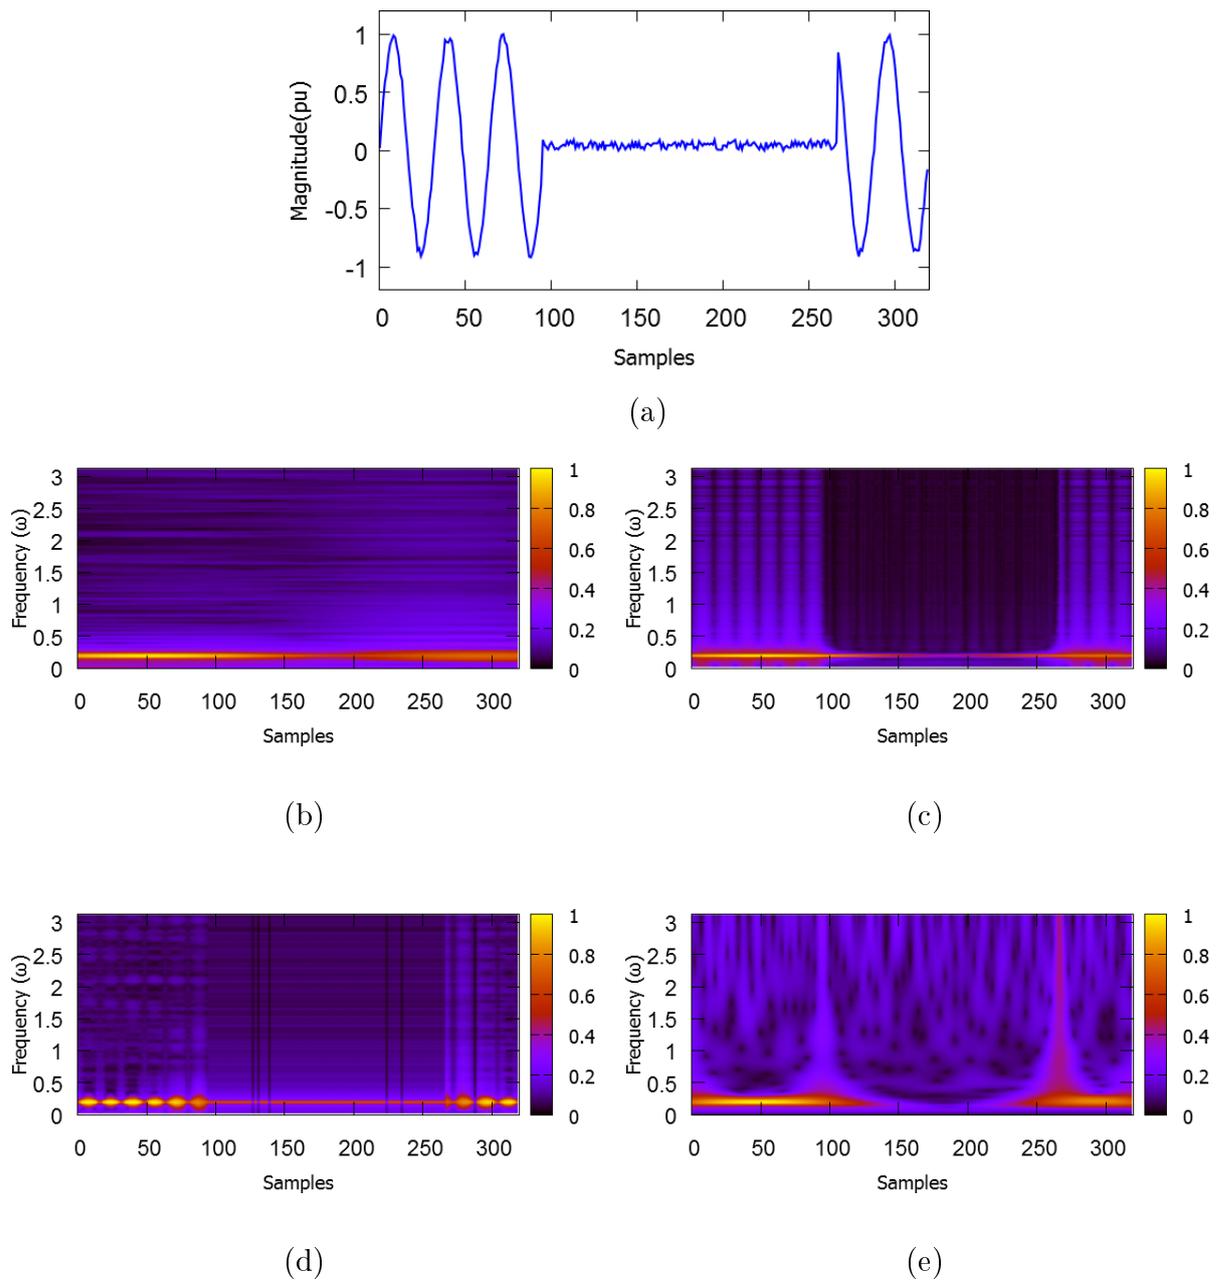


Figura B.22: (a) Sinal com ruído (20db) com distúrbio tipo *Interrupt*, (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT₂, (e) Espectrograma ST.

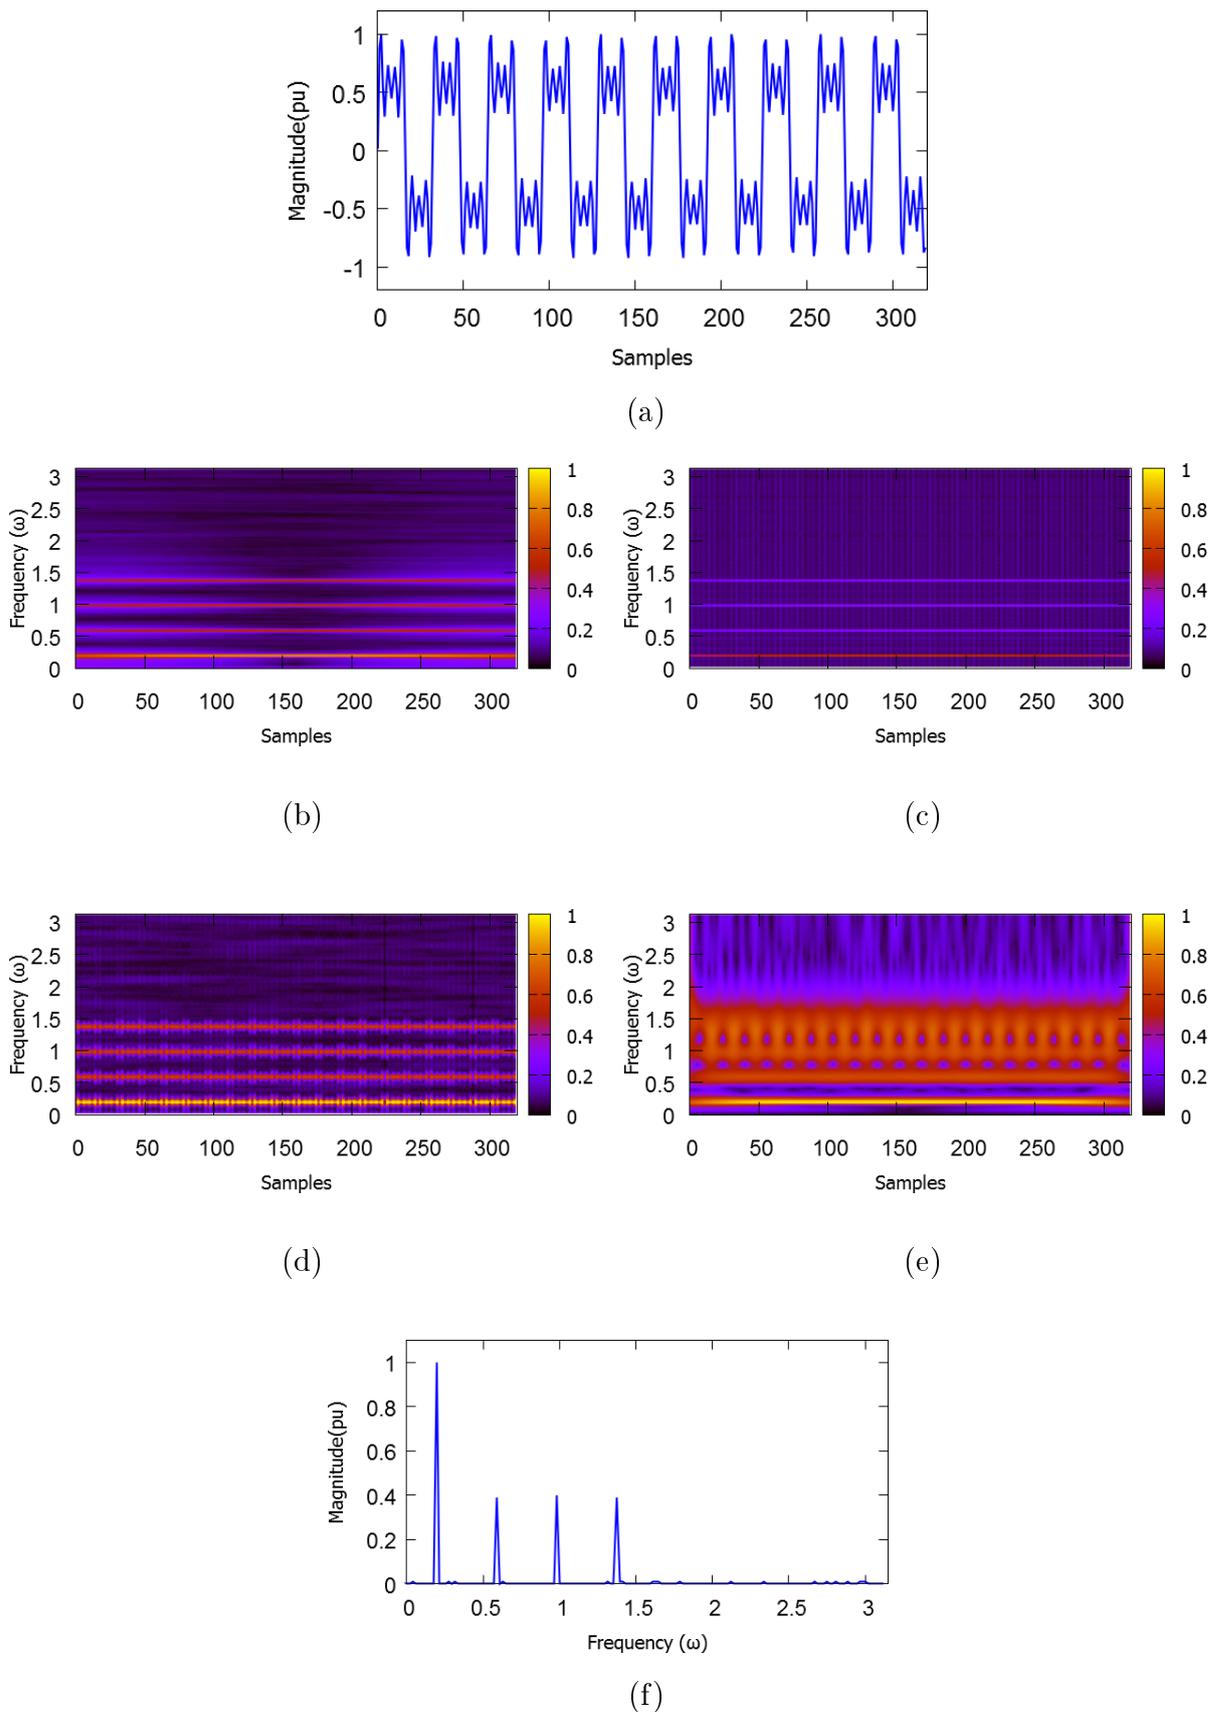


Figura B.23: (a) Sinal com ruído (20db) com distúrbio tipo *Harmonics*, (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma $STGT_2$, (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).

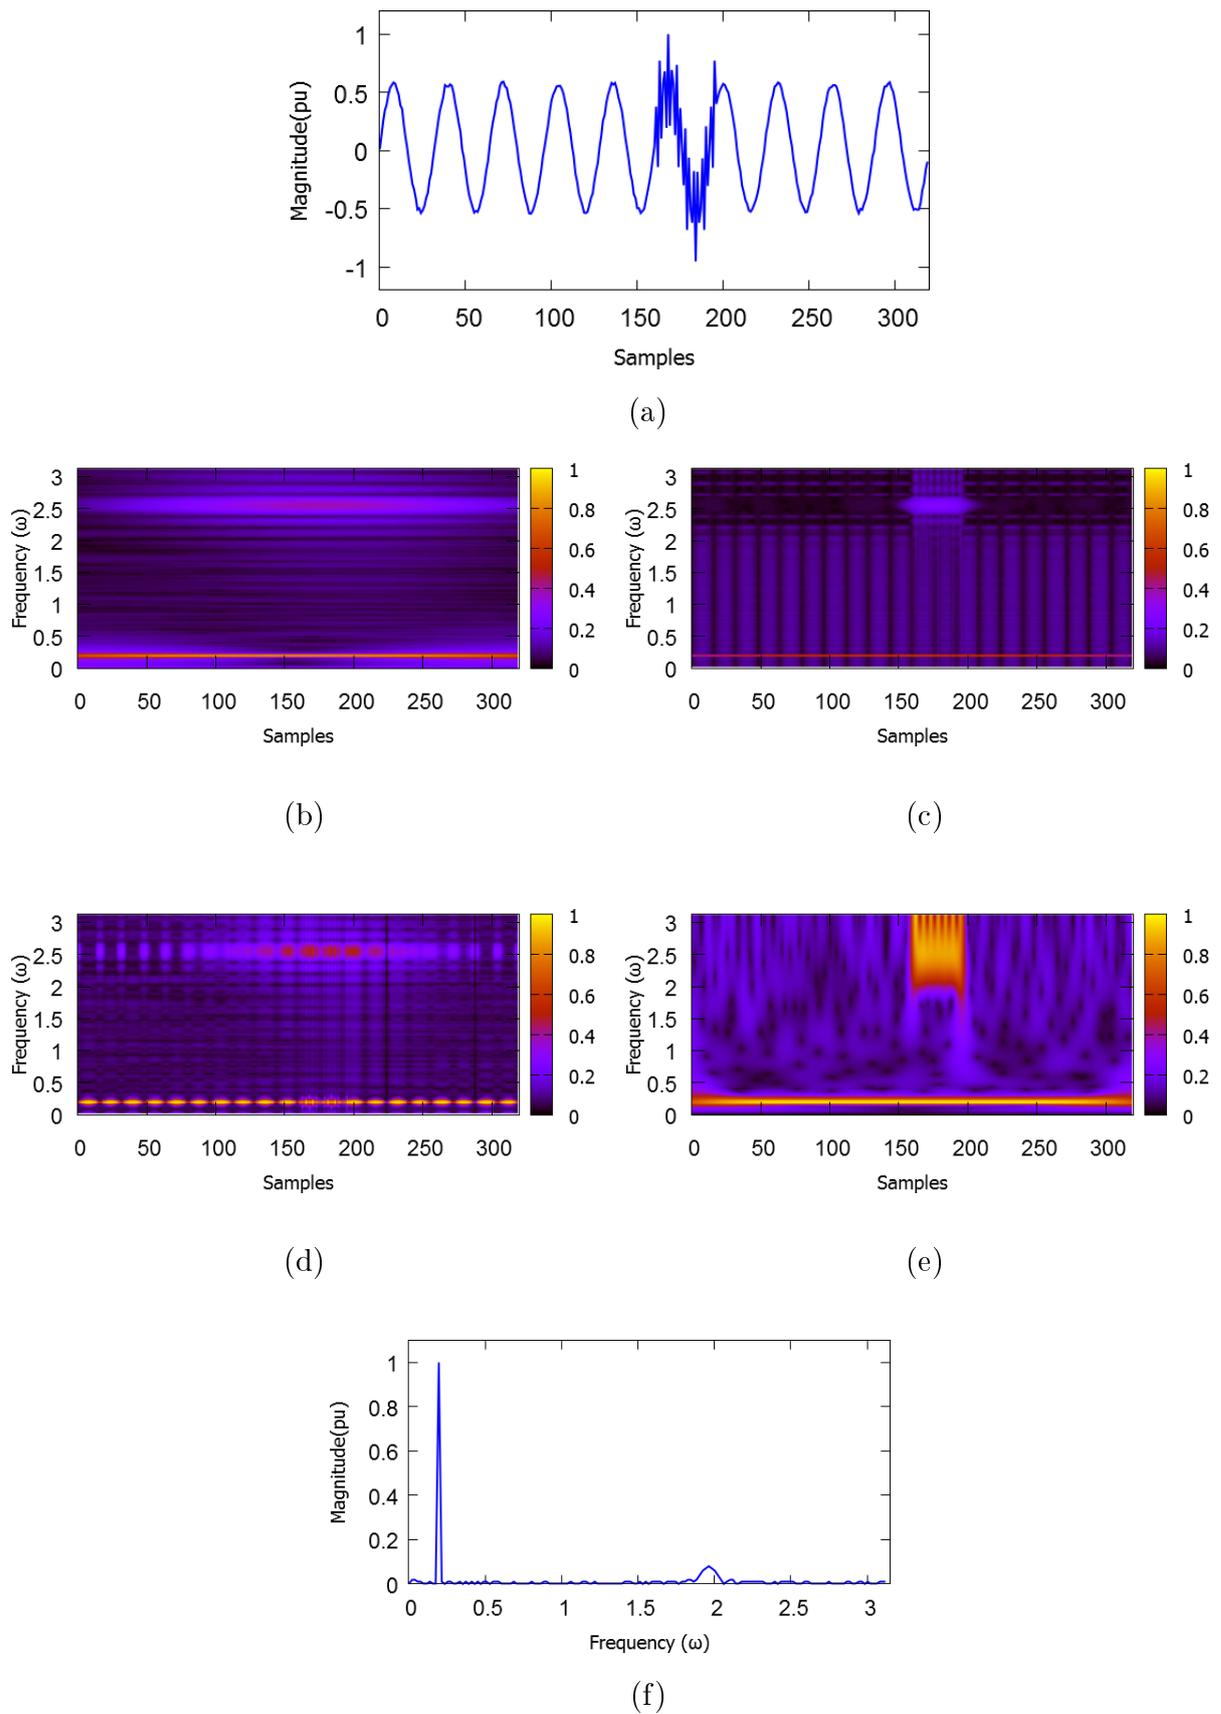


Figura B.24: (a) Sinal com ruído (20db) com distúrbio tipo *Transient*, (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT₂, (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).

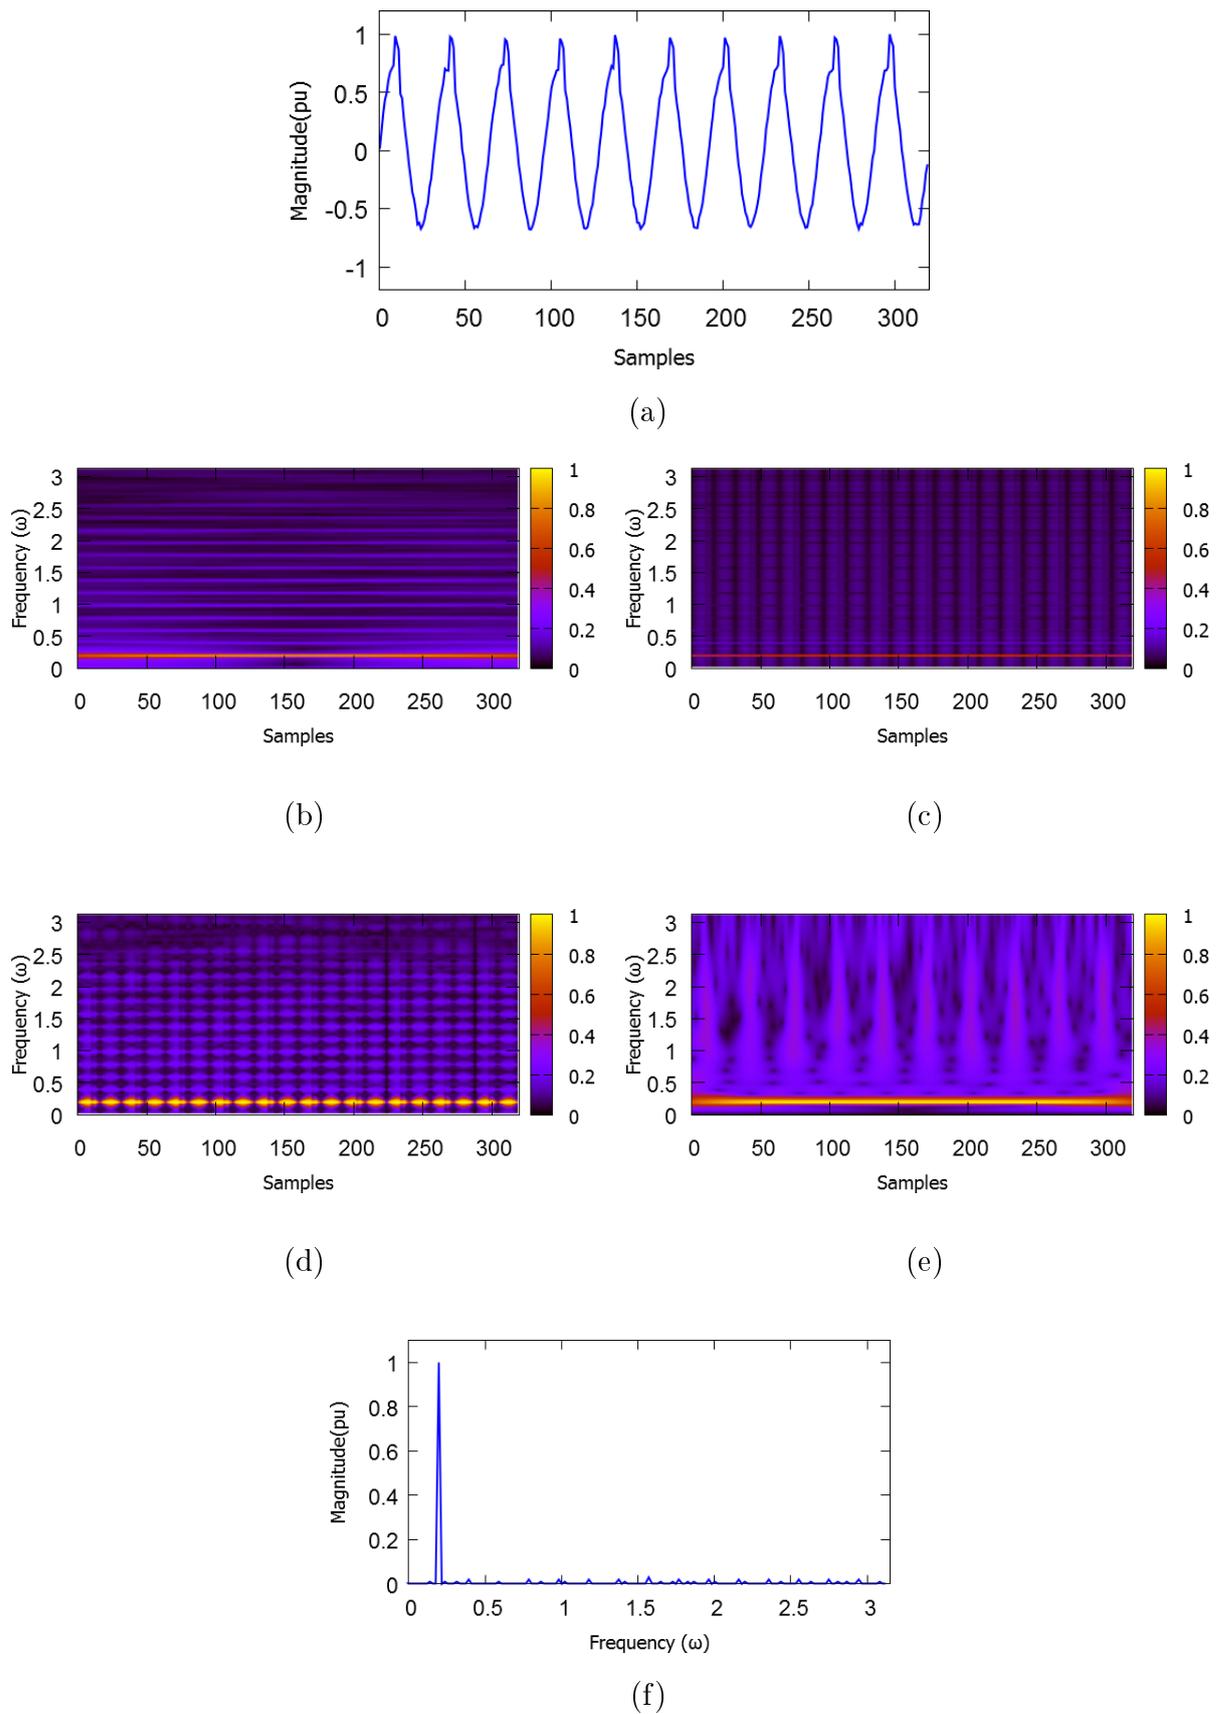


Figura B.25: (a) Sinal com ruído (20db) com distúrbio tipo *Notches*, (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT₂, (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).

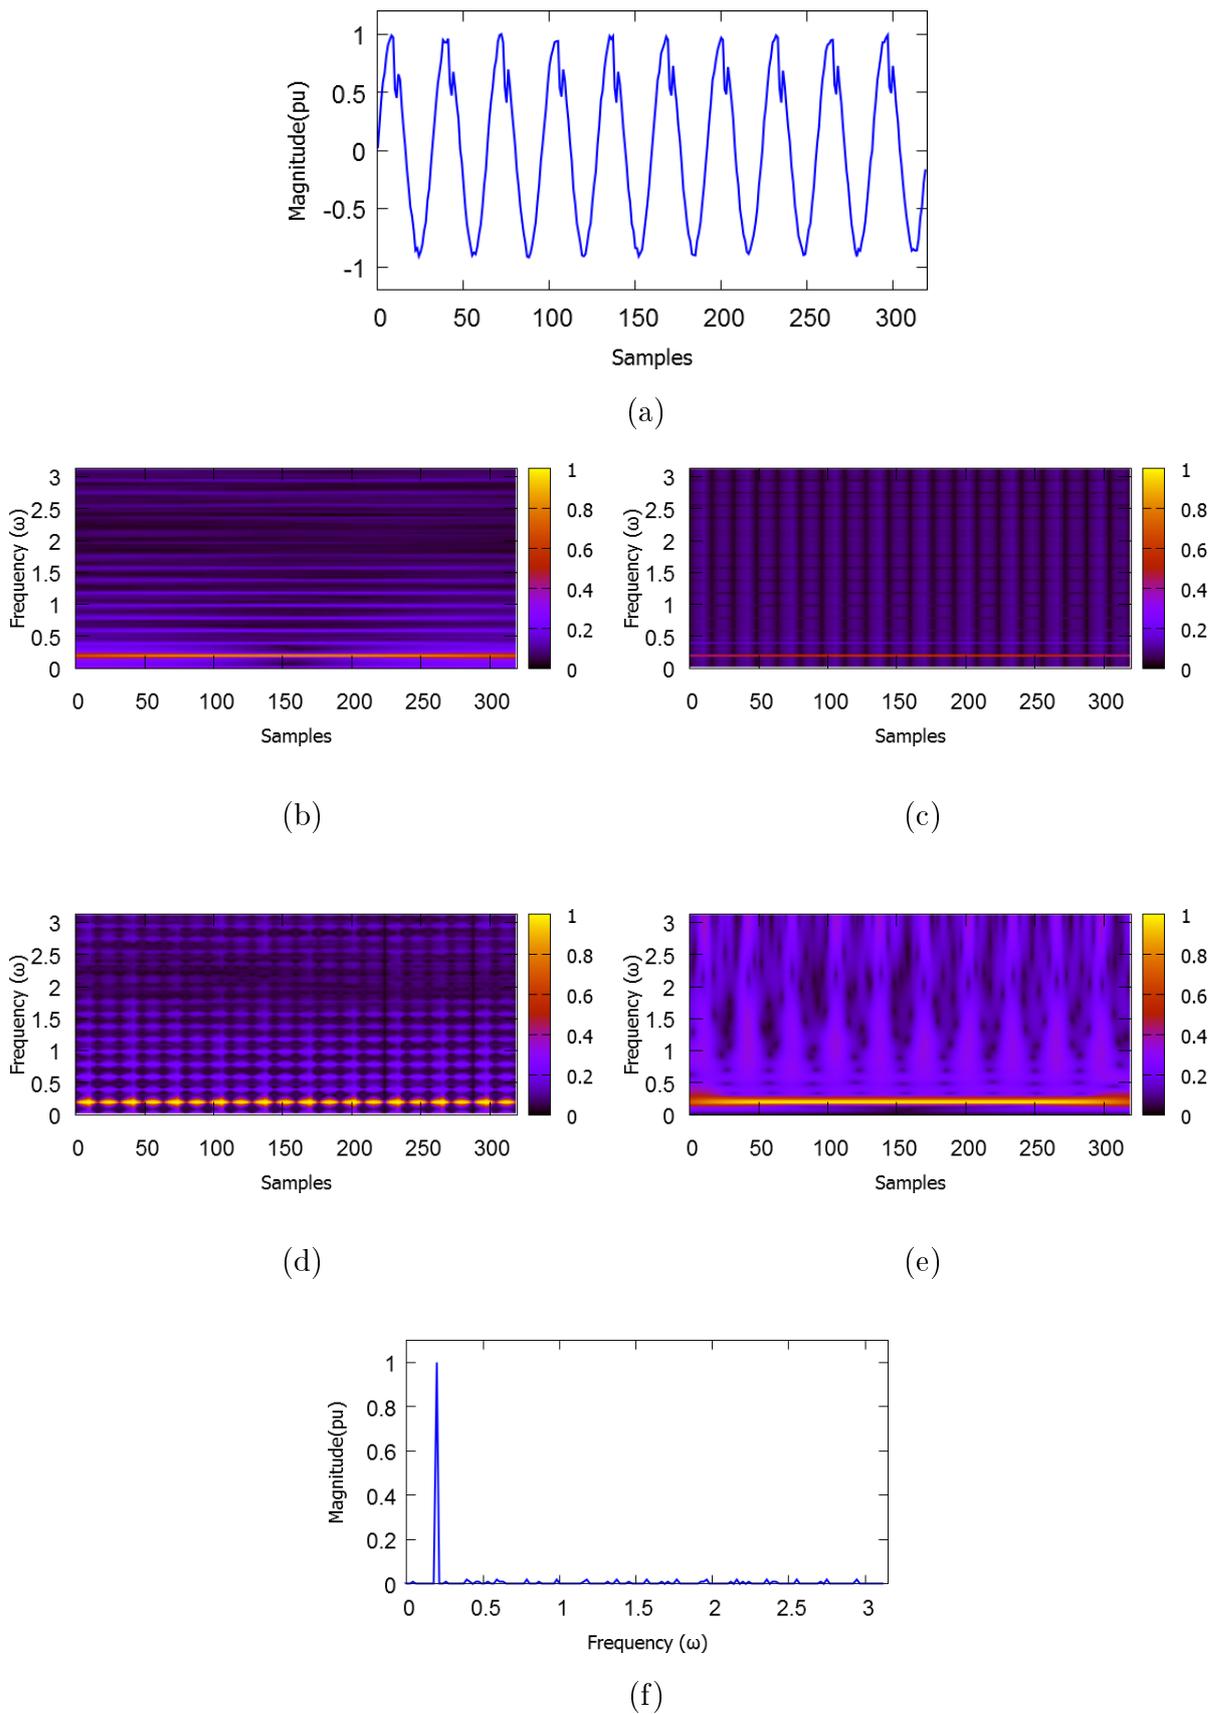


Figura B.26: (a) Sinal com ruído (20db) com distúrbio tipo *Spikes*, (b) Espectrograma GT, (c) Espectrograma STGT, (d) Espectrograma STGT₂, (e) Espectrograma ST, (f) Magnitude da Transformada de Fourier do sinal em (a).

APÊNDICE C - Modelo de simulação de um SEP

Apresentamos aqui o sistema utilizado para simular os sinais de VTCD apresentados no Capítulo 4. Utilizou-se o toolbox SimPowerSystems, do software MATLAB, com um modelo de sistema com 29 barras e rede de transmissão de 735 kV, com sete usinas de 13,8 kV (geração total disponível de 26200 MVA), incluindo turbinas hidráulicas e um parque eólico de 9 MW. O modelo detalhado, incluindo valores de estabilizadores, tipos de cargas, fluxo de potência, impedâncias, etc., pode ser consultado na Ref. [102] As Figs. C.1 a C.4 mostram uma rede de transmissão de 735 kV com modelagem detalhada de sete usinas de 13,8 kV (geração disponível total = 26200 MVA), incluindo turbinas hidráulicas, regulação de velocidade, sistemas de excitação e estabilizadores do sistema de potência. A rede de transmissão de 735 kV é composta por capacitores e indutores fixos. A carga é agrupada em dois barramentos (MTL7 e QUE7). O subsistema de carga MTL conectado ao barramento MTL7 consiste em quatro tipos de blocos de carga conectados no sistema de distribuição de 25 kV através de transformadores de 735 kV / 230 kV e 230 kV / 25 kV. O subsistema QUE tem carga de 6000 MW (constante Z e constante PQ) conectada no barramento de 120 kV. Um parque eólico de 9 MW, usando um gerador assíncrono, é conectado ao barramento de 120 kV através de um alimentador de 25 kV e um transformador de 25 kV / 120 kV.

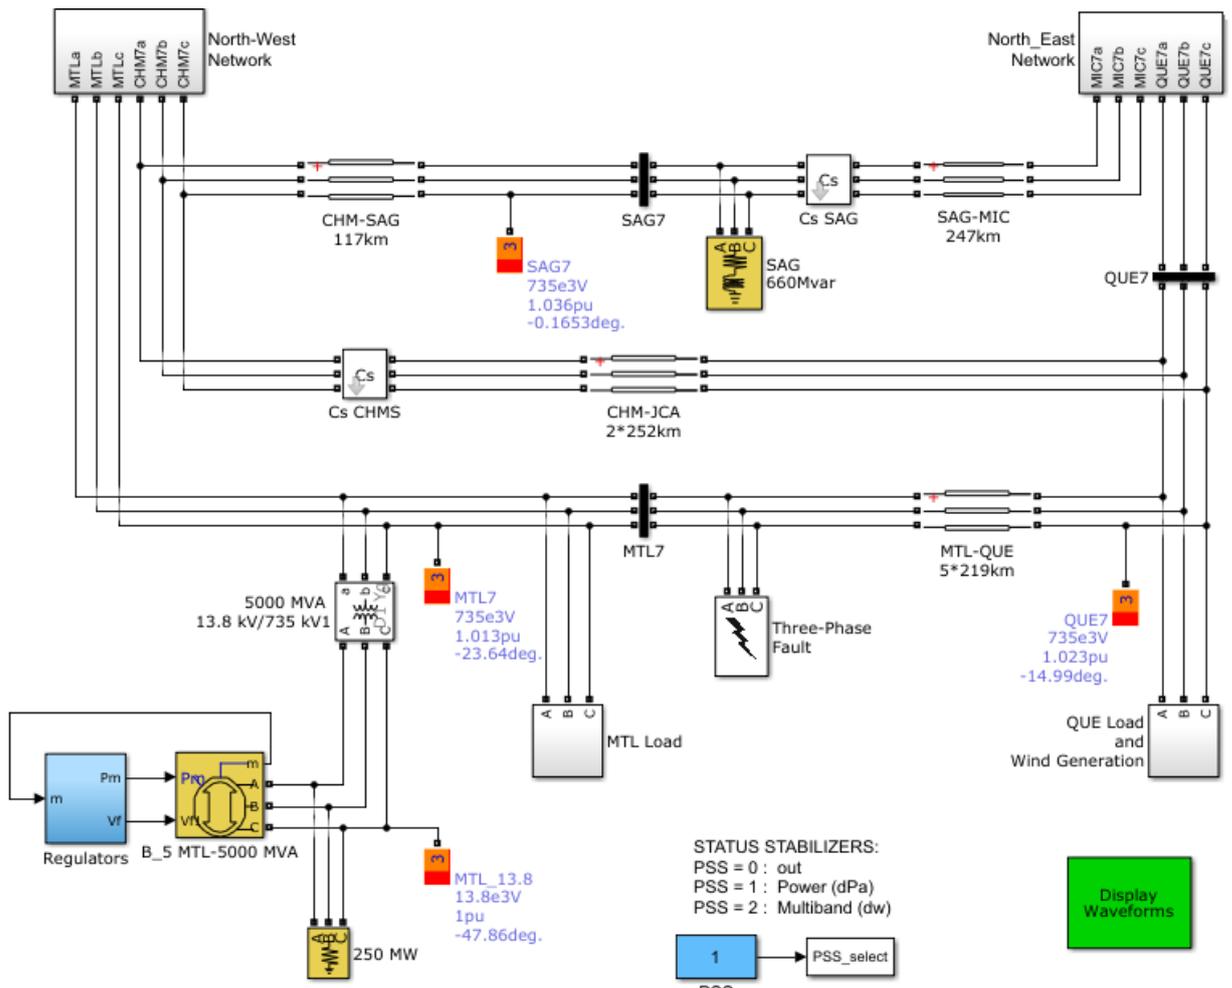


Figura C.1: Sistema de Geração Distribuída - Área 01

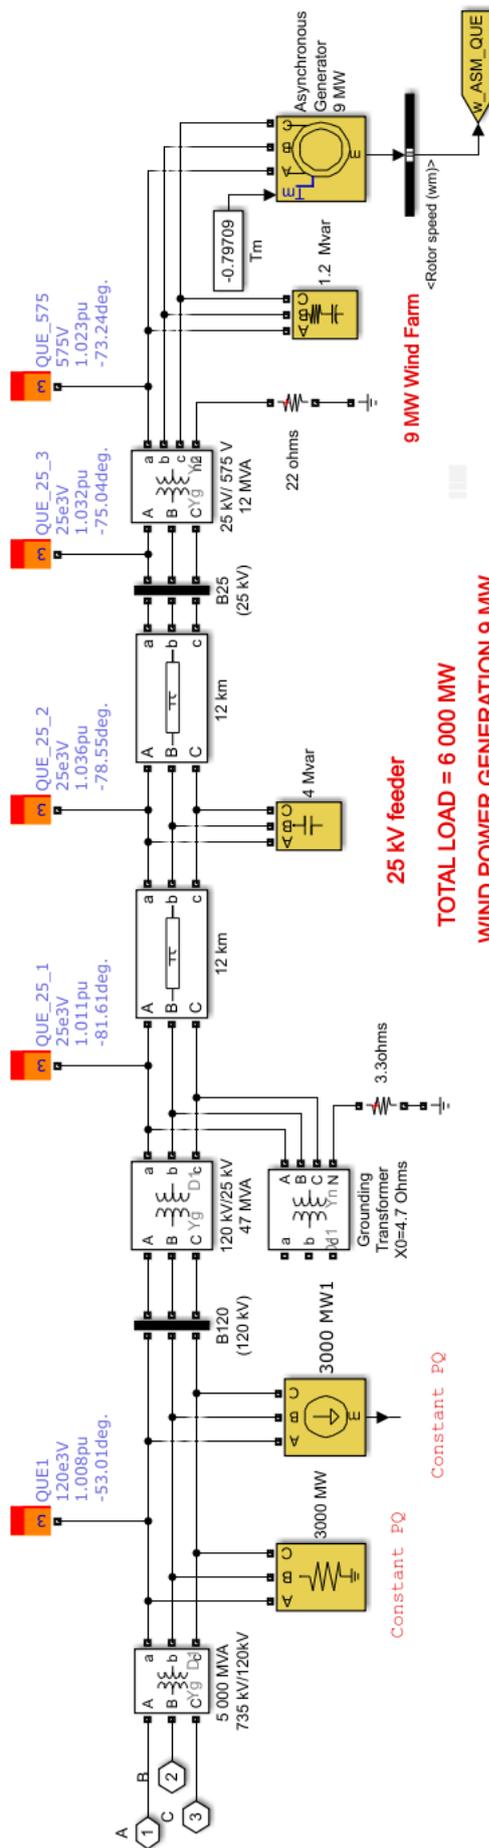


Figura C.2: Sistema de Geração Distribuída - Área 02

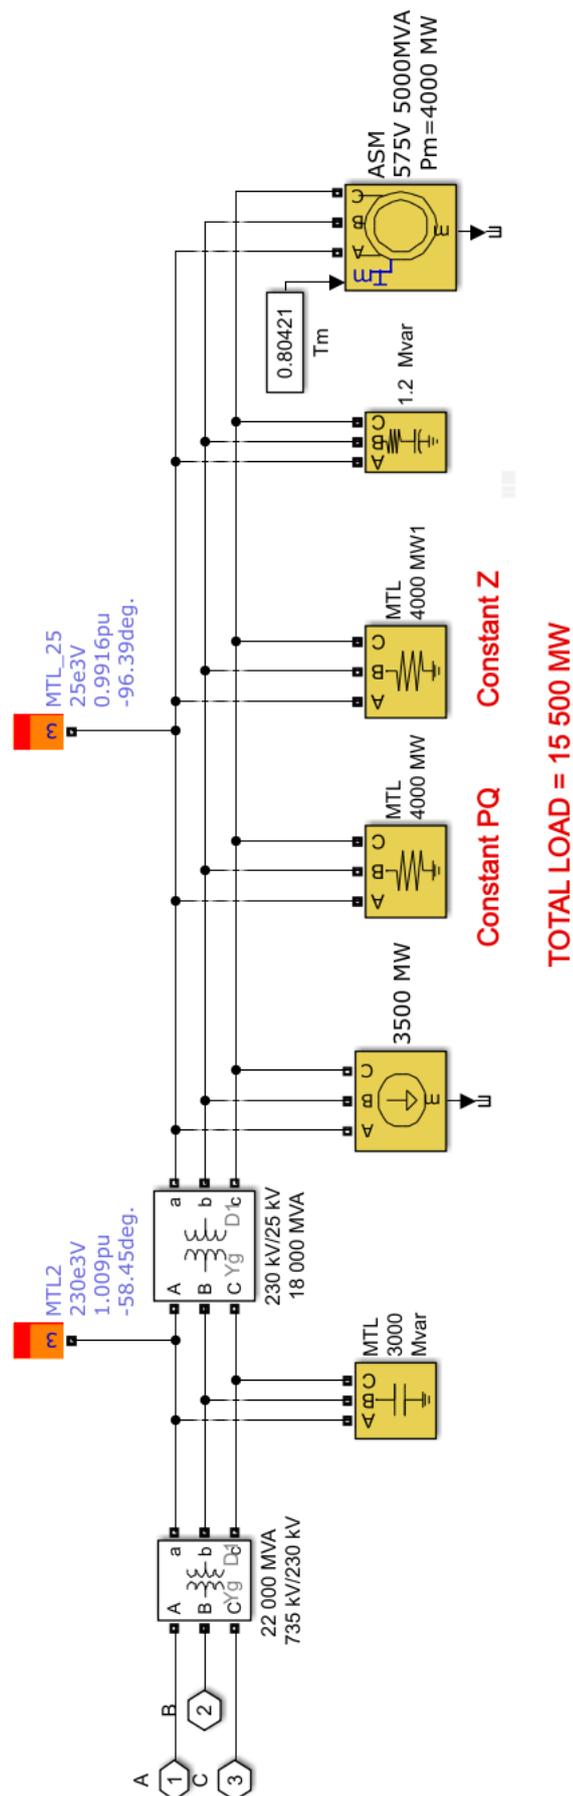
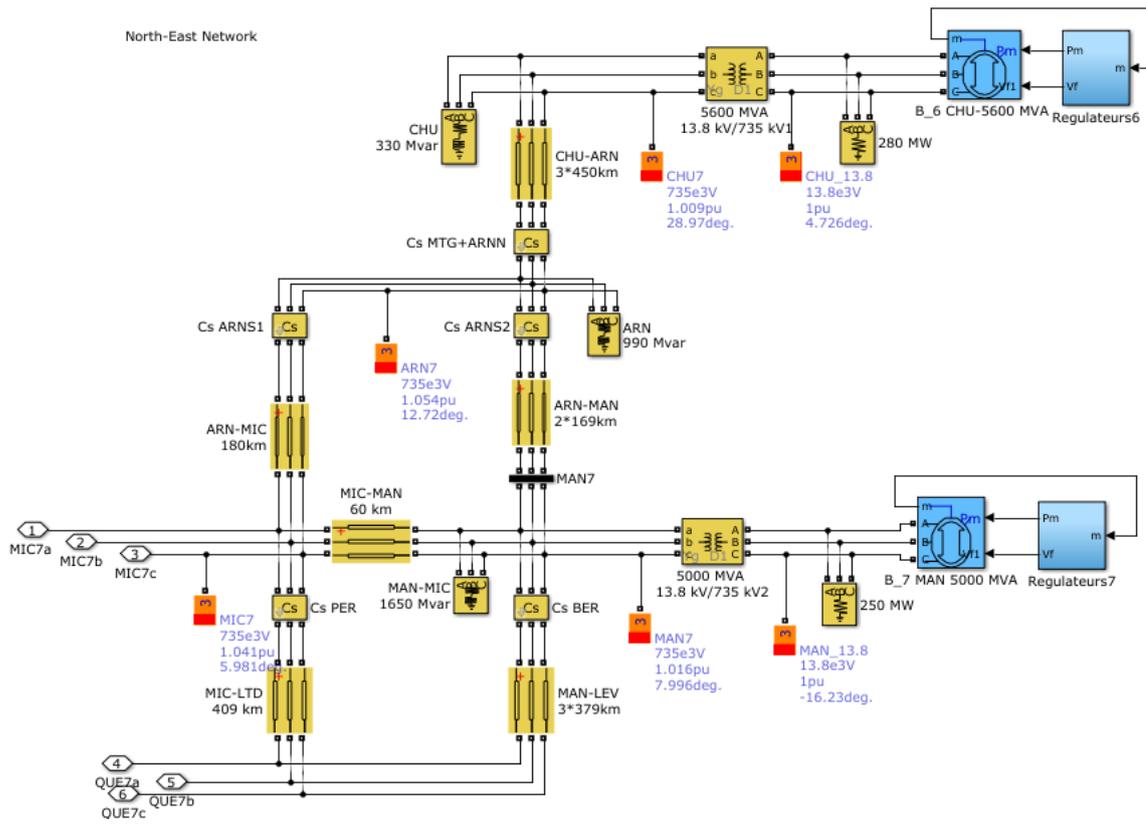


Figura C.3: Sistema de Geração Distribuída - Área 03



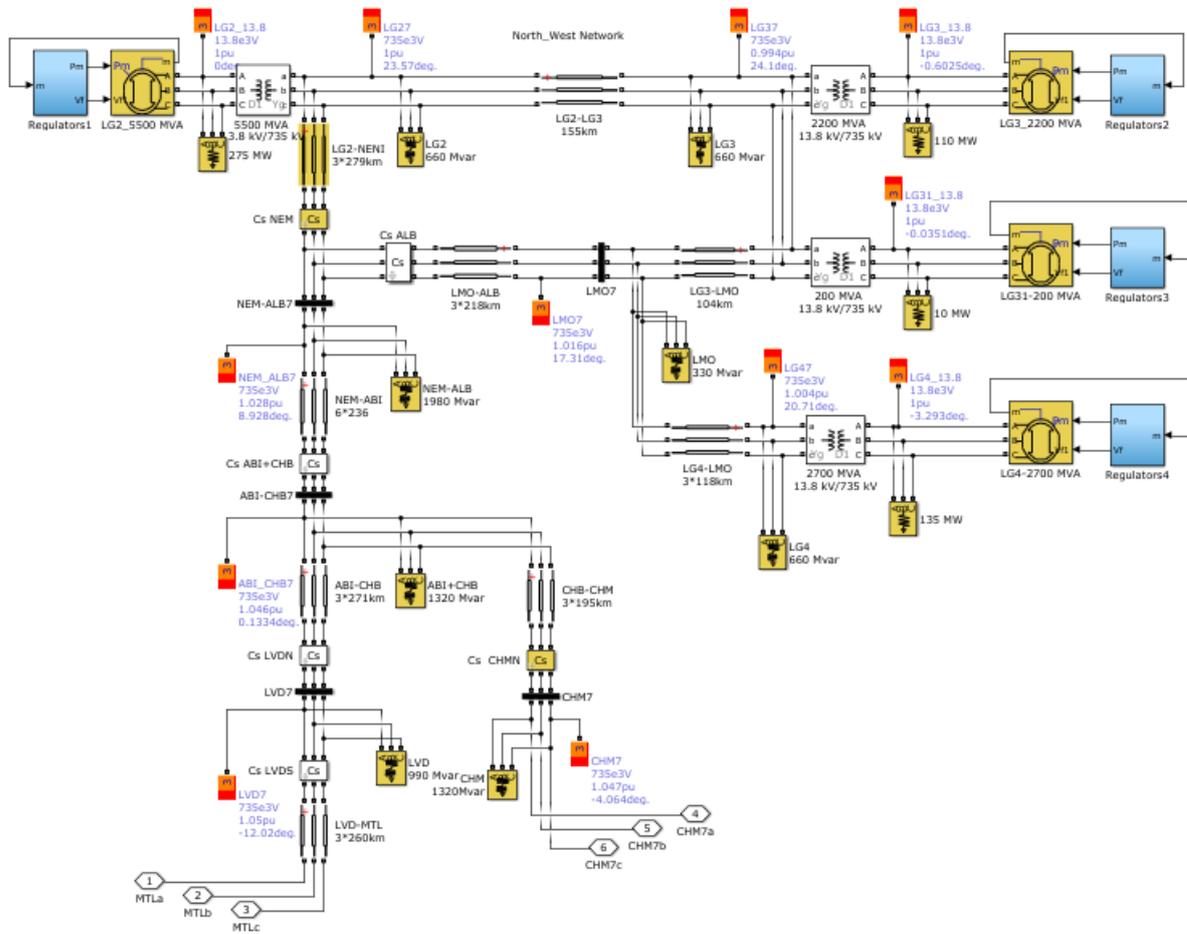


Figura C.5: Sistema de Geração Distribuída - Área 05

Referências

- [1] ABDULLAH, A. Busbar protection using a wavelet based ann. In *2017 IEEE Texas Power and Energy Conference (TPEC)* (Feb 2017), pp. 1–5.
- [2] ABDULLAH, A.; SHAAMERI, A. Detection and classification of power quality disturbances using time-frequency analysis technique. *2007. SCORED 2007*, vol. 65, no December, p. 0-5, (2007).
- [3] AFRONI, M. J.; SUTANTO, D.; STIRLING, D. Analysis of nonstationary power-quality waveforms using iterative hilbert huang transform and sax algorithm. *IEEE Trans. Power Deliv.*, vol. 28, no. 4, pp. 2134-2144, (2013).
- [4] AJAB, M. A Combination of Linear and Quadratic Time- Frequency Techniques for Time-Varying Signals by. *IEEE Xplore Digital Library* (2013).
- [5] ALMEIDA, B. The fractional Fourier transform and time-frequency representations - Signal Processing, IEEE Transactions on. *IEEE Trans. SIGNAL Process.* 42, 11 (1994), 3084–3091.
- [6] ALSHAHRANI, S.; ABBOD, M.; TAYLOR, G. Detection and classification of power quality disturbances based on hilbert-huang transform and feed forward neural networks. In *2016 51st International Universities Power Engineering Conference (UPEC)* (Sept 2016), pp. 1–6.
- [7] AMARAL, M. S. *Abordagem sintonizada de Gabor para a modelagem de neurônios do córtex visual primário*. Tese de Doutorado, Universidade Federal Fluminense - Niterói, RJ, 2017.
- [8] AMIROU, A., ET AL. Using s-transform and shannon energy for electrical disturbances detection. In *IECON 2014 - 40th Annual Conference of the IEEE Industrial Electronics Society* (Oct 2014), pp. 2452–2457.
- [9] AMIROU, A.; ZIDELMAL, Z. Stockwell-transform for electrical defaults localization. *IEEE Power Energy Soc. Gen. Meet.* (2015), pp.1–7.
- [10] AMIROU, Z.; AHMED, Z. Stockwell-transform for estimation of single-phase and three-phase power-quality indices using empirical wavelet transform. *IEEE Power Energy Soc. Gen. Meet.*, p. 7, (2015).
- [11] ANISSA, E. P., ET AL. Improvement of power quality monitoring based on modified s-transform. In *2016 Int. Semin. Intell. Technol. Its Appl.* (2016), pp. 539–544.
- [12] APETREI, V.; FILOTE, C.; GRAUR, A. Harmonic analysis based on discrete wavelet transform in electric power systems. *Ninth Int. Conf. Ecol. Veh. Renew. Energies*, pp. 1-8, (2014).

- [13] ARAVIND, M.; MATHEW, A. T. PMU data based post disturbance analysis for a large grid using wavelets and Lyapunov Exponent. In *2016 Natl. Power Syst. Conf.* (2016), pp. 1–6.
- [14] BARROS, J.; DIEGO, R. I.; DE APRAIZ, M. Applications of wavelet transforms in electric power quality: Harmonic distortion. *Appl. Meas. Power Syst. (AMPS), 2011 IEEE Int. Work.*, pp. 13-18, (2011).
- [15] BARROS, J.; DIEGO, R. I.; DE APRAIZ, M. Applications of wavelet transform for analysis of harmonic distortion in power systems: A review. *Ieee Trans. Instrum. Meas.*, vol. 61, no. 10, pp. 2604-2611 (2012).
- [16] BHUIYAN, M.; BEGUM, M.; ALAM, M. S-transform and mahalalanobis distance based approach for classifying power quality disturbances. In *2017 International Conference on Electrical, Computer and Communication Engineering (ECCE)* (Feb 2017), pp. 681–685.
- [17] BISCARO, A., ET AL. Integrated fault location and power-quality analysis in electric power distribution systems. *IEEE Trans. Power Deliv.*, vol. 31, no 2, p. 428-436, (2016).
- [18] BISWAL, B.; BISWAL, M.; RAO, M. V. N. S-transform based pattern classifier for non-stationary signals. *Proc. 2010 Annu. IEEE India Conf. Green Energy, Comput. Commun. INDICON 2010*, pp. 2-5, (2010).
- [19] BISWAL, M.; DASH, P. K. Estimation of time-varying power quality indices with an adaptive window-based fast generalised s-transform. *IET Sci. Meas. Technol.*, vol. 6, no. 4, p. 189, (2012).
- [20] BISWAL, M.; DASH, P. K. Measurement and classification of simultaneous power signal patterns with an s-transform variant and fuzzy decision tree. *IEEE Transactions on Industrial Informatics* 9, 4 (Nov 2013), 1819–1827.
- [21] BOASHASH, B. Time frequency signal analysis and processing. p. 2003.
- [22] BORGES, F., ET AL. Feature extraction and power quality disturbances classification using smart meters signals. *IEEE Transactions on Industrial Informatics* 12, 2 (April 2016), 824–833.
- [23] BORGES, F. A. *Extração de Características Combinadas com Árvore de Decisão para Detecção e Classificação dos Distúrbios de Qualidade da Energia Elétrica*. Tese de Doutorado, Universidade de São Paulo EESC/USP, 2013.
- [24] BORRAS, M. D., ET AL. Disturbance ratio for optimal multi-event classification in power distribution networks. *IEEE Trans. Ind. Electron.*, vol. 63, no 5, p. 3117-3124 (2016).
- [25] BOSNIC, J. A., ET AL. Power quality disturbance classification based on wavelet transform and support vector machine. In *2017 11th Int. Conf. Meas.* (2017), pp. 9–13.
- [26] BRACEWELL, R. N. The Fourier Transform and its Applications. In *McGraw Hill* (1965), vol. 11, p. 357.

- [27] CAI, Z.; NING, F.; LI, W.; GULLIVER, T. A. Power quality signal analysis for the smart grid using the hilbert-huang transform. *2013 IEEE Pacific Rim Conf. Commun. Comput. Signal Process.*, pp. 296-301, (2013).
- [28] CANDIDO, C. K. S. *classificacao de disturbios com ann e wavelet.pdf*. Tese de Doutorado, Universidade Federal do Rio Grande do Norte, 2008.
- [29] CASEY, R. G.; NAGY, G. Advances in Pattern Recognition. In *Sci. Am.* (1971), vol. 224, pp. 56–71.
- [30] CASSOLATO, M. T. *Classificação de data streams utilizando árvore de decisão estatística e a teoria dos fractais na análise evolutiva dos dados*. Tese de Doutorado, Universidade Federal de São Carlos, USFSCAR, São Carlos SP., 2014.
- [31] CESAR, T. M., ET AL. Wavelet transform analysis for grid-connected photovoltaic systems. In *2017 6th International Conference on Clean Electrical Power (ICCEP)* (June 2017), pp. 1–6.
- [32] CHAKRAVORTI, T.; PATNAIK, R.; DASH, P. Advanced signal processing techniques for multiclass disturbance detection and classification in microgrids. *IET Science, Measurement Technology* 11, 4 (2017), 504–515.
- [33] CHEN, V. C.; LING, H. *Time-Frequency Transforms for Radar Imaging and Signal Analysis*. Boston, London, 2002.
- [34] CHENG, B.; TITTERINGTON, D. M. Neural networks: A review from a statistical perspective. *Stat. Sci.* 9, 1 (1994), 2–30.
- [35] CHO, S. H.; JANG, G.; KWON, S. H. Time-frequency analysis of power-quality disturbances via the gabor ;wigner transform. *IEEE Trans. Power Deliv.*, vol. 25, no 1, p. 494-499, (2010).
- [36] CHUN-TAO, M.; JIAN-TONG, L. Allocation of voltage sag monitoring based on improved s-transform and exposed area. in *2015 Fifth International Conference on Instrumentation and Measurement, Computer, Communication and Control (IMCCC)*, p. 1898-1903. (2015).
- [37] CHUNLING, C.; PENGFEI, W.; TONGYU, X. Analysis of power quality transient disturbance signal based on wavelet packet transform. *2011 2nd Int. Conf. Artif. Intell. Manag. Sci. Electron. Commer.*, vol. 1, pp. 3760-3763, (2011).
- [38] CHUPAKHINA, A., ET AL. Modern mathematical methods and computerized tools of artificial intelligence for solving problems of identifying the energy quality of electrical systems. In *2017 International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON)* (Sept 2017), pp. 485–490.
- [39] COHEN, L. Time-frequency distributions-a review. *Proceedings of the IEEE* 77, 7 (1989), 941–981.
- [40] CONDON, E. Immersion of the Fourier Transform in a Continuous Group of Functional Transformations. *Proc. Natl. Acad. Sci. U. S. A.*, x (1937), 158–164.

- [41] DEKHANDJI, F. Z. Detection of power quality disturbances using discrete wavelet transform. In *2017 5th International Conference on Electrical Engineering - Boumerdes (ICEE-B)* (Oct 2017), pp. 1–5.
- [42] DEVARAJ, D.; RATHIKA, P. Discrimination of power quality disturbances using combined mathematical transforms and artificial neural network. *2008 IEEE Int. Conf. Sustain. Energy Technol.*, pp. 1134–1139, (2008).
- [43] DIVYA, S.; RAO, K. Comparative performance of different wavelets in power quality disturbance detection and quantification. in *2016 Second International Conference on Cognitive Computing and Information Processing (CCIP)*, p. 1–5. (2016).
- [44] DRUMMOND, C. F.; SUTANTO, D. Classification of power quality disturbances using the iterative hilbert huang transform. in *Proceedings of 14th International Conference on Harmonics and Quality of Power - ICHQP 2010*, p. 1–7. (2010).
- [45] DUGAN, R. C.; MCGRANAGHAN, M. F.; BEATY, H. W. Electrical power systems quality. *Electr. Power Syst. Qual.* (1996).
- [46] EGHTEADARPOUR, N.; FARJAH, E.; KHAYATIAN, A. Effective voltage flicker calculation based on multiresolution s-transform. *IEEE Transactions on Power Delivery* 27, 2 (April 2012), 521–530.
- [47] ELANGO, M. K.; LOGANATHAN, K. Classification of power quality disturbances using stockwell transform and back propagation algorithm. In *2016 International Conference on Emerging Technological Trends (ICETT)* (Oct 2016), pp. 1–7.
- [48] FENG, H., ET AL. Modulation recognition for hybrid carrier scheme based on weighted-type fractional Fourier transform. *Proc. 2011 6th Int. ICST Conf. Commun. Netw. China, CHINACOM 2011* (2011), 381–383.
- [49] FERNANDES, J.; COSTA, F.; DE MEDEIROS, R. Power transformer disturbance classification based on the wavelet transform and artificial neural networks. In *2016 International Joint Conference on Neural Networks (IJCNN)* (July 2016), pp. 640–646.
- [50] FERREIRA, J. C. Utilização da transformada de wavelet para detectar variações anormais de frequência em sistemas de geração distribuída. In *Dissertação: UFU-Universidade Federal de Uberlândia* (2009).
- [51] FERREIRA, J. C.; TORREÃO, J. R.; VICTER, S. M. Signal-tuned gabor approach for power disturbance classification. In *2016 17th International Conference on Harmonics and Quality of Power (ICHQP)* (Oct 2016), pp. 42–47.
- [52] FERREIRA, J. C.; TORREÃO, J. R.; VICTER, S. M. Signal-Tuned Gabor Application in Islanding Detection in Distributed Generation at the Power System. *XII Conferência Bras. sobre Qual. da Energ. Elétrica - CBQEE2017 unic*, 1 (2017), 2–7.
- [53] GABOR, D. Theory of communication. In *Journal of the Institution of Electrical Engineers - Part III: Radio and Communication Engineering* (1946), vol. 93, pp. 429–441.

- [54] GANYUN, L., ET AL. A novel method of complex pq disturbances classification without adequate history data. In *2016 IEEE Power and Energy Society General Meeting (PESGM)* (July 2016), pp. 1–5.
- [55] GASPARESC, G. Automatic classification of power quality events using s-transform. In *2011 10th International Conference on Environment and Electrical Engineering* (May 2011), pp. 1–4.
- [56] GRANADOS-LIEBERMAN, D., ET AL. Techniques and methodologies for power quality analysis and disturbances classification in power systems: A review. *IET Gener. Transm. Distrib.*, vol. 5, no 4, p. 519-529, (2011).
- [57] GU, X.; LO, K. Wavelet transform based fuzzy logic for power quality classification. *Univ. Power Eng. Conf. (UPEC), 2010 45th Int.* (2010).
- [58] GUO, H., ET AL. Research of transient voltage disturbance moments detection method based on discrete orthonormal s-transform. *Proc. - 2015 2nd Int. Conf. Inf. Sci. Control Eng. ICISCE 2015*, pp. 876-879, (2015).
- [59] HALL, M. F., ET AL. The weka data mining software. *SIGKDD Explor* 11, 1 (2009), 378–382.
- [60] HAN, J., ET AL. Data Mining: Concepts and Techniques. In *San Fr. CA, itd Morgan Kaufmann* (2012), p. 745.
- [61] HAYKIN, S. Neural Networks and Learning Machines. In *Pearson Prentice Hall New Jersey USA 936 pLinks* (2008), vol. 3, p. 906.
- [62] HEARST, M. A., ET AL. Trends and controversies - support vector machines. *IEEE Intell. Syst.* 13 (1998), 18–28.
- [63] HOSSAIN-MCKENZIE, S.; HAN, K.; DAVIS, K. Generator control action classification based on localized voltage measurements. in *2016 North American Power Symposium (NAPS)*, p. 1-6. (2016).
- [64] HOSSEINI, S. M.; JALILZADE, S. A new method to analyze power quality phenomena using wavelet and s-transform matrix. *IEEE/PES Power Syst.* (2013).
- [65] HU, G. Power Quality Disturbance Based on Gabor-Wigner Transform. *J. Inf. Comput. Sci.* 12, 1 (2015), 329–337.
- [66] HUANG, N.; LIN, L.; HUANG, W.; QI, J. Review of power-quality disturbance recognition using s-transform. in *Proceedings - 2009 IITA International Conference on Control, Automation and Systems Engineering, CASE 2009*, pp. 438-441. (2009).
- [67] HUANG, N.; XU, D.; LIU, X. Power quality disturbances recognition based on hs-transform. in *2010 First International Conference on Pervasive Computing, Signal Processing and Applications*, p. 311-314. (2010).
- [68] HUANG, Y., ET AL. Effective voltage flicker detection approach based on a new modified s-transform algorithm. in *The 26th Chinese Control and Decision Conference (2014 CCDC)*, pp. 4747-4752. (2014).

- [69] HUDA, N. H. T.; ABDULLAH, A. R.; JOPRI, M. H. Power quality signals detection using s-transform. *Proc. 2013 IEEE 7th Int. Power Eng. Optim. Conf. PEOCO 2013*, no. June, pp. 552-557, (2013).
- [70] HUIMIN, Q.; YUXING, D. Power quality disturbance classification using s-transform and decision tree. *Proc. - 2008 Pacific-Asia Work. Comput. Intell. Ind. Appl. PA-CIIA 2008*, vol. 2, pp. 602-606, (2008).
- [71] HUNTER, D., ET AL. Selection of proper neural network sizes and architectures x2014;a comparative study. *IEEE Transactions on Industrial Informatics* 8, 2 (May 2012), 228–240.
- [72] IEEE, T. D. C. IEEE Recommended Practice for Monitoring Electric Power Quality. In *IEEE Std 1159-2009 (Revision IEEE Std 1159-1995)* (2009), pp. c1–81.
- [73] JAIN, H.; GAWRE, S. K. Detection and classification of current interruptions and transients by using wavelet transform and neural network. *2016 Int. Conf. Electr. Power Energy Syst.*, pp. 462-468 (2016).
- [74] JETTANASEN, C., ET AL. Fault classification in transformer using low frequency component. In *2017 IEEE 10th International Workshop on Computational Intelligence and Applications (IWCIA)* (Nov 2017), pp. 199–202.
- [75] JIA, Y.; HE, Z. Y.; ZANG, T. L. S-transform based power quality indices for transient disturbances. *IEEE Xplore Digital Library* pp. 1-4, (2010).
- [76] JING, G. A new scale-frequency method for inter-harmonic detection based on continuous wavelet transform. in *2010 International Conference on Computer, Mechatronics, Control and Electronic Engineering*, vol. 5, p. 137-139. (2010).
- [77] JING, W., ET AL. The study of generalized s-transform in power quality disturbances analysis. *Asia-Pacific Power Energy Eng. Conf. APPEEC*, no. 6, pp. 2-5, (2009).
- [78] KAMTHEKAR, P.; GAUTAM, P.; MUNJE, R. Detection, characterization and classification of short duration voltage events using dwt and fuzzy logic. In *2017 International Conference on Innovative Mechanisms for Industry Applications (ICIMIA)* (Feb 2017), pp. 242–247.
- [79] KAMTHEKAR, P. R. Detection and Classification of Power Quality Events using DWT and MSD. *IEEE Xplore Digital Library*, Icimia (2017), 150–157.
- [80] KARASU, S.; BASKAN, S. Classification of power quality disturbances by using ensemble technique. in *2016 24th Signal Processing and Communication Application Conference (SIU)*, p. 529-532. (2016).
- [81] KAUR, M. Automatic Modulation Recognition for Digital Communication Signals. *IEEE Xplore Digital Library* 10, 2 (2012), 110–114.
- [82] KHAN, R.; PADHI, S. K. Non stationary signal analysis and classification using fft transform and naive bayes classifier. *2015 IEEE Power, Commun. Inf. Technol. Conf.*, no. 4, (2015).

- [83] KHOKHAR, S., ET AL. Automatic classification of single and hybrid power quality disturbances using wavelet transform and modular probabilistic neural network. *pp. 457-462*, (2015).
- [84] KHOSRAVI, M.; HAJIBAGHERIFARD, M. A.; BINA, M. T. The study of voltage sag detection by improved s-transform. *2012 3rd Power Electron. Drive Syst. Technol. PEDSTC 2012, no. 1, pp. 160-163*, (2012).
- [85] KOHAVI, R.; QUINLAN, R. Decision Tree Discovery. *Handb. Data Min. Knowl. Discov. 3*, Hunt 1962 (1999), 267—276.
- [86] KUMAR, R., ET AL. Recognition of power-quality disturbances using s-transform-based ann classifier and rule-based decision tree. *IEEE Trans. Ind. Appl., vol. 51, no 2, p. 1249-1258*, (2015).
- [87] KUMAR, R.; SINGH, B.; SHAHANI, D. Symmetrical components-based modified technique for power-quality disturbances detection and classification. *IEEE Trans. Ind. Appl., vol. 52, no 4, p. 3443-3450*, (2016).
- [88] KUMARI, K.; DADHICH, A. K.; MAHELA, O. P. Detection of power quality disturbances in the utility grid with solar energy using s-transform. In *2016 IEEE 7th Power India International Conference (PIICON)* (Nov 2016), pp. 1–6.
- [89] LI, J.; TENG, Z.; TANG, Q.; SONG, J. Detection and classification of power quality disturbances using double resolution s-transform and dag-svms. *IEEE Transactions on Instrumentation and Measurement 65*, 10 (Oct 2016), 2302–2312.
- [90] LI, K.; OTHERS. Automated classification of power quality disturbances using the s-transform. in *2008 International Conference on Wavelet Analysis and Pattern Recognition, 2008, vol. 1, no 3, p. 321-326*. (2008).
- [91] LIMA, J. A Transformada Fracional de Fourier : Conceitos e Cenários de Aplicações. *Rev. Tecnol. DA Inf. E Comun. 1* (2012).
- [92] LIMA, M., ET AL. Analysis of the influence of the window used in the short-time fourier transform for high impedance fault detection. In *2016 17th International Conference on Harmonics and Quality of Power (ICHQP)* (Oct 2016), pp. 350–355.
- [93] LIMA, M. A. A. *Uma Nova Metodologia para Análise da Qualidade da Energia Elétrica sob Condições de Ocorrência de Múltiplos Distúbios*. Tese de Doutorado, Universidade de São Paulo, 2013.
- [94] LIN, Y.; MA, C. Automatic Modulation Recognition for Digital Communication Signals. *Int. J. Futur. Gener. Commun. Netw. 10*, 2233-7857 IJFGCN (2017), 1–14.
- [95] LIU, J.; QIANG, L. A Novel Modulation Classification Algorithm Based on Daubechies5 Wavelet and Fractional Fourier Transform in Cognitive Radio. *IEEE/PES Power Syst* (2012), 2–7.
- [96] LIU, S.; SUN, Y. Study on the classification method of power disturbances based on the combination of s transform and svm multi-class classifier with binary tree. *3rd Int. Conf. Deregul. Restruct. Power Technol. DRPT 2008, no. April, pp. 2275-2280*, (2008).

- [97] MAHELA, O. P.; SHAIK, A. G. Recognition of power quality disturbances using s-transform and rule-based decision tree. In *2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)* (July 2016), pp. 1–6.
- [98] MAN, C. T.; LIANG, J. T. Allocation of voltage sag monitoring based on improved S-transform and exposed area. *Proc. - 5th Int. Conf. Instrum. Meas. Comput. Commun. Control. IMCCC 2015* (2016), 1898–1903.
- [99] MANGLIK, A.; LI, W.; AHMAD, S. U. Fault detection in power system using the Hilbert-Huang Transform. In *2016 IEEE Can. Conf. Electr. Comput. Eng.* (2016), pp. 1–4.
- [100] MARKOVSKA, M.; TASKOVSKI, D. On the choice of wavelet based features in power quality disturbances classification. In *2017 IEEE International Conference on Environment and Electrical Engineering and 2017 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I CPS Europe)* (June 2017), pp. 1–6.
- [101] MARKOVSKA, M.; TASKOVSKI, D. Optimal Wavelet Based Feature Extraction and Classification of Power Quality Disturbances Using Random Forest. *IEEE Xplore Digital Library*, July (2017), 6–8.
- [102] MATHWORKS. Simpowersystems. <http://www.mathworks.com/examples/simpower/56-initializing-a-29-bus-7-power-plant-network-with-the-load-flow-tool-of-powergui>. [Online; acessado em 15-Junho-2015].
- [103] MEHER, S. K. A novel power quality event classification using slantlet transform and fuzzy logic. in *2008 Joint International Conference on Power System Technology and IEEE Power India Conference*, p. 1-4. (2008).
- [104] MISHRA, S.; BHENDE, C.; PANIGRAHI, B. K. Detection and classification of power quality disturbances using s-transform and probabilistic neural network. *IEEE Trans. Power Deliv.*, vol. 23, no 1, p. 280-287, (2008).
- [105] MOHAMED, M. A. Identification of capacitor switching relative location using the s-transform. *2011 IEEE/PES Power Syst. Conf. Expo. PSCE 2011*, pp. 1-6, (2011).
- [106] MORAIS, J. M. *Avaliação de Desempenho de Classificadores de Faltas em Sistemas Elétricos de Potência*. Tese de Doutorado, Universidade Federal do Pará Instituto de Tecnologia Pós-graduação em Engenharia Elétrica, 2011.
- [107] MORSI, W.; EL-HAWARY, M. Time-frequency single-phase power components measurements for harmonics and inter-harmonics distortion based on wavelet packet transform; part i: Mathematical formulation. *Can. J. Electr. Comput. Eng.*, vol. 35, no 1, p. 8-14, (2010).
- [108] MORSI, W. G. Components measurements for harmonics and inter-harmonics distortion based on wavelet packet transforms. *IEEE Xplore Digital Library vol. 35, no. 1, pp. 1-7*, (2010).
- [109] MORSI, W. G.; EL-HAWARY, M. E. Time-frequency non-sinusoidal current decomposition based on the wavelet packet transform. *2007 IEEE Power Eng. Soc. Gen. Meet.*, pp. 1-8, (2007).

- [110] MORSI, W. G.; EL-HAWARY, M. E. A new perspective for the IEEE standard 1459-2000 via stationary wavelet transform in the presence of nonstationary power quality disturbance. *IEEE Trans. Power Deliv.*, vol. 23, no. 4, pp. 2356-2365, (2008).
- [111] MORSI, W. G.; EL-HAWARY, M. E. Wavelet packet transform-based power quality indices for balanced and unbalanced three-phase systems under stationary or nonstationary operating conditions. *IEEE Trans. Power Deliv.*, vol. 24, no. 4, pp. 2300-2310, (2009).
- [112] NAIK, C.; KUNDU, P. Analysis of power quality disturbances using wavelet packet transform. in *2014 IEEE 6th India International Conference on Power Electronics (IICPE)*, p. 1-4. (2014).
- [113] NAIK, C. A.; KUNDU, P. Identification of short duration power quality disturbances employing s-transform. in *2011 International Conference on Power and Energy Systems*, p. 1-5. (2011).
- [114] NAIK, C. A.; KUNDU, P. New power quality indices based on s-transform for nonstationary signals. in *2012 IEEE International Conference on Power and Energy (PECon)*, p. 677-682. (2012).
- [115] NANDI, R.; PANIGRAHI, B. K. Detection of fault in a hybrid power system using wavelet transform. pp. 203-206, (2015).
- [116] NASHAD, N., ET AL. A simplistic mathematical approach for detection and classification of power quality events. In *2017 International Conference on Electrical, Computer and Communication Engineering (ECCE)* (Feb 2017), pp. 698-703.
- [117] NICOLAE, I. Using discrete wavelet transform to evaluate power quality at highly distorted three-phase systems. vol. 2008, no. 536, (2009).
- [118] NICOLAE, I. D.; NICOLAE, P. M. Using discrete wavelet transform to evaluate power quality at highly distorted three-phase systems. in *11th International Conference on Electrical Power Quality and Utilisation*, p. 1-6. (2011).
- [119] NIGMS, N. I. O. G. M. S. Data base diagnostic ecg patient267. <http://www.physionet.org/cgi-bin/atm/ATM>. [Online; acessado em 09-Junho-2017].
- [120] OLESKOVICZ, M., ET AL. Estudo comparativo de ferramentas modernas de análise aplicadas à qualidade da energia elétrica. *Sba: Controle & Automação Sociedade Brasileira de Automatica* 17, 3 (2006), 331-341.
- [121] OMIDI, H.; SADEGHHELFRUSH, M.; DANYALI, H.; TASHK, A.; KAZEMI, K. A novel method for classification of power quality disturbances based on a new one dimensional local binary pattern approach. *IEEE Xplore Digital Library*, August (2017), 4-5.
- [122] ONAL, Y., ET AL. Detection of voltage flicker and voltage harmonic using hilbert huang transform. *16th Int. Power Electron. Motion Control Conf. Expo. PEMC*, pp. 805-810, 2014. (2014).
- [123] ORTIZ, L. S., ET AL. Analysis of the voltage event segmentation using kaiman filter and wavelet transform. *Andescon, 2010 Ieee*, vol. 2, no. 1, pp. 0-5, (2010).

- [124] OZAKTAS, H. M., ET AL. Filtering in fractional fourier domains and their relation to chirp transforms. In *Electrotechnical Conference, 1994. Proceedings., 7th Mediterranean* (Apr 1994), pp. 77–79 vol.1.
- [125] PEREIRA, S.; MORETO, M. A wavelet based tool to assist the automated analysis of waveform disturbances records in power generators. *IEEE Lat. Am. Trans., vol. 14, no 8, p. 3621-3629* (2016).
- [126] PINTO, S. J.; PANDA, G. Power quality analysis in a grid connected pv system employing a hybrid technique based on fractional wavelet transform. In *2016 IEEE Region 10 Conference (TENCON)* (Nov 2016), pp. 2925–2929.
- [127] PUTHENPURAKEL, S.; SUBADHRA, P. Identification and classification of microgrid disturbances in a hybrid distributed generation system using wavelet transform. In *2016 International Conference on Next Generation Intelligent Systems (ICNGIS)* (Sept 2016), pp. 1–5.
- [128] QIAN, S.; CHEN, D. Joint time-frequency analysis: Methods and applications. *Signal Processing, IEEE Transactions on* (1996).
- [129] RAHIM, A., ET AL. Performance Evaluation of Real Power Quality Disturbances Analysis Using S-Transform. *Appl. Mech. Mater. 752-753*, March (2015), 1343–1348.
- [130] RAJ, S.; PHANI, T. C.; DALEI, J. Power quality analysis using modified S-transform on ARM processor. *Proc. - 2016 6th Int. Symp. Embed. Comput. Syst. Des. ISED 2016* (2017), 166–170.
- [131] RAY, P., ET AL. Islanding and Power Quality Disturbance Detection in Grid-Connected Hybrid Power System Using Wavelet and -Transform. *Power, Electr. Conf. Distrib. IEEE 3, 3* (2012), 1082–1094.
- [132] RAY, P. K., ET AL. Power quality disturbance detection in grid-connected wind energy system using wavelet and s-transform. in *2010 International Conference on Power, Control and Embedded Systems, p. 1-4.* (2010).
- [133] RAY, P. K.; KISHOR, N.; MOHANTY, S. R. Islanding and power quality disturbance detection in grid-connected hybrid power system using wavelet and s-transform. *IEEE Trans. Smart Grid, vol. 3, no 3, p. 1082-1094*, (2012).
- [134] RODRÍGUEZ, A., ET AL. Time-frequency transforms comparison for power quality analysis. *IEEE Xplore Digital Library pp. 1-6*, (2008).
- [135] RODRIGUEZ, A., ET AL. Classification of power quality disturbances using s-transform and artificial neural networks. *2011 IEEE Int. Conf. Power Eng. Energy Electr. Drives, vol. 1, no. May, pp. 608-615* (2011).
- [136] RODRIGUEZ, A., ET AL. A decision tree and s-transform based approach for power quality disturbances classification. *Power Eng. Energy Electr. Drives (POWER-RENG), 4th Int. Conf., no. May, pp. 13-17, 2013.* (2013).
- [137] RUI, Z., ET AL. The application of complex wavelet transform in voltage fluctuations detection. in *Proceedings of 2011 6th International Forum on Strategic Technology, vol. 2, p. 963-966.* (2011).

- [138] SAHANI, M.; UPADHYAY, B.; BEURA, R.; MISHRA, S. Detection and classification of power quality event using wavelet transform and extreme learning machine. In *2016 International Conference on Circuit, Power and Computing Technologies (ICCPCT)* (March 2016), pp. 1–6.
- [139] SALEM, M. E.; MOHAMED, A.; SAMAD, S. A. Rule based system for power quality disturbance classification incorporating s-transform features. *Expert Systems with Applications* 37, 4 (2010), 3229 – 3235.
- [140] SALZBERG, S. L. C4.5: Programs for machine learning by j. ross quinlan. morgan kaufmann publishers, inc., 1993. *Machine Learning* 16 (1994), 235–240.
- [141] SATAO, S. R.; KANKALE, R. S. A new approach for classification of power quality events using s-transform. In *2016 International Conference on Computing Communication Control and automation (ICCUBEA)* (Aug 2016), pp. 1–4.
- [142] SAXENA, D.; SINGH, S. N.; VERMA, K. S. Analysis of composite power quality events using s-transform. *2012 IEEE Innov. Smart Grid Technol. - Asia, ISGT Asia*, pp. 1-7, 2012. (2012).
- [143] SEJDI, E.; DJUROVI, I. Time frequency feature representation using energy concentration : An overview of recent advances. *IEEE Xplore Digital Library* 19 (2009), 153–183.
- [144] SHAIK, A.; REDDY, A. S. Combined classification of power quality disturbances and power system faults. in *2016 International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT)*, p. 3796-3799. (2016).
- [145] SHAIK, S.; BABU, U. R.; SUBHANI, S. Detection and classification of power quality disturbances: Using curvelet transform and support vector machines. In *2016 International Conference on Information Communication and Embedded Systems (ICICES)* (Feb 2016), pp. 1–8.
- [146] SHARMA, A. K.; OLA, S. R. Detection of power quality disturbances using discrete wavelet transform. *IEEE Xplore Digital Library* (2016), 450–455.
- [147] SHI, Z., ET AL. The research of power quality analysis based on improved s-transform. *2009 9th Int. Conf. Electron. Meas. Instruments*, no. 4, pp. 477-481, (2009).
- [148] SHICHENG, X., ET AL. An effective s-transform feature extraction method for classification of power quality disturbance signals. in *2015 Chinese Automation Congress (CAC)*, p. 1555-1560. (2015).
- [149] SIKORSKI, T.; KOSTYLA, P. Detection of power system transients disturbances in distributed generation systems using hilbert transform and signal decomposition. *IEEE/PES Power Syst.* (2014).
- [150] SINGH, U.; SINGH, S. N. Application of fractional Fourier transform for classification of power quality disturbances. *IEEE Xplore Digital Library* (2016), 67–76.

- [151] SINGH, U.; SINGH, S. N. Detection and classification of power quality disturbances based on time-frequency-scale transform. *IET Science, Measurement Technology* 11, 6 (2017), 802–810.
- [152] SINGH, U.; SINGH, S. N. Time frequency scale transform for analysis of pq disturbances. *IET Science, Measurement Technology* 11, 3 (2017), 305–314.
- [153] STEPHANE, M. A wavelet tour of signal processing. In *A Wavelet Tour of Signal Processing (Third Edition)* (Boston, 2009), M. Stephane, Ed., Academic Press, pp. 1–805.
- [154] STOCKWELL, R. G., ET AL. Localization of the complex spectrum: the S transform. *Signal Processing, IEEE Transactions on* 44, 4 (1996), 998–1001.
- [155] SUBBARAO, M. V.; SAMUNDISWARY, P. Time-frequency analysis of non-stationary signals using frequency slice wavelet transform. *IEEE Xplore Digital Library pp. 1-6*, (2016).
- [156] SZMAJDA, M.; GÓRECKI, K.; MROCZKA, J. Gabor transform, Gabor-Wigner transform and SPWVD as a time-frequency analysis of power quality. In *ICHQP 2010 - 14th International Conference on Harmonics and Quality of Power* (2010).
- [157] TADEUSZ, Z. L.; WO, O. K. Analysis of power quality disturbances using. *Converter, vol. xx, no. January, pp. 1-4*, (2007).
- [158] TAKAHASHI, A. *Máquina de Vetores-Suporte Intervalar*. Tese de Doutorado, Universidade Federal do Rio Grande do Norte, Natal, RN, 2012.
- [159] TAO, W., ET AL. Classification of power quality disturbance signals based on s-transform and hht. in *Proceedings of the 32nd Chinese Control Conference, p. 3639-3644*. (2013).
- [160] THANGARAJ, K.; MURUGANANDHAM, J.; SELVAUMAR, S.; JAGAN, R. Analysis of harmonics using s-transform. In *2016 International Conference on Emerging Trends in Engineering, Technology and Science (ICETETS)* (Feb 2016), pp. 1–5.
- [161] THIRUMALA, K.; UMARIKAR, A. C.; JAIN, T. Estimation of single-phase and three-phase power-quality indices using empirical wavelet transform. *IEEE Transactions on Power Delivery* 30, 1 (Feb 2015), 445–454.
- [162] TORREÃO, J. R. Generalized signal-tuned gabor approach for signal representation and analysis. *Journal, Int. Physics, Mod. Sci. World Company, Publ.* 28, 1 (2017), 1–11.
- [163] TORREÃO, J. R.; VICTER, S. M.; FERNANDES, J. L. A Signal-Tuned Gabor Transform With Application To EEG Analysis. *Int. J. Mod. Phys. C* 24, 04 (2013), 1350017.
- [164] TORREÃO, J. R.; VICTER, S. M.; AMARAL, M. S. Signal-tuned gabor functions as models for stimulus-dependent cortical receptive fields. *Neural Computation* 26, 5 (2014), 920–952. PMID: 24555452.

- [165] UYA, M., ET AL. An effective wavelet-based feature extraction method for classification of power quality disturbance signals. *IEEE Xplore Digital Library vol. 78*, pp. 1747-1755, (2008).
- [166] UYAR, M.; KAYA, Y.; ATAS, M. Classification of power quality disturbances based on s-transform and image processing techniques. *in 2013 21st Signal Processing and Communications Applications Conference (SIU)*, p. 1-4. (2013).
- [167] VALENTE, W. A. G. *Reconhecimento de Padrões em Sistemas de Energia Elétrica através de uma Abordagem Geométrica Aprimorada para a Construção de Redes Neurais Artificiais*. Tese de Doutorado, Universidade Federal de Juiz de Fora, MG, 2015.
- [168] VAPNIK, V. N. The nature of statistical learning theory. In *Springer-Verlag New York, Inc.* (New York, NY, USA, 1995).
- [169] VENKATESH, C., ET AL. Detection of voltage sag/swell and harmonics using discrete s-transform. *IEEE Reg. 10 Annu. Int. Conf. Proceedings/TENCON*, no. 1, pp. 1-6, (2008).
- [170] VENKATESH, C.; SYDULU, M. Classification of voltage sag, swell and harmonics using s-transform based modular neural network. *IEEE Power Systems no. 1*, pp. 1-7. (2010).
- [171] VICTER, S. M. C. *Funções de Gabor Sintonizadas: Aplicação à Análise e à Síntese de Sinais*. Tese de Doutorado, Universidade Federal Fluminense - Niterói, RJ, 2012.
- [172] VICTER, S. M. C.; FERREIRA, J. C.; TORREÃO, J. R. A. Signal-tuned spectral gabor transform as a tool for power quality monitoring. In *2018 18th International Conference on Harmonics and Quality of Power (ICHQP)* (May 2018), pp. 1-6.
- [173] VYAS, S.; KUMAR, R.; KAVASSERI, R. Statistical identification and classification of potential islanding precursors in a grid-connected solar photo voltaic system. In *2016 IEEE 6th International Conference on Power Systems (ICPS)* (March 2016), pp. 1-6.
- [174] WAIKATO, U. Weka 3.6 Machine Learning Software in Java. <http://www.cs.waikato.ac.nz/ml/weka>. [Online; acessado em 30-Setembro-2016].
- [175] WANG, J.; SHEN, Y.; WENG, G. Study on the classification method of power quality disturbances based on generalized s-transform and dmt svms classifier. *in 2009 International Conference on Sustainable Power Generation and Supply*, p. 1-4. (2009).
- [176] WANG, S. A comprehensive survey on fractional fourier transform. *IEEE Xplore Digital Library*, October (2017), 0-48.
- [177] WEI, D., ET AL. Time frequency analysis method based on affine Fourier transform and Gabor transform. *IET Signal Process.* 11, 2 (2017), 213-220.
- [178] WENG, J. Study on the classification method of power quality disturbances based on generalized s-transform and dmt svms classifier. *IEEE Trans. Power Syst.*, pp. 1-4, (2010).

- [179] WESTON, J.; HERBRICH, R. Adaptive Margin Support Vector Machines. In *Adv. Large Margin Classif.* (Cambridge, MA, 1999), M. I. of Technology, Ed., pp. 281–296.
- [180] WIGNER, E. On the quantum correction for thermodynamic equilibrium. *Physical Review* 40, 5 (1932), 749–759.
- [181] XIAO, X., ET AL. Sdpq classification based on maximum similarity principle of s-transform mtfm. in *APCCAS 2008 - 2008 IEEE Asia Pacific Conference on Circuits and Systems*, p. 1880-1883. (2008).
- [182] XIAO, X.; XU, F.; YANG, H. Short duration disturbance classifying based on s-transform maximum similarity. *Electrical Power and Energy Systems*. 31 (2009), 374–378.
- [183] XU, F., ET AL. Classification for voltage sags based on similarity of generalized s-transform modulus matrixes. In *2012 IEEE 15th International Conference on Harmonics and Quality of Power* (June 2012), pp. 288–292.
- [184] XU, F.; WANG, Y.; YANG, H. Voltage sags detection based on fundamental frequency vector of generalized s-transform modulus matrixes. in *2012 9th International Conference on Fuzzy Systems and Knowledge Discovery*, p. 2019-2022. (2012).
- [185] YALCIN, T.; OZDEMIR, M. Pattern recognition method for identifying smart grid power quality disturbance. In *2016 17th International Conference on Harmonics and Quality of Power (ICHQP)* (Oct 2016), pp. 903–907.
- [186] YANG, L., ET AL. Disturbance source identification of voltage sags based on hilbert-huang transform. in *2010 Asia-Pacific Power and Energy Engineering Conference*, p. 1-4. (2010).
- [187] YANG, M., ET AL. S-Transform and Scale Zooming Based Classification for Short Duration Power Quality Disturbance According to Partial Similarity. In *2010 Asia-Pacific Power Energy Eng. Conf.* (2010), pp. 1–7.
- [188] YANG, X., ET AL. Sdpq classification based on maximum similarity principle of s-transform mtfm. *IEEE Xplore Digital Library pp. 1880-1883*, (2008).
- [189] YAO, W., ET AL. Fast s-transform for time-varying voltage. *IEEE/PES Power Syst. vol. 63, no. 1, pp. 72-79, 2014.* (2014).
- [190] YI, J.; PENG, J. Power quality disturbances denoising using modified s-transform. *2009 Int. Conf. Sustain. Power Gener. Supply, no. 50677015, pp. 1-5*, (2009).
- [191] YONG-HONG, H., ET AL. Effective voltage flicker detection approach based on a new modified s-transform algorithm. *IEEE/PES Power Syst. pp. 4747-4752*, (2014).
- [192] YU, J.; LAI, Y. Disturbance source identification of voltage sags. *IEEE Xplore Digital Library vol. 0, pp. 2-5*, (2010).

-
- [193] ZHANG, P., ET AL. Power measurement under time-varying waveform using discrete wavelet packet transform. In *2011 IEEE Power Engineering and Automation Conference* (Sept 2011), vol. 3, pp. 345–348.
- [194] ZHANG, R., ET AL. The classification and recognition of power quality disturbance based on s transform. *Proc. 2012 Int. Conf. Meas. Inf. Control. MIC 2012, vol. 2, no. Mic, pp. 663-667* (2012).
- [195] ZHAO, L.; LIU, X.; FU, G. Identification of power quality disturbances based on improved tt transform and support vector classifier. In *2016 IEEE 8th International Power Electronics and Motion Control Conference (IPEMC-ECCE Asia)* (May 2016), pp. 416–420.
- [196] ZHAO, Y.; XU, Y.; XIAO, X.; ZHU, Y.; GUO, C. Power quality disturbances identification based on dq conversion, wavelet transform and fft. *Asia-Pacific Power Energy Eng. Conf. APPEEC, pp. 5-8*, (2010).