

Universidade de São Paulo
Escola de Engenharia de São Carlos

Katia Cristina Silva Paulo

Identificação de Padrões de Sinais Acústicos com Base
em Classificação Paraconsistente

São Carlos - SP

2016

Katia Cristina Silva Paulo

Identificação de Padrões de Sinais Acústicos
com Base em Classificação Paraconsistente

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia de São Carlos da Universidade de São Paulo para obtenção do título de Doutor em Ciências.

Área de concentração: Sistemas Dinâmicos.

Orientador: Prof. Dr. Ivan Nunes da Silva.

Coorientador: Prof. Dr. Rodrigo Capobianco Guido.

São Carlos - SP

2016

AUTORIZO A DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE

Ficha catalográfica elaborada pelo Serviço de Biblioteca e Informação EESC/USP

Paulo, Katia Cristina Silva.

Identificação de Padrões de Sinais Acústicos com Base em Classificação Parconsistente. / Katia Cristina Silva Paulo;

Orientador: Ivan Nunes da Silva – São Carlos, 2016.

Coorientador: Rodrigo Capobianco Guido – São Carlos, 2016.

Tese (Doutorado - Programa de Pós-Graduação em Engenharia Elétrica - Área de Concentração: Sistemas Dinâmicos - Opção Automação Inteligente de Processos e Sistemas) -

Escola de Engenharia de São Carlos da Universidade de São Paulo.

FOLHA DE JULGAMENTO

Candidata: Bacharel **KATIA CRISTINA SILVA PAULO**.

Título da tese: "Identificação de padrões de sinais acústicos com base em classificação paraconsistente".

Data da defesa: 20/09/2016.

Comissão Julgadora:

Resultado:

Prof. Associado **Ivan Nunes da Silva (Orientador)**
(Escola de Engenharia de São Carlos/EESC)

APROVADA

Prof. Dr. **André Sanches Fonseca Sobrinho**
(Universidade Tecnológica Federal do Paraná/UTFPR)

APROVADA

Prof. Associado **Rogério Andrade Flauzino**
(Escola de Engenharia de São Carlos/EESC)

Aprovado

Profa. Titular **Agma Juci Machado Traina**
(Instituto de Ciências Matemáticas e de Computação/ICMC)

APROVADA

Profa. Dra. **Anna Diva Plasencia Lotufo**
(Universidade Estadual Paulista "Júlio de Mesquita Filho"/UNESP – Ilha Solteira)

APROVADA

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica:
Prof. Associado **Luis Fernando Costa Alberto**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Luis Fernando Costa Alberto**

Dedico a presente tese aos meus pais Ademir e Nely, ao meu marido Eduardo, meus filhos Miguel e Leonardo e familiares.

Agradecimentos

Primeiramente, gostaria de agradecer a Deus por me guiar, iluminar e me dar oportunidades de alcançar meus objetivos e não desanimar com as dificuldades.

À minha mãe Nely por todo apoio e dedicação de avó nos momentos que eu mais precisava, estava sempre pronta para cuidar de seus netos. Ao meu pai Ademir, que foi quem me incentivou em realizar esse trabalho, dizendo que era um orgulho para ele, quase uma cobrança de pai, fico muito feliz em poder apresentar esse título de doutora ao senhor, pois eu nunca me esqueci de suas palavras. Obrigada por todo o esforço de vocês para minha formação.

Ao meu marido Eduardo pela compreensão e apoio nos momentos difíceis e que é a pessoa que a vida escolheu para ser meu companheiro, amo você. Aos meus filhos Miguel e Leonardo que são as minhas maiores riquezas, benção de Deus.

À minha irmã Claudia, sobrinhas e famílias que estavam sempre presentes, torcendo e orando por mim em cada momento, principalmente nos momentos de avaliações.

À minha amiga Regiane, minha irmã de coração a qual estava sempre pronta a me ajudar, minha companheira de viagens para USP, de realizações das disciplinas e avaliações, momentos esses que ficarão gravados para sempre em minha vida. Ao meu amigo André por me ajudar nas horas mais difíceis, me mostrando que há sempre uma saída mais fácil e simples para seguir, admiro muito você.

Ao meu amigo Tony, pelo seu conhecimento e profissionalismo, por me fornecer o banco de músicas, separadas por gêneros musicais, para que eu pudesse realizar todos os testes desse trabalho.

E principalmente ao meu orientador Professor Ivan que me aceitou como orientada e aluna, acreditando em meu trabalho e por toda experiência que me proporcionou durante esse tempo. E meu coorientador, Professor Rodrigo que não tenho palavras para agradecer, estando presente todo esse tempo, nunca me abandonou, estando também sempre pronto a me atender e ajudar e que me ensinou muito. Obrigada Rodrigo, se Deus te proporcionar a metade do que faz por nós, alunos e orientados, pode ter a certeza que vai ser feliz pelo resto de sua vida.

“Quanto mais as pessoas acreditam em uma coisa, quanto mais se dedicam a ela, mais podem influenciar no seu acontecimento”

Dov Éden.

Resumo

PAULO, K.C.S *Identificação de Padrões de Sinais Acústicos com Base em Classificação Paraconsistente*. 2016. Tese (Doutorado em Ciências) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016.

Com o uso de um conceito ainda não explorado para fins de classificação de dados, baseado em Lógica Paraconsistente Anotada (LPA), este trabalho visa à construção de um sistema inteligente para classificação de gêneros musicais (*Music Genre Classification* - MGC). Este tema, de caráter emergente na literatura, tem recebido atenção crescente da comunidade científica, tendo em vista a sua grande aplicabilidade, destacando-se o potencial de comercialização de dados multimídia pela Internet, assim como a automatização de inúmeras tarefas de *data mining* que envolvem sinais musicais. Utilizando uma base de dados composta por amostras de músicas representativas de cada gênero musical, tais como jazz, bolero, bossa nova, forró, salsa e sertanejo, assim como de um classificador discriminativo paraconsistente, uma abordagem supervisionada é proposta para solucionar o problema. O primeiro módulo do sistema realiza a extração de características dos diversos segmentos das músicas com base na análise tempo-frequência associada com as bandas críticas do ouvido humano. Por outro lado, o segundo módulo utiliza o classificador proposto, que deve permitir a manipulação de sinais com características contraditórias de uma maneira mais semelhante àquela realizada pelo cérebro humano. Os resultados, quando comparados com as abordagens pré-existentes para MGC, demonstram a viabilidade do uso da LPA para tal fim. Além disso, caracteriza-se neste trabalho, uma contribuição original ao estado-da-arte no tema, que consiste justamente no uso da LPA para MGC, procedimento para o qual inexistente descrição na literatura até este momento.

Palavras-chave: Classificação automática de gênero musical. Inteligência artificial. Máquina Paraconsistente Discriminativa (DPM). Lógica Paraconsistente.

Abstract

PAULO, K.C.S. *Identification of Acoustic Signal Patterns based on Paraconsistent Classification*. 2016. Tese (Doutorado em Ciências) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016.

By using a new concept, which is based on Paraconsistent Logic (LPA) and has not yet been applied for classification, this work aims at constructing an intelligent system for Music Genre Classification (MGC). This topic, that is emergent in the literature, has received an increasing attention from the scientific community due to its applicability, emphasizing both a commercial potential to commercialize multimedia content on the Internet and data mining tasks involving music signals. By adopting a database formed by samples of songs, which represent different styles of music, such as jazz, bolero, bossa nova, forró, salsa and sertanejo, and a discriminative paraconsistent classifier, a supervised procedure is used to solve the problem. The system is divided in two modules. The first extracts features from the music files, based on the concepts of time-frequency analysis and critical bands of the human ear. On the other hand, the second implements the proposed classifier, which allows an efficient treatment of contradictions in such a way that is more similar to the human brain. The results obtained, when compared with existing approaches used to MGC, demonstrate how LPA is suitable for this purpose. Additionally, this is the original contribution to the state-of-the-art: the use of LPA for MGC, an inexistent approach up to date.

Key-words: Automatic music genre classification. Artificial intelligence. Discriminative Paraconsistent Machine (DPM). Paraconsistent Logic.

Lista de Figuras

2.1	Demonstração de um sistema básico de análise paraconsistente.	34
2.2	O plano paraconsistente, de acordo com Huhn [4].	35
2.3	Estrutura DPM (extraída de [1]).	38
2.4	DPM de saída para o experimento com o vetor de entrada $\{1, 0, 1\}$. O círculo (\circ) , representando a localidade do ponto $[G_1, G_2]$, é exatamente em $[0, 1]$	46
2.5	DPM de saída para o experimento com o vetor de entrada $\{3, 3, 3\}$. O círculo (\circ) representa a localidade do ponto $[G_1, G_2]$, ou seja, $[0, -0, 589446]$	46
2.6	DPM de saída para o experimento com o vetor de entrada $\{2, 2, 4\}$. O círculo (\circ) representa a localidade do ponto $[G_1, G_2]$, ou seja, $[0, 960, 0, 034]$	47
2.7	DPM de saída para o experimento com o vetor de entrada $\{2, 2, 0\}$. O círculo (\circ) representa a localidade do ponto $[G_1, G_2]$, ou seja, $[-0, 960, 0, 034]$	47
3.1	Representação esquemática do processo de classificação: arquitetura elementar do sistema proposto.	54
4.1	DPM_bolero (Tabela 4.1).	63
4.2	DPM_bossa nova (Tabela 4.2).	64
4.3	DPM_forró (Tabela 4.3).	64
4.4	DPM_jazz (Tabela 4.4).	65
4.5	DPM_salsa (Tabela 4.5).	66
4.6	DPM_sertanejo (Tabela 4.6).	66

Lista de Tabelas

2.1	<i>Chunk 1</i> do formato WAV: componentes e descrições dos 12 bytes integrantes (adaptado de [28]).	48
2.2	<i>Chunk 2</i> do formato WAV: componentes e descrições dos 24 bytes integrantes (adaptado de [28]).	49
2.3	<i>Chunk</i> de dados do formato WAV: componentes e descrições dos bytes integrantes (adaptado de [28]).	49
2.4	Escala <i>Bark</i>	52
4.1	<i>Resultados utilizando 802 parâmetros, 10% da base para treinamento e 90% para testes no reconhecimento da músicas do estilo bolero.</i>	62
4.2	<i>Resultados utilizando 802 parâmetros, 10% da base para treinamento e 90% para testes no reconhecimento da músicas do estilo bossa nova.</i>	63
4.3	<i>Resultados utilizando 802 parâmetros, 10% da base para treinamento e 90% para testes no reconhecimento da músicas do estilo forró.</i>	63
4.4	<i>Resultados utilizando 802 parâmetros, 10% da base para treinamento e 90% para testes no reconhecimento da músicas do estilo jazz.</i>	63
4.5	<i>Resultados utilizando 802 parâmetros, 10% da base para treinamento e 90% para testes no reconhecimento da músicas do estilo salsa.</i>	65
4.6	<i>Resultados utilizando 802 parâmetros, 10% da base para treinamento e 90% para testes no reconhecimento da músicas do estilo sertanejo.</i>	65

Lista de Abreviaturas

MGC	<i>Music Genre Classification</i>
DPM	<i>Discriminative Paraconsistent Machine</i>
RNA	Redes Neurais Artificiais
IFSC/USP	Instituto de Física de São Carlos
EESC/USP	Engenharia Elétrica de São Carlos
MFCC	<i>Mel-Frequency Cepstral Coefficients</i>
GMM	<i>Gaussian Mixture Models</i>
KNN	<i>K-Nearest Neighbors</i>
GLM	<i>Generalized Linear Model</i>
LP	Lógica Paraconsistente
LPA	Lógica Paraconsistente Anotada
HMM	<i>Hidden Markov Models</i>
ADC	<i>Analog-to-digital convertors</i>
DAC	<i>Digital-to-analog convertor</i>
SVM	<i>Support Vector Machines</i>
PU	Unidade Passiva
POU	Unidade de saída paraconsistente
DSP	Processamento de sinal digital

Sumário

1	Introdução	23
1.1	Objetivos e Contribuição	24
1.2	Disposição do Trabalho	25
2	Revisão Bibliográfica	27
2.1	Lógica Paraconsistente	29
2.1.1	Aplicação da Lógica Paraconsistente Anotada	31
2.1.2	Lógica Paraconsistente Anotada - LPA 1v	33
2.1.3	Lógica Paraconsistente Anotada - LPA 2v	34
2.2	Pesquisas em desenvolvimento pela LPA e a <i>Discriminative Paraconsistente Machine</i> (DPM)	36
2.3	A DPM e sua arquitetura	37
2.3.1	Camada inicial	37
2.3.2	Camada discriminativa	38
2.3.3	Camada de mistura	39
2.3.4	Camada final	41
2.3.5	Exemplo numérico de uma DPM	42
2.4	Conceitos Teóricos Ademais	48
2.4.1	O formato de áudio wav	48
2.4.2	Extração de parâmetros	48
2.4.3	Parâmetros utilizados	50

3	A Técnica Proposta	53
3.1	A Base de Dados	53
3.2	Etapa de Extração de Características	54
3.3	Etapa de Classificação	56
4	Testes e Resultados	61
5	Conclusões	69
	Referências	71
	Apêndice I - Publicações durante o doutorado.	77

Capítulo 1

Introdução

A classificação de gêneros musicais (*Music Genre Classification - MGC*) tem se tornado cada vez mais importante, à medida que a facilidade de obter e armazenar dados digitais aumenta, principalmente com o uso da Internet. Particularmente nos últimos anos, a rede mundial de computadores tem se tornado, rapidamente, um mercado apetecível para um determinado conjunto de serviços que tiram partido dos sistemas de MGC, visando aumentar a satisfação e a comodidade dos utilizadores. Para se tornarem interessantes, esses serviços necessitam de bases de dados sempre atualizadas e equipamentos de pesquisa eficientes e rápidos que respondam com sucesso às pesquisas formuladas.

Por outro lado, processos manuais de classificação de gêneros musicais acarretam alguns problemas, tais como o tempo necessário para concluir tais operações no caso em que os dados a organizar são volumosos e o grau de subjetividade associado com cada classificação, já que os resultados desse processo dependem da pessoa que classifica e do seu conhecimento sobre o assunto. Assim sendo, surge a inevitabilidade da utilização de sistemas computacionais automatizados para implementar esse tipo de tarefa.

O classificador proposto é a Máquina Discriminativa Paraconsistente (*Discriminative Paraconsistent Machine - DPM*) [1], que foi desenvolvida nos grupos de pesquisa de Processamento de Sinais e Inteligência Artificial do IFSC/USP e da EESC/USP e que possui como característica a possibilidade de classificação não somente binária [2] [3], tal como a Lógica Fuzzy [4],

propiciando o devido tratamento de contradições e indefinições entre as classes. Uma vez que a classificação obtida no sistema proposto ocorra diferentemente da forma como ocorre com a lógica clássica, também chamada de binária, a base para a elaboração da DPM foi a Lógica Paraconsistente [5]. Este último modelo lógico visa oferecer alternativas aos princípios clássicos, que são insuficientes para tratar proposições cujo resultado seja diferente de “pertence” ou “não-pertence”, por exemplo [6].

Assim, a DPM utiliza resultados formulados com base na Lógica Paraconsistente, mais especificamente a Lógica Paraconsistente Anotada com anotação de dois valores (LPA2v), consistindo em um caso particular da Lógica Paraconsistente que considera a existência de argumentos favoráveis e contrários a uma certa proposição, sendo expressos por meio de um grau de crença e um grau de descrença, respectivamente.

Uma breve revisão de literatura permite encontrar algumas técnicas diversas utilizadas comumente para fins de classificação, tais como as Funções de Base Radial (RBFs), os perceptrons multicamadas (MLPs), além das árvores de decisão estruturadas [7], que também têm sido usados para reconhecimento de padrões. Máquinas de pertinência do vetor (RVMs) [8], além de alguns algoritmos utilizados para o agrupamento multiclasse, tais como códigos de correção de erro, classificadores reavaliado, classificadores não determinísticos, *Support Vector Machine* ou Máquina de Vetor de Suporte (SVMs) probabilísticos e abordagens relacionadas [9], [10], [11], são métodos alternativos. Alguns deles ligeiramente aproximam a intenção das DPMs, mas ainda estão longe de seu objetivo principal que é a de levar em conta indefinições e contradições com base na LPA2v. Portanto, esta foi a principal motivação para utilizar a DPMs: classificação não binária, e portanto mais flexível, associada com o correto tratamento de contradições e indefinições entre as classes.

1.1 Objetivos e Contribuição

O objetivo deste trabalho é o desenvolvimento de um sistema inteligente para identificação de gêneros musicais acústicos com a finalidade de auxiliar no gerenciamento das coleções

de músicas digitais, sendo este de grande importância principalmente para os profissionais da área, ao invés de para os usuários finais, por possibilitar a quantificação do nível de pertinência de determinada música no que diz respeito a diversos gêneros, e não somente um. A abordagem proposta consiste na implementação de um módulo de extração de características e outro módulo de classificação que, em conjunto, devem formar o sistema inteligente proposto. Particularmente, o primeiro módulo é responsável por transformar sinais musicais em um conjunto de características, de tamanho fixo, com base nos conceitos que envolvem análise tempo-frequência de sinais e bandas críticas do ouvido humano. Já o segundo módulo utiliza os conceitos da LPA2v para caracterizar o classificador proposto com base na DPM, que faz uso de um modelo de treinamento supervisionado, incorporando critérios que permitam o tratamento de contradições e indefinições.

Fundamentalmente, a contribuição original deste trabalho ao estado-da-arte consiste no uso da LPA2v, por meio da DPM, para fins de MGC, procedimento para o qual inexistia descrição na literatura até este momento.

1.2 Disposição do Trabalho

Este trabalho está dividido em cinco capítulos, incluindo esta introdução. As particularidades são abordadas da seguinte forma:

- **Capítulo 2:** apresenta uma revisão literária, relacionando fundamentalmente os seguintes tópicos: conceitos de processamentos de sinais, extração de parâmetros, análise tempo-frequência com base nas bandas críticas do ouvido humano, matriz de confusão e sistemas de classificação e reconhecimento de padrões com base na LPA2v e na DPM;
- **Capítulo 3:** descrição da metodologia utilizada para o desenvolvimento da presente técnica;
- **Capítulo 4:** testes e resultados com a análise das técnicas e discussão sobre os resultados;
- **Capítulo 5:** conclusões do trabalho.

Capítulo 2

Revisão Bibliográfica

A MGC tem sido recentemente estudada por vários investigadores [12, 13, 14, 15]. McKay e Fujinaga [16], por exemplo, elaboraram um documento descrevendo as razões pelas quais os cientistas continuam investindo no aumento das pesquisas na área. Fundamentalmente, as questões que eles apontam são relacionadas à ambiguidade e à subjetividade nas classificações, assim como ao dinamismo dos estilos musicais, sendo necessário possuir experiência e habilidade para classificar manualmente determinadas gravações. Poucos gêneros musicais têm definições claras e, muitas vezes, há significativo nível de sobreposição entre eles. Além disso, muitas vezes, as classificações tendem a ser realizadas com base nos artistas ou nos álbuns, em vez de nas gravações individuais. Finalmente, novos gêneros são introduzidos regularmente e a compreensão daqueles já existentes muda com o passar do tempo.

O trabalho pioneiro de Dannenberg et al [17], realizado com base em redes Bayesianas, identifica um dentre quatro estilos musicais. Os autores reportam testes com um artista que produziu, consistentemente e intencionalmente, músicas de estilos diferentes. Considerando uma base com algumas centenas de gravações, uma precisão de 98% foi alcançada, quando a classificação objetivou distinguir entre quatro estilos. Ao utilizar oito classificadores, treinados para votar “sim” ou “não” para oito diferentes estilos, eles conseguiram uma precisão geral que variou entre 77% e 90%.

George Tzanetakis e Perry Cook [18] classificaram as músicas em geral como pertencentes

a um dentre dez gêneros, nomeadamente: música clássica, country, disco, hip-hop, jazz, rock, blues, reggae, pop e metal. No caso particular do jazz, consideram seis sub-gêneros; bigband, cool, fusão, piano, quartetos e swing. Já no caso da música clássica, quatro sub-gêneros foram definidos: coral, orquestra, piano e quarteto de cordas. As características tímbricas utilizadas para definir os estilos foram: centróide, roll-off¹, flux², MFCC (*Mel-Frequency Cepstral Coefficients*) e zcr³. Essas características foram calculadas em janelas de análise de curta duração (23ms). Posteriormente, foram calculadas as médias e variâncias das características anteriores, em intervalos de tempo de 1s. Foi calculada ainda a característica *low-energy* nos mesmos intervalos de 1s. As características rítmicas usadas foram calculadas a partir do histograma de batidas das músicas.

As características do conteúdo de pitch⁴ são baseadas em técnicas de detecção de múltiplos pitches. Tanto as características rítmicas como as de conteúdo de pitch são calculadas em relação a toda a música. No sentido de avaliar a importância das características, foram utilizados dois classificadores: Modelos de Misturas Gaussianas (*Gaussian Mixture Models* - GMM) e K-Vizinhos Mais Próximos (*K-Nearest Neighbors* - KNN). As taxas de acertos variam de 61% a 82,25%.

Seth Golub [19] classifica música em sete gêneros bastante diferentes: a cappella, celta, clássica, eletrônica, jazz, latina e pop-rock. As características utilizadas são *loudness*, centróide, largura de banda e uniformidade, bem como outras características estatísticas obtidas a partir delas. Foram utilizados três classificadores: Modelo Linear Generalizado (*Generalized Linear Model* - GLM), MLP e KNN. Os melhores resultados de classificação conseguidos foram de 67%.

Goulart [20] desenvolveu um sistema de classificação automática de gênero musical onde utiliza-se apenas de conceitos da teoria da informação e da geometria de fractais. Entropia, lacunaridade e dimensão fractal são os parâmetros que treinam os classificadores. Os testes foram

¹Medida da forma do espectro do sinal

²Medida da alteração do espectro do sinal

³Medida do conteúdo de frequência do sinal

⁴Percepção que o ouvido humano tem da frequência do sinal

realizados com duas coleções criadas para este trabalho e os resultados foram proeminentes.

Martin e Kim [21] estudam o problema de identificação de instrumentos musicais. Eles propõem um conjunto de características relacionadas com as propriedades físicas dos instrumentos com o objetivo de identificá-los em um ambiente polifônico.

Silla et al. [22] realizaram uma análise diferente, na qual dividiram a música em três partes (começo, meio e fim, com trechos de 30 segundos cada), utilizando classificadores diferentes para cada parte e combinando os resultados. Nesse trabalho, foi alcançada uma taxa média de acerto 3% maior do que o melhor resultado obtido individualmente (55,15% sem a combinação e 58,07%, utilizando três segmentos, para dez gêneros musicais).

Os trabalhos citados anteriormente descrevem o estado-da-arte sobre o tema. A abordagem proposta difere das apresentadas, conforme descrito adiante, fundamentalmente pela característica inovadora do classificador proposto.

2.1 Lógica Paraconsistente

Para melhor entendimento da Lógica Paraconsistente, serão apresentadas definições básicas dos diversos tipos de lógicas [5].

Lógica é o estudo sistemático do pensamento dedutivo que permite construir argumentos corretos nas ciências naturais, nas ciências humanas e nas ciências formais, possibilitando distinguir os argumentos corretos dos incorretos. A Lógica estabelece as leis do raciocínio, a maneira certa de como a razão deve operar, pouco importando se o raciocínio tem ou não fundamento na realidade. A Lógica moderna e contemporânea usa os mesmos métodos que são usados em Matemática e, por isso, é também chamada de Lógica Simbólica. Por outro lado, a própria Matemática faz uso intenso da Lógica em suas demonstrações e em seus fundamentos.

A Lógica Clássica é aquela que percorreu uma longa trajetória desde Aristóteles, estando já relacionada ao método axiomático da Geometria de Euclides, com intensa atividade na Idade Média, até confluir modernamente nas ideias de Gottlob Frege em 1879 sobre a primeira lingua-

gem formal para a Lógica. Esse tipo de lógica utiliza apenas dois estados lógicos: verdadeiro ou falso. Por exemplo, na proposição “A maçã é vermelha”, num resultado de análise só vão existir duas únicas situações: ela é vermelha ou é não-vermelha. Mas sabe-se que, na realidade, existem inúmeros casos em que uma maçã pode ter cor próxima da vermelha ou próxima da cor verde. É por possuir as características binárias que a Lógica Clássica oferece facilidades em ser aplicada em sistemas de computação; mas por outro lado, quando queremos descrever o mundo real, é justamente esta característica binária que a torna inadequada para ser aplicada em certos casos.

As rígidas leis da Lógica Clássica não permitem tratar situações tais como ambiguidades, contradições, inconsistências e incertezas. Para dar um melhor tratamento à situações não cobertas pela lógica clássica, surgiram as chamadas Lógicas Não-Clássicas. Teoria recente, foi somente a partir do início do Século XX que as Lógicas Não-Clássicas tiveram início com relevantes estudos que deram origem às Lógicas Multivalentes, historicamente ligadas à Jean Lukasiewicz, à Lógicas Intuicionistas historicamente ligadas à Alois Brower e Arendt Heyting, e as Lógicas Paraconsistentes historicamente ligadas a Stanislaw Jaskowski e a Newton Carneiro Afonso da Costa.

A Lógica Paraconsistente (LP) é uma lógica Não-Clássica que nasceu da necessidade de se criar análises mais eficientes, com capacidade de considerar situações reais que fogem às rígidas leis binárias da Lógica Clássica. Portanto, a lógica Paraconsistente trata-se de uma lógica Não-Clássica criada para desafiar o princípio da contradição.

Lógica Paraconsistente Anotada (LPA) é uma classe de Lógica Paraconsistente que traz as proposições valoradas por anotações muitas vezes chamadas de Graus de Crença. Na LPA, essas proposições, com seus respectivos graus de crença, são representadas por meio de um reticulado associado, o que permite a manipulação de dados e descrições inconsistentes de modo não-trivial.

Com a descoberta da LPA, introduzidas pela primeira vez em programação lógica por Subrahmanian [23], encontrou-se uma forma de aplicar os conceitos teóricos da LP nos mais vari-

ados campos. Devido à aplicações que as lógicas anotadas encontraram, tornou-se conveniente um estudo de seus fundamentos.

2.1.1 Aplicação da Lógica Paraconsistente Anotada

Quando sistemas computacionais precisam descrever situações do mundo real, todas as informações necessárias para análise, devido a vários fatores, vêm impregnadas de ruídos que conferem às mesmas um determinado grau de incerteza. Nas análises feitas baseadas em informações obtidas de condições não ideais, diz-se que os sistemas tratam com conhecimento incerto.

Rich [24] descreve a seguinte definição: O conhecimento incerto é aquele que é discutível e ao qual, normalmente, associamos uma medida de incerteza que descreva, de algum modo, crenças para as quais existem certas evidências de apoio. A LPA tem como objetivo principal implementar Sistemas Lógicos de Controle por meio de programas de computação que permitam manipular e raciocinar com sinais representativos sobre informações de conhecimento incerto que podem ser inconsistentes.

A fim de ilustrar como a LPA pode ajudar a resolver as tarefas de classificação e decisão, assume-se aqui uma situação em que um homem quer decidir se quer ou não ir para a praia durante as férias. A decisão será tomada com base em dois critérios completamente independentes: o saldo disponível em sua conta bancária e a previsão do tempo.

Apesar de um classificador tradicional, tal como uma Máquina de vetores de suporte (*Support Vector Machines* - SVM) [7, 25, 26, 27], certamente poder ser treinada para resolver o caso com base em um certo número de exemplos que levem em conta ambos os critérios, a hipótese é que há algumas vantagens na adoção da LPA. Primeiro, suponha que a decisão tomada pelo homem implique não apenas a possibilidade de ir à praia. Particularmente, uma decisão positiva implica que ele poderá não apenas aproveitar o mar, mas também assistir a um *show* de sua banda de *rock* favorita em frente ao mar. Ficar em casa, no entanto, proporciona uma oportunidade significativa para descobrir se a sua namorada está lhe traindo, que é um fato que

ele tem suspeitado durante os últimos meses. A decisão, portanto, depende drasticamente, não só dos fatores mencionados, mas do que o homem considera mais importante para ele. É possível que, mesmo com mau tempo e pouco dinheiro, ele decida viajar e ver o *show*, porque ele não é tão apaixonado pela garota. Por outro lado, se ela é o amor da sua vida, ele vai preferir ficar em casa, mesmo possuindo uma considerável quantidade de dinheiro e prevendo um dia maravilhoso de sol. O homem também pode ter um conflito em sua mente, tal como “eu definitivamente quero ver o *show* na praia, porque isso é o que eu tenho esperado minha vida toda, mas eu faria qualquer coisa para pegar minha garota com outro homem”, ou uma indecisão, como “eu estou perdido e não sei como decidir.” O primeiro pensamento representa uma contradição, ou seja, ele quer e não quer ir, ao mesmo tempo, e este último representa uma indefinição, ou seja, nem ir nem ficar em casa parece ser uma escolha razoável.

Constantemente, todas as pessoas enfrentam situações como a descrita acima. Como cada cérebro decide? Isso ainda é um mistério para a comunidade científica, pelo menos em parte. Apesar de não se poder explicar todo o processo pelo qual um ser humano elabora uma decisão, sabe-se que existe uma considerável influência da personalidade da pessoa, inspiração, educação e assim por diante, em tal ação. Ciências biomédicas têm descoberto fatos importantes nessa área e, paralelamente, diversas abordagens que artificialmente aproximam o comportamento biológico do cérebro têm surgido na literatura. Em tal contexto, a LPA ganhou um espaço considerável no campo de inteligência artificial. Particularmente, sistemas paraconsistentes tiveram seus princípios estabelecidos em 1910, quando Jean Lukasiewicz e Nicolai Vasiliev afirmaram que alguns aspectos clássicos de lógica, incluindo o princípio da contradição, deveriam ser revistos. Em 1948, Stanislaw Jaskowski apresentou um sistema lógico que poderia ser aplicada para a solução de problemas inconsistentes e, por volta de 1960, o brasileiro Newton Carneiro Afonso da Costa especificou uma lógica capaz de tratar indefinições e contradições, ou seja, PLA. Ela tem estado na vanguarda das formulações e do estado-da-arte, as quais podem ser encontradas nas áreas de inteligência artificial, física aplicada, matemática, engenharias e ciências afins.

A principal motivação para o uso da LPA é o fato que ela pode ser aplicada ao projeto de

sistemas que sejam capazes de tratar os problemas da vida real, como o mencionado anteriormente, de uma forma mais eficiente do que lógicas comuns. Em particular, uma LPA pode ser considerada como sendo um sistema lógico que tenta lidar com contradições e indefinições em um modo discriminatório. Neste trabalho, a LPA será utilizada para uma tarefa de MGC, que é considerada como sendo uma hipótese que tem o seu grau de crença e seu grau de descrença. Essas quantificações produzirão o coeficiente de segurança e o coeficiente de contradição que serão utilizados para resolver a classificação. Abordagens semelhantes, tais como os de [28], [4] e [29], foram recentemente criadas para o tratamento de situações não determinísticas, no entanto, todas elas são inteiramente baseadas nos conceitos de sistemas lógicos regulares. Em [31], [30], e [32], uma conceituação teórica mais ampla pode ser obtida.

2.1.2 Lógica Paraconsistente Anotada - LPA 1v

Para uma melhor representação, a LPA 1v pode ser associada a um reticulado, em cujos vértices são alocados os símbolos que indicam os estados lógicos. O estado lógico é encontrado com base em dois valores de anotação, μ_1 e μ_2 , onde μ_1 representa o grau de crença e μ_2 representa o grau de descrença atribuído à proposição.

Os estados lógicos, com os valores dos graus de crença e de descrença podem ser relacionados da seguinte forma:

- **T** = (1,1) Inconsistente.
- **V** = (1, 0) Verdadeiro.
- **F** = (0, 1) Falso.
- **\perp** = (0, 0) Indeterminado.

Os graus de crença e descrença em um procedimento prático são considerados como as informações de entrada do sistema e os estados lógicos representados nos vértices do reticulado são as saídas resultantes da análise paraconsistente, como mostrado na Figura 2.1.

Dada a proposição “João matou Pedro”, tem-se:




Figura 2.1 – Demonstração de um sistema básico de análise paraconsistente.

- Se anotarmos com $[1,1]$, existe uma inconsistência na proposição, alguém forneceu uma informação que João estava com Pedro no momento do crime, enquanto outra pessoa afirmou que naquele momento João estava no cinema;
- Se anotarmos com $[0,0]$, ninguém soube dizer onde João estava, ninguém viu com Pedro nem em outro lugar;
- Se anotarmos com $[1,0]$, crê-se totalmente que João matou Pedro, alguém afirmou que João estava com Pedro e viu o crime ocorrer;
- Se anotarmos com $[0,1]$, crê-se totalmente que João não matou Pedro, alguém informou que João não estava com Pedro no momento do crime.

2.1.3 Lógica Paraconsistente Anotada - LPA 2v

A LPA 2v traz a anotação composta por dois componentes, onde para cada proposição, associa-se dois valores de graus. Tal fato pode ser observado, por exemplo, como sendo o re-

sultado de uma inferência no *Paralog*⁵ [33], que consiste no fechamento dos fatores evidenciais do predicado que foi consultado na inferência. É possível obter o *grau de contradição* (*Gct*) e o *grau de certeza* (*Gc*) a partir do *grau de crença* e do *grau de descrença* de uma proposição. O *Gct* é o valor que representa, no reticulado, a distância entre os dois estados extremos *inconsistente* e *indeterminado*, conforme a Figura 2.2.

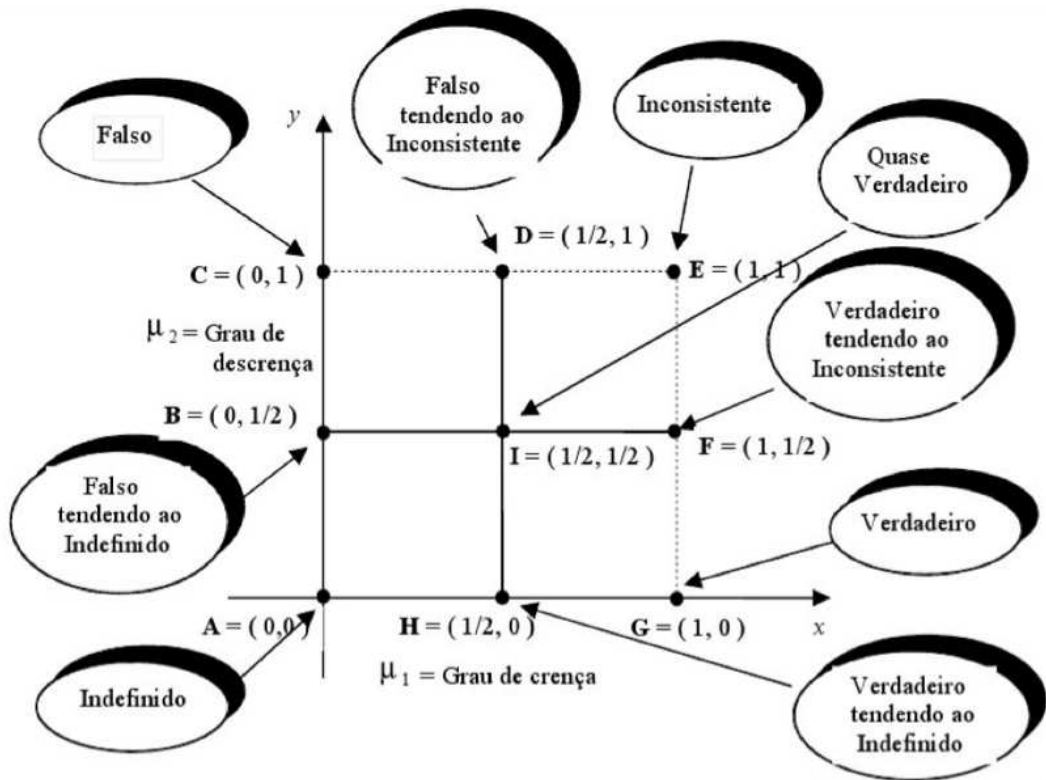


Figura 2.2 – O plano paraconsistente, de acordo com Huhn [4].

A LPA2v, surgida como evolução da LPA1v, consiste da base para a construção da DPM, discutida a seguir.

⁵O ParaLog_e é um interpretador escrito na linguagem Prolog baseado no Paralog (26). O ParaLog_e utiliza conceitos de Programação Lógica Evidencial Paraconsistente baseada em Lógica Anotada com notações infinitamente valoradas

2.2 Pesquisas em desenvolvimento pela LPA e a *Discriminative Paraconsistente Machine* (DPM)

A linha de pesquisas em desenvolvimento pelo LPA está atualmente dividida em 5 ramos de atuação:

- Criação de Sistemas Especialistas;
- Criação de Sistemas de Reconhecimento de Padrões e Imagens;
- Criação de Sistemas de Controle e Reconhecimento para Área de Robótica;
- Sistemas Inteligentes e Modelos para Neurocomputação;
- Criação de Sistemas de Controle para Automação de Processos.

Para uso em cada uma das situações elencadas, Guido et al [1] desenvolveu uma nova ferramenta para reconhecimento de padrões chamado Máquina Paraconsistente Discriminativa (DPM - *Discriminative Paraconsistent Machine*), que consiste em um novo classificador elaborado com base na lógica paraconsistente anotada (LPA). É baseada em um modelo discriminativo de treinamento semi-supervisionado que incorpora critérios paraconsistência, permitindo um tratamento inteligente de contradições e indefinições. DPMs podem ser aplicadas para resolver problemas em muitos campos da ciência, de acordo com os testes e discussões apresentados no trabalho, demonstram a eficácia na utilização desse sistema.

Barbon Jr [34] apresenta em seu trabalho de doutorado visando a identificação de patologias na laringe, a definição, construção e a aplicação da rede DPM. Os resultados obtidos são motivadores, indicando um avanço na área de classificação. Isso se deve ao fato de que a DPM foi criada para tratar situações tais como inconsistências e indefinições, diferentemente de outros classificadores que não foram criados para tal fim.

2.3 A DPM e sua arquitetura

DPMs são ferramentas que recebem um sinal real de dimensão X como entrada e produzem saídas numéricas que correspondem à solução esperada para o problema a ser tratado. A arquitetura da DPM é ilustrada na Figura 2.3. Seus elementos, que são inspirados sobre os que formam a maioria das redes neurais artificiais (RNA) como descrito em [12], são:

- Camada inicial contendo X unidades passivas (PU), cada uma tendo uma entrada alimentada por valores externos e T saídas que estão conectadas aos neurônios da camada discriminativa;
- Camada discriminativa contendo T neurônios com X entradas cada, mais os seus pesos associados $h_{i,j}$, onde j é o j -ésimo peso da unidade i , ($0 \leq i \leq X - 1$) e ($0 \leq j \leq T - 1$). Cada neurônio tem uma saída que se liga às entradas de ambos os neurônios da camada de mistura;
- Camada de mistura contendo dois neurônios (neurônio₁ e neurônio₂) com T entradas e uma saída cada um, sendo $g_{i,c1}$ e $g_{i,c2}$, ($0 \leq i \leq T - 1$), seus pesos associados, respectivamente. As saídas dos neurônios (neurônio₁ e neurônio₂) ligam-se à unidade de saída paraconsistente (POU) da camada final;
- Camada final contendo uma POU com duas entradas e uma saída. Os pesos associados para ambas as entradas são sempre 1, isto é, nenhuma saída dos dois neurônios da camada de mistura é modificada antes da entrada POU. Esta unidade é responsável pela produção da saída da máquina, ou seja, o resultado final.

As subseções seguintes descrevem como essas camadas listadas funcionam.

2.3.1 Camada inicial

Cada PU da camada inicial simplesmente encaminha a sua entrada para todos os neurônios da camada discriminativa, sem processamento adicional, sendo considerados elementos simbólicos.

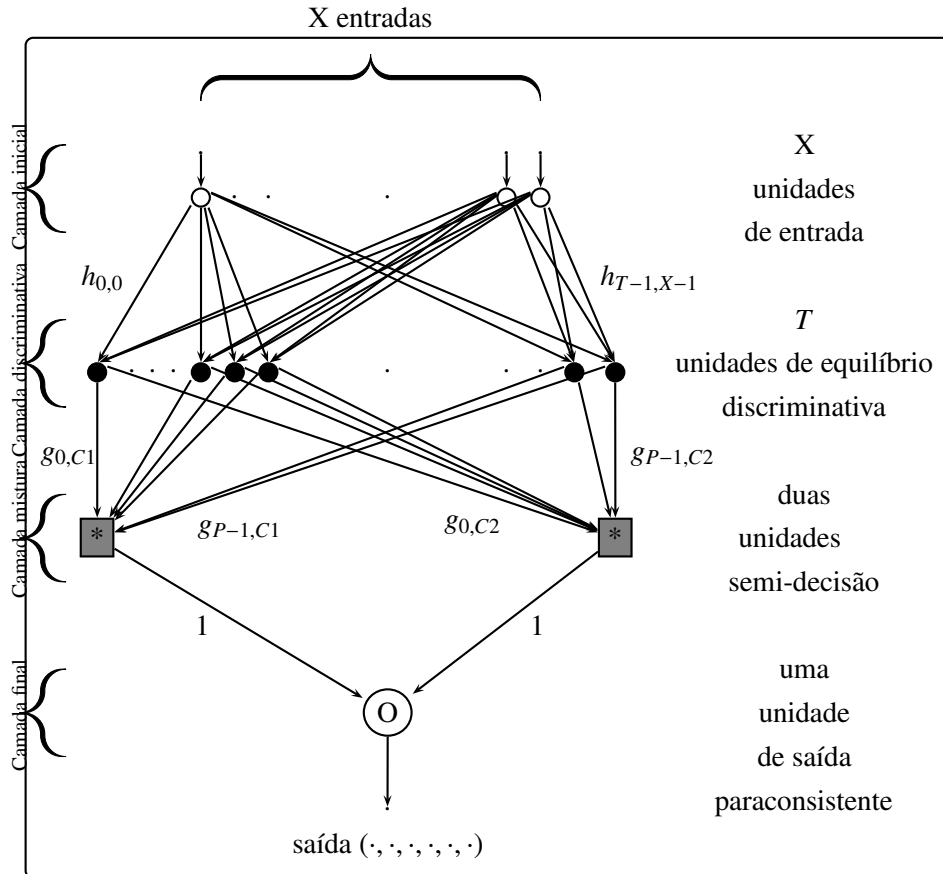


Figura 2.3: Estrutura DPM (extraída de [1]).

2.3.2 Camada discriminativa

Os neurônios da camada discriminativa são ativos, ou seja, processam os valores ponderados apresentados nas suas entradas para produzir uma saída, de acordo com a equação (2.1), sendo que $c_{y,t}$ é a saída da y -ésima unidade do t -ésimo exemplo de treinamento ($0 \leq y, t \leq T - 1$).

$$c_{y,t} = \sum_{k=0}^{X-1} x_{k,t} h_{y,k} \quad , \quad (2.1)$$

O primeiro objetivo da camada discriminativa de uma DPM é o de aumentar a dimensão dos dados de entrada a partir de X para T , o que faz com que seja mais fácil a produção de uma separação linear entre as classes. O segundo objetivo é que a t -ésima saída do neurônio dessa camada forneça a máxima resposta ao t -ésimo exemplo de treinamento e a mínima resposta aos demais exemplos ($0 \leq t \leq T - 1$), sendo a máxima e mínima respostas iguais aos valores 1 e -1,

respectivamente. Então, para a t -ésima unidade, o sistema linear de T equações e X variáveis apresenta-se como a equação (2.2).

$$c_{y,t} = \sum_{k=0}^{X-1} x_{k,i} h_{y,k} = \begin{cases} 1 & \text{para } y = t. \\ -1 & \text{para todos } y \in [0, T-1], y \neq t. \end{cases} \quad (2.2)$$

Cada um dos T sistemas de equações gerados pela variação de y na equação (2.2) apresenta o seguinte problema: não existe uma solução exata para ele, devido ao fato do número de equações (T) ser maior do que o número de variáveis (X). Matrizes podem ser usadas para expressar tais sistemas da seguinte forma:

$$\underbrace{\begin{pmatrix} x_{0,0} & x_{1,0} & x_{2,0} & \dots & \dots & \dots & x_{X-2,0} & x_{X-1,0} \\ x_{0,1} & x_{1,1} & x_{2,1} & \dots & \dots & \dots & x_{X-2,1} & x_{X-1,1} \\ x_{0,2} & x_{1,2} & x_{2,2} & \dots & \dots & \dots & x_{X-2,2} & x_{X-1,2} \\ \vdots & \vdots & \vdots & & & & \vdots & \vdots \\ x_{0,T-2} & x_{1,T-2} & x_{2,T-2} & \dots & \dots & \dots & x_{X-2,T-2} & x_{X-1,T-2} \\ x_{0,T-1} & x_{1,T-1} & x_{2,T-1} & \dots & \dots & \dots & x_{X-2,T-1} & x_{X-1,T-1} \end{pmatrix}}_{\text{matrix } A_{[T][X]}} \cdot \underbrace{\begin{pmatrix} h_{y,0} \\ h_{y,1} \\ h_{y,2} \\ \vdots \\ h_{y,X-2} \\ h_{y,X-1} \end{pmatrix}}_{\text{array } B_{[X]}} = \underbrace{\begin{pmatrix} c_{y,t} \\ c_{y,t} \\ c_{y,t} \\ \vdots \\ c_{y,t} \\ c_{y,t} \end{pmatrix}}_{\text{array } C_{[T]}}. \quad (2.3)$$

Definindo $A_{[T][X]}^*$ como sendo a transposta de $A_{[T][X]}$, os seguintes sistemas lineares são formados:

$$A_{[T][X]}^* \cdot A_{[T][X]} \cdot B_{[X]} = A_{[T][X]}^* \cdot C_{[T]} \quad (2.4)$$

obtendo-se assim um sistema com um total de X equações e X incógnitas cada um, apresentando soluções exatas que resolvem o problema da incompatibilidade nas equações dos sistemas originais em (2.2). Este cálculo apresentado corresponde ao método dos mínimos quadrados que tem a finalidade de solucionar sistemas lineares incompatíveis [35]. Aplicando este método, os sistemas sempre convergem para uma solução, independente de qualquer procedimento iterativo.

2.3.3 Camada de mistura

A camada de mistura requer dois neurônios, para os quais há necessidade de treinamento supervisionado, que são responsáveis pela produção de dois valores de saída, I_{C1} e I_{C2} , sendo

cada um gerado por um desses neurônios. Pode-se calcular I_{C_1} e I_{C_2} como se segue:

$$I_{C_1} = \sum_{k=0}^{P-1} \Phi(c_{k,t}) g_{k,C_1} \quad \text{e} \quad I_{C_2} = \sum_{k=0}^{P-1} \Phi(c_{k,t}) g_{k,C_2} \quad , \quad (2.5)$$

sendo $\phi(\alpha) = \frac{1}{1+e^{-\alpha}}$ a função de aprendizado que mantém $c_{y,t}$ limitado, isto é, $(0 \leq c_{y,t} \leq 1)$. Em seguida é utilizada a equação (2.6), sendo que os pesos g_{k,C_1} e g_{k,C_2} , $(0 \leq k \leq P-1)$, foram determinados durante o período de treino. Correspondem, respectivamente, às soluções dos seguintes sistemas de equações lineares nas incógnitas T :

$$\begin{pmatrix} \Phi(c_{0,0}) & \Phi(c_{1,0}) & \Phi(c_{2,0}) & \dots & \dots & \dots & \Phi(c_{P-2,0}) & \Phi(c_{P-1,0}) \\ \Phi(c_{0,1}) & \Phi(c_{1,1}) & \Phi(c_{2,1}) & \dots & \dots & \dots & \Phi(c_{P-2,1}) & \Phi(c_{P-1,1}) \\ \Phi(c_{0,2}) & \Phi(c_{1,2}) & \Phi(c_{2,2}) & \dots & \dots & \dots & \Phi(c_{P-2,2}) & \Phi(c_{P-1,2}) \\ \vdots & \vdots & \vdots & & & & \vdots & \vdots \\ \Phi(c_{0,T-2}) & \Phi(c_{1,T-2}) & \Phi(c_{2,T-2}) & \dots & \dots & \dots & \Phi(c_{T-2,T-2}) & \Phi(c_{T-1,T-2}) \\ \Phi(c_{0,T-1}) & \Phi(c_{1,T-1}) & \Phi(c_{2,T-1}) & \dots & \dots & \dots & \Phi(c_{T-2,T-1}) & \Phi(c_{T-1,T-1}) \end{pmatrix} \cdot \begin{pmatrix} g_{0,C_1} \\ g_{1,C_1} \\ g_{2,C_1} \\ \vdots \\ g_{P-2,C_1} \\ g_{P-1,C_1} \end{pmatrix} = \begin{pmatrix} s_{0,C_1} \\ s_{1,C_1} \\ s_{2,C_1} \\ \vdots \\ s_{P-2,C_1} \\ s_{P-1,C_1} \end{pmatrix} \quad (2.6)$$

e

$$\begin{pmatrix} \Phi(c_{0,0}) & \Phi(c_{1,0}) & \Phi(c_{2,0}) & \dots & \dots & \dots & \Phi(c_{P-2,0}) & \Phi(c_{P-1,0}) \\ \Phi(c_{0,1}) & \Phi(c_{1,1}) & \Phi(c_{2,1}) & \dots & \dots & \dots & \Phi(c_{P-2,1}) & \Phi(c_{P-1,1}) \\ \Phi(c_{0,2}) & \Phi(c_{1,2}) & \Phi(c_{2,2}) & \dots & \dots & \dots & \Phi(c_{P-2,2}) & \Phi(c_{P-1,2}) \\ \vdots & \vdots & \vdots & & & & \vdots & \vdots \\ \Phi(c_{0,T-2}) & \Phi(c_{1,T-2}) & \Phi(c_{2,T-2}) & \dots & \dots & \dots & \Phi(c_{T-2,T-2}) & \Phi(c_{T-1,T-2}) \\ \Phi(c_{0,T-1}) & \Phi(c_{1,T-1}) & \Phi(c_{2,T-1}) & \dots & \dots & \dots & \Phi(c_{T-2,T-1}) & \Phi(c_{T-1,T-1}) \end{pmatrix} \cdot \begin{pmatrix} g_{0,C_2} \\ g_{1,C_2} \\ g_{2,C_2} \\ \vdots \\ g_{P-2,C_2} \\ g_{P-1,C_2} \end{pmatrix} = \begin{pmatrix} s_{0,C_2} \\ s_{1,C_2} \\ s_{2,C_2} \\ \vdots \\ s_{P-2,C_2} \\ s_{P-1,C_2} \end{pmatrix} \quad (2.7)$$

sendo s_{i,C_1} e s_{i,C_2} , com $(0 \leq i \leq P-1)$, as saídas de dois conjuntos de resultados da camada de mistura, pertencendo uma a cada uma das classes C_1 e C_2 , respectivamente; s_{i,C_1} e s_{i,C_2} , com resultados 1 e -1, correspondem, também respectivamente, a uma indicação positiva e uma negativa.

Existe também a possibilidade de atribuir qualquer valor real entre 1 e -1 para os resultados acima mencionados, em vez de apenas 1 ou -1. Nesse caso, tais valores descrevem o grau de afirmação de que uma certa entrada pertence, ou não, a uma das classes, sendo 1 e -1 os níveis máximo e mínimo, respectivamente.

2.3.4 Camada final

A POU não é usada para o treinamento da rede, e sim para executar as decisões previstas na fase de teste. Esta unidade produz o resultado final com base nos dois valores recebidos da camada de mistura e na PL. Particularmente, a POU considera os valores recebidos de ambas as camadas de mistura para decidir se uma determinada entrada da DPM corresponde a C_1 , a C_2 , ou ambas, indicando também o nível de contradição e/ou indefinição na classificação. Essa decisão é baseada no grau de confiança (γ_1) e no grau de descrédito (γ_2) de cada uma das decisões, que são medidas independentes, sem que uma complemente a outra. Os valores de γ_1 e γ_2 ($0 \leq \gamma_1, \gamma_2 \leq 1$), são definidos com base nas saídas dos dois neurônios da camada de mistura como se segue:

$$\gamma_1 = e^{-|I_{C1}-1|} \quad (2.8)$$

$$\gamma_2 = e^{-|I_{C2}-1|} \quad (2.9)$$

onde I_{C1} e I_{C2} são as saídas dos dois neurônios da camada de mistura.

Em análise, γ_1 descreve o grau de fé que uma certa entrada na DPM pertence à classe C_1 . Por outro lado, γ_2 descreve o grau de descrédito que a mesma entrada da DPM não pertence a C_1 . Seis coeficientes, de acordo com a teoria de PL, são calculados a partir dos resultados anteriores:

$$G_1 = \gamma_1 - \gamma_2 \quad , \quad \text{com domínio entre } [-1, 1] \quad (2.10)$$

que é chamado coeficiente de segurança e descreve o nível de certeza de que a entrada da DPM pertence a uma determinada classe,

$$G_2 = \gamma_1 + \gamma_2 - 1 \quad , \quad \text{com domínio entre } [-1, 1] \quad (2.11)$$

que é chamado coeficiente de contradição e descreve o nível de contradição e / ou indefinição

da classificação,

$$R_1 = 1 - \frac{D_1}{D_1 + D_2 + D_3 + D_4}, \quad \text{com domínio entre } [0, 1] \quad (2.12)$$

que é chamado de fé real em C_1 ,

$$R_2 = 1 - \frac{D_2}{D_1 + D_2 + D_3 + D_4}, \quad \text{com domínio entre } [0, 1] \quad (2.13)$$

que é chamado de fé real em C_2 ,

$$R_3 = 1 - \frac{D_3}{D_1 + D_2 + D_3 + D_4}, \quad \text{com domínio entre } [0, 1] \quad (2.14)$$

que é chamado de fé real em contradição, e

$$R_4 = 1 - \frac{D_4}{D_1 + D_2 + D_3 + D_4}, \quad \text{com domínio entre } [0, 1] \quad (2.15)$$

que é chamado de fé real em indefinição.

Nas equações (2.12) a (2.15), os valores de $D_1 = \sqrt{(G_1 - 1)^2 + G_2^2}$, $D_2 = \sqrt{(G_1 + 1)^2 + G_2^2}$, $D_3 = \sqrt{G_1^2 + (G_2 - 1)^2}$ e $D_4 = \sqrt{G_1^2 + (G_2 + 1)^2}$ correspondem às distâncias entre os pontos $(1, 0)$, $(-1, 0)$, $(0, 1)$, $(0, -1)$, respectivamente, para o ponto (G_1, G_2) no plano paraconsistente.

2.3.5 Exemplo numérico de uma DPM

Para ilustrar melhor os processos de treinamento e de testes da rede DPM, será apresentado um exemplo de base numérica. Tal problema não tem significado estatístico. Classificações reais normalmente requerem um número maior de dados para o treinamento.

Declaração do problema

O problema consiste em identificar um determinado padrão de entrada, considerando as classes C_1 e C_2 , utilizando uma DPM. A primeira classe é formada por vetores em três

dimensões para os quais o terceiro elemento corresponde à soma do primeiro mais o segundo. Por outro lado, esta última classe é formada pelos vetores para os quais o terceiro elemento corresponde à diferença entre o primeiro e o segundo. Os exemplos a seguir são usados para treinar a DPM: $E_1=\{0,1,1\}$, $E_2=\{1,0,1\}$, $E_3=\{1,1,2\}$, $E_4=\{0,1,-1\}$ e $E_5=\{1,1,0\}$.

Solução

Uma DPM com $X = 3$ entradas e $T = 5$ neurônios na camada discriminativa é necessária porque há cinco exemplos de dimensão três. Cinco sistemas lineares são obtidos por meio da equação (2.3) para $(0 \leq y \leq 4)$, ou seja:

$$\begin{pmatrix} 0 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 2 \\ 0 & 1 & -1 \\ 1 & 1 & 0 \end{pmatrix} \cdot \begin{pmatrix} h_{0,0} \\ h_{0,1} \\ h_{0,2} \end{pmatrix} = \begin{pmatrix} 1 \\ -1 \\ -1 \\ -1 \\ -1 \end{pmatrix} \quad ; \quad \begin{pmatrix} 0 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 2 \\ 0 & 1 & -1 \\ 1 & 1 & 0 \end{pmatrix} \cdot \begin{pmatrix} h_{1,0} \\ h_{1,1} \\ h_{1,2} \end{pmatrix} = \begin{pmatrix} -1 \\ 1 \\ -1 \\ -1 \\ -1 \end{pmatrix} \quad ;$$

$$\begin{pmatrix} 0 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 2 \\ 0 & 1 & -1 \\ 1 & 1 & 0 \end{pmatrix} \cdot \begin{pmatrix} h_{2,0} \\ h_{2,1} \\ h_{2,2} \end{pmatrix} = \begin{pmatrix} -1 \\ -1 \\ 1 \\ -1 \\ -1 \end{pmatrix} \quad ; \quad \begin{pmatrix} 0 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 2 \\ 0 & 1 & -1 \\ 1 & 1 & 0 \end{pmatrix} \cdot \begin{pmatrix} h_{3,0} \\ h_{3,1} \\ h_{3,2} \end{pmatrix} = \begin{pmatrix} -1 \\ -1 \\ -1 \\ 1 \\ -1 \end{pmatrix} \quad ;$$

$$\text{e} \quad \begin{pmatrix} 0 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 2 \\ 0 & 1 & -1 \\ 1 & 1 & 0 \end{pmatrix} \cdot \begin{pmatrix} h_{4,0} \\ h_{4,1} \\ h_{4,2} \end{pmatrix} = \begin{pmatrix} -1 \\ -1 \\ -1 \\ -1 \\ 1 \end{pmatrix} .$$

Com o uso da equação (2.4), os sistemas acima são convertidos, respectivamente, para os

seguintes:

$$\begin{pmatrix} 3 & 2 & 3 \\ 2 & 4 & 2 \\ 3 & 2 & 7 \end{pmatrix} \cdot \begin{pmatrix} h_{0,0} \\ h_{0,1} \\ h_{0,2} \end{pmatrix} = \begin{pmatrix} -3 \\ -2 \\ -1 \end{pmatrix} \quad ; \quad \begin{pmatrix} 3 & 2 & 3 \\ 2 & 4 & 2 \\ 3 & 2 & 7 \end{pmatrix} \cdot \begin{pmatrix} h_{1,0} \\ h_{1,1} \\ h_{1,2} \end{pmatrix} = \begin{pmatrix} -1 \\ -4 \\ -1 \end{pmatrix} \quad ;$$

$$\begin{pmatrix} 3 & 2 & 3 \\ 2 & 4 & 2 \\ 3 & 2 & 7 \end{pmatrix} \cdot \begin{pmatrix} h_{2,0} \\ h_{2,1} \\ h_{2,2} \end{pmatrix} = \begin{pmatrix} -1 \\ -2 \\ 1 \end{pmatrix} \quad ; \quad \begin{pmatrix} 3 & 2 & 3 \\ 2 & 4 & 2 \\ 3 & 2 & 7 \end{pmatrix} \cdot \begin{pmatrix} h_{3,0} \\ h_{3,1} \\ h_{3,2} \end{pmatrix} = \begin{pmatrix} -3 \\ -2 \\ -5 \end{pmatrix} \quad e$$

$$\begin{pmatrix} 3 & 2 & 3 \\ 2 & 4 & 2 \\ 3 & 2 & 7 \end{pmatrix} \cdot \begin{pmatrix} h_{4,0} \\ h_{4,1} \\ h_{4,2} \end{pmatrix} = \begin{pmatrix} -1 \\ -2 \\ -3 \end{pmatrix}$$

que apresentam, respectivamente, as seguintes soluções:

$$\begin{aligned} h_{0,0} &= -1.500, & h_{0,1} &= 0, & h_{0,2} &= 0.500; \\ h_{1,0} &= 0.500, & h_{1,1} &= -1.250, & h_{1,2} &= 0; \\ h_{2,0} &= -0.500, & h_{2,1} &= -0.500, & h_{2,2} &= 0.500; \\ h_{3,0} &= -0.500, & h_{3,1} &= 0, & h_{3,2} &= -0.500; \\ h_{4,0} &= 0.500, & h_{4,1} &= -0.500, & h_{4,2} &= -0.500. \end{aligned}$$

Aplicando a equação (2.1) no resultados $h_{j,i}$, para $0 \leq t, y \leq 4$, tem-se:

$$\begin{aligned} c_{0,0} &= 0.500, & c_{1,0} &= -1.250, & c_{2,0} &= 0, & c_{3,0} &= -0.500, & c_{4,0} &= -1.000; \\ c_{0,1} &= -1.000, & c_{1,1} &= 0.500, & c_{2,1} &= 0, & c_{3,1} &= -1.000, & c_{4,1} &= 0; \\ c_{0,2} &= -0.500, & c_{1,2} &= -0.750, & c_{2,2} &= 0, & c_{3,2} &= -1.500, & c_{4,2} &= -1.000; \\ c_{0,3} &= -0.500, & c_{1,3} &= -1.250, & c_{2,3} &= -1.000, & c_{3,3} &= 0.500, & c_{4,3} &= 0; \\ c_{0,4} &= -1.500, & c_{1,4} &= -0.750, & c_{2,4} &= -1.000, & c_{3,4} &= -0.500, & c_{4,4} &= 0. \end{aligned}$$

O próximo passo é a utilização das equações 2.6 e 2.7 para obter, respectivamente,

$$\begin{pmatrix} 0.62 & 0.22 & 0.50 & 0.38 & 0.27 \\ 0.27 & 0.62 & 0.50 & 0.27 & 0.50 \\ 0.38 & 0.32 & 0.50 & 0.18 & 0.27 \\ 0.38 & 0.22 & 0.27 & 0.62 & 0.50 \\ 0.18 & 0.32 & 0.27 & 0.38 & 0.50 \end{pmatrix} \cdot \begin{pmatrix} g_{0,C_1} \\ g_{1,C_1} \\ g_{2,C_1} \\ g_{3,C_1} \\ g_{4,C_1} \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ 1 \\ -1 \\ -1 \end{pmatrix}$$

e

$$\begin{pmatrix} 0.62 & 0.22 & 0.50 & 0.38 & 0.27 \\ 0.27 & 0.62 & 0.50 & 0.27 & 0.50 \\ 0.38 & 0.32 & 0.50 & 0.18 & 0.27 \\ 0.38 & 0.22 & 0.27 & 0.62 & 0.50 \\ 0.18 & 0.32 & 0.27 & 0.38 & 0.50 \end{pmatrix} \cdot \begin{pmatrix} g_{0,C_2} \\ g_{1,C_2} \\ g_{2,C_2} \\ g_{3,C_2} \\ g_{4,C_2} \end{pmatrix} = \begin{pmatrix} -1 \\ 1 \\ -1 \\ 1 \\ 1 \end{pmatrix}$$

O lado direito do primeiro sistema implica que o primeiro, segundo e terceiro exemplos de treinamento pertencem à classe C_1 , mas o quarto e o quinto não. Por outro lado, o lado direito do último sistema implica que o segundo, quarto e quinto exemplos de treinamento pertencem à classe C_2 , enquanto que o primeiro e o terceiro não. Os sistemas têm, respectivamente, as seguintes soluções:

$$g_{0,C_1} = 1.37, \quad g_{1,C_1} = 6.14, \quad g_{2,C_1} = 0.77, \quad g_{3,C_1} = 1.37, \quad \text{e} \quad g_{4,C_1} = -7.89;$$

$$g_{0,C_2} = 1.37, \quad g_{1,C_2} = 6.14, \quad g_{2,C_2} = -7.89, \quad g_{3,C_2} = 1.37, \quad \text{e} \quad g_{4,C_2} = 0.77$$

Testando a DPM treinada

Quatro vetores de entrada foram usados para testar a DPM. O primeiro é $\{1, 0, 1\}$, que pertence ao conjunto de treinamento; o segundo, o terceiro e o quarto, que não pertencem ao conjunto, são $\{3, 3, 3\}$, $\{2, 2, 4\}$ e $\{2, 2, 0\}$, respectivamente.

i) Teste do vetor $\{1, 0, 1\}$: a saída foi $\{0, 1, 0,707, 0,707, 1, 0,586\}$, o que significa que o

vetor de entrada corresponde a ambas as classes e as entradas são mais prováveis a causar uma contradição, como é mostrado na Figura 2.4.




Figura 2.4: DPM de saída para o experimento com o vetor de entrada $\{1, 0, 1\}$. O círculo (\circ), representando a localidade do ponto $[G_1, G_2]$, é exatamente em $[0, 1]$.

ii) Teste do vetor $\{3, 3, 3\}$: a saída foi $\{0, -0,589, 0,731, 0,731, 0,632, 0,905\}$, isto é, o vetor de entrada corresponde a ambas as classes, sendo mais provável de causar uma indefinição. O plano paraconsistente para este caso é apresentada na Figura 2.5.




Figura 2.5: DPM de saída para o experimento com o vetor de entrada $\{3,3,3\}$. O círculo (\circ) representa a localidade do ponto $[G_1, G_2]$, ou seja, $[0, -0,589446]$.

iii) Teste do vetor $\{2, 2, 4\}$: a saída foi $\{0,960, 0,034, 0,989, 0,590, 0,715, 0,705\}$, o que significa que o vetor de entrada corresponde à classe C_1 , como é mostrado na Figura 2.6.

iv) Teste do vetor $\{2, 2, 0\}$: a saída foi $\{-0,960, 0,034, 0,590, 0,989, 0,715, 0,705\}$, isto é, o vetor de entrada corresponde à classe C_2 . O plano paraconsistente para este exemplo é mostrado na Figura 2.7.




Figura 2.6: DPM de saída para o experimento com o vetor de entrada $\{2,2,4\}$. O círculo (\circ) representa a localidade do ponto $[G_1, G_2]$, ou seja, $[0,960, 0,034]$.




Figura 2.7: DPM de saída para o experimento com o vetor de entrada $\{2,2,0\}$. O círculo (\circ) representa a localidade do ponto $[G_1, G_2]$, ou seja, $[-0,960, 0,034]$.

Os exemplos anteriores: $E_1=\{0,1,1\}$, $E_2=\{1,0,1\}$, $E_3=\{1,1,2\}$, $E_4=\{0,1,-1\}$ e $E_5=\{1,1,0\}$ são adequados para ilustrar como a localização do ponto (G_1, G_2) deve ser interpretada no plano paraconsistente. Portanto, G_1 está diretamente relacionado com a classe para a qual será classificada a saída da DPM. Se G_1 for mais próxima de 1, então esta saída é classificada como pertencente à classe C_1 ; caso contrário, é classificada como pertencente à classe C_2 . No caso em que for igual a 0, a saída corresponde exatamente ambas as classes. Por outro lado, G_2 está diretamente relacionada com o nível de contradição que pode ocorrer na saída da rede. Se G_2 está mais próximo de 1, então esta saída está mais provável de causar contradições; caso contrário, podem causar indefinições. No caso em que é igual a 0, a saída permite uma

Tabela 2.1 – *Chunk 1* do formato WAV: componentes e descrições dos 12 bytes integrantes (adaptado de [28]).

Byte	Descrição
0 a 3	<i>string</i> ascii “RIFF”.
4 a 7	comprimento do <i>chunk</i> .
8 a 11	<i>string</i> ascii “WAV”.

classificação perfeita com absolutamente nenhuma contradição e/ou indefinição.

2.4 Conceitos Teóricos Ademais

Esta seção descreve brevemente conceitos adicionais e tradicionalmente encontrados na literatura que foram utilizados neste trabalho.

2.4.1 O formato de áudio wav

Um arquivo no formato WAV [36], que é o formato utilizado para armazenar os sinais musicais utilizados no presente trabalho, consiste em um cabeçalho subdividido em duas partes chamadas *chunk 1* e *chunk 2*, nesta ordem, seguidas pelos valores de amplitudes das amostras, que fazem parte de uma porção identificada como *chunk* de dados. De acordo com a especificação do formato, no caso de sinais amostrados com uma quantização de 16 bits, a faixa de valores para cada amostra vai de - 32768 até 32767. Nas Tabelas 2.1, 2.2 e 2.3 constam as especificações de cada um dos *chunks* mencionados.

2.4.2 Extração de parâmetros

Em qualquer metodologia de classificação de sinais digitais, uma etapa importante é a etapa de extração de parâmetros [37, 38, 39, 40, 41]. Ela visa reduzir a dimensão do sinal de entrada, que pode ser variável, transformando-o em um conjunto reduzido e fixo de valores numéricos, ou características (vetor de características). Os parâmetros são extraídos do sinal

Tabela 2.2 – *Chunk 2* do formato WAV: componentes e descrições dos 24 bytes integrantes (adaptado de [28]).

Byte	Descrição
0 a 3	<i>string</i> ascii “FMT”.
4 a 7	comprimento do <i>chunk</i> .
8 a 9	0 para mono (um canal) e 1 para estéreo (dois canais) .
10 a 11	número de canais (1 para mono e 2 para estéreo).
12 a 15	taxa de amostragem em Hz.
16 a 19	bytes por segundo.
20 a 21	bytes por amostra .
22 a 23	bits por amostra.

Tabela 2.3 – *Chunk* de dados do formato WAV: componentes e descrições dos bytes integrantes (adaptado de [28]).

Byte	Descrição
0 a 3	<i>string</i> ascii “data”.
4 a 7	comprimento do <i>chunk</i> .
8 até o fim	“dados brutos”.

inteiro ou de segmentos dele para, posteriormente, serem entregues ao classificador. Raramente enviam-se os sinais digitais diretamente para o classificador tendo em vista que as suas dimensões são variáveis e consideravelmente grandes, dificultando o projeto e a implementação do mesmo, além de estarem, muitas vezes, contaminados por ruídos.

Como exemplo, pode-se refletir que um minuto de uma música extraída de um CD, digitalizado a 44100 amostras/segundo e quantizado com 16 bits, ocupa em disco cerca de 10MB [42, 43, 44]. Assim, a base de qualquer sistema automático de classificação de áudio é, em geral, a extração de características. Adicionalmente, deve-se observar que para classificar músicas em gêneros musicais por meio do computadores, torna-se necessário definir uma representação para as músicas de forma a tornar viável essa mesma classificação. Assim, o tipo de características a extrair depende do tipo de classificação a efetuar.

Neste trabalho a intenção foi utilizar dois parâmetros contrastantes, ou seja, de domínios distintos. Assim, foram utilizados a energia temporal e a energia espectral de determinadas

bandas de frequências.

2.4.3 Parâmetros utilizados

Energia temporal

Em processamento digital de sinais de áudio, a medição da intensidade sonora pode ser realizada por meio do cálculo da energia do sinal [45]. Para tanto, são usadas técnicas no domínio do tempo (análise temporal) e/ou no domínio da frequência (análise espectral) [46]. Nesse âmbito, a energia de um sinal temporal $x[\cdot]$ com N amostras discretas é um escalar definido, segundo [7], como

$$E = \sum_{i=0}^{N-1} x_i^2 \quad .$$

No presente trabalho, as energias temporais consistem de um grupo de parâmetros utilizados para alimentar o sistema de classificação adotado.

Energia espectral: filtragem via convolução

Segundo [44], o processo de filtragem via convolução é realizado inteiramente no domínio do tempo e constitui o procedimento mais utilizado atualmente para obter sinais modificados que, a partir de um sinal original $x[\cdot]$, contenham apenas determinadas faixas de frequências. A convolução de $x[\cdot]$ com o filtro $t[\cdot]$, que será a abordagem de filtragem digital utilizada daqui para frente, é dada por:

$$y[\cdot] = x[\cdot] * t[\cdot] = \sum_k t_k x_{n-k} \quad , \quad (2.16)$$

sendo $y[\cdot]$ o sinal resultante da filtragem.

Após a filtragem, isto é, após a obtenção de $y[\cdot]$, é possível realizar também, conforme des-

critério anteriormente, um cálculo de energia que visa caracterizar a intensidade de determinadas faixas de frequências. Esse procedimento também é empregado no presente trabalho.

Energia espectral considerando-se Bandas Críticas / Escala Bark

A escala Bark está associada à largura das bandas críticas do ouvido humano. A largura de cada banda crítica difere de acordo com a faixa de frequências: abaixo de 500 Hz as bandas são constantes e com larguras iguais a 100 Hz. Acima de 500 Hz a largura da próxima banda crítica é 20% maior que a da anterior. Foi então criada uma unidade psico-acústica especial: o *bark*. Um *bark* (z) corresponde à largura de uma banda crítica. A faixa de frequência audível corresponde a, aproximadamente, 24 *barks*, contados a partir do *bark* 0. Quando dois ou mais sons, de frequências diferentes mas pertencentes à mesma banda crítica, estão sendo captados simultaneamente, o de maior amplitude mascara o(s) outro(s), portanto, o de menor amplitude não é percebido.

Na Tabela 2.4 constam as bandas críticas, na escala de frequências em Hertz (Hz) e na escala Bark (z), que é uma escala adotada para linearizar o intervalo entre as bandas. A conversão para Barks é dada pela equação $z = \frac{26,81f}{1960+f} - 0,53$, na qual f representa a frequência em Hertz.

Tendo em vista que o ouvido humano processa os sinais de áudio, tais como os sinais musicais empregados neste trabalho, com base nas bandas críticas, este trabalho está, também, baseado na extração de parâmetros, isto é, características, que levam em conta tal procedimento. Assim, filtragens via convolução são empregadas com base em filtros que selecionam frequências de acordo com as bandas críticas. Em seguida, cálculos de energias são aplicados nos sinais filtrados visando obter uma medida da intensidade de tais frequências.

Tabela 2.4 – Escala *Bark*.

Escala Bark	Bandas Críticas	Bandas (Hz)	Índice da Matriz
0	0 - 100	0 - 96.90	0 - 8
1	100 - 200	96.90 - 204.57	9 - 18
2	200 - 300	204.57 - 301.46	19 - 27
3	300 - 400	301.46 - 398.36	28 - 36
4	400 - 510	398.36 - 506.03	37 - 46
5	510 - 630	506.03 - 624.46	47 - 57
6	630 - 770	624.46 - 775.20	58 - 71
7	770 - 920	775.20 - 925.92	72 - 85
8	920 - 1080	925.92 - 1087.43	86 - 100
9	1080 - 1270	1087.43 - 1270.46	101 - 115
10	1270 - 1480	1270.46 - 1485.79	116 - 137
11	1480 - 1720	1485.79 - 1722.66	138 - 159
12	1720 - 2000	1722.66 - 2002.59	160 - 185
13	2000 - 2320	2002.59 - 2325.59	186 - 215
14	2320 - 2700	2325.59 - 2702.42	216 - 250
15	2700 - 3150	2702.42 - 3154.62	251 - 292
16	3150 - 3700	3154.62 - 3703.71	293 - 343
17	3700 - 4400	3703.71 - 4403.54	344 - 408
18	4400 - 5300	4403.54 - 5297.17	409 - 491
19	5300 - 6400	5297.17 - 6395.36	492 - 593
20	6400 - 7700	6395.36 - 7698.12	594 - 714
21	7700 - 9500	7698.12 - 9496.14	715 - 881
22	9500 - 12000	9496.14 - 12004.76	882 - 1114
23	12000 - 15500	12004.76 - 15503.91	1115 - 1439
24	15500 - 22050	15503.91 - 22020.00	1440 - 2047

Capítulo 3

A Técnica Proposta

O sistema proposto consiste em um algoritmo para classificar automaticamente seis gêneros musicais, descritos adiante, sendo que a sua implementação será realizada em duas etapas: extração de parâmetros e classificação por meio do classificador paraconsistente DPM. Os parâmetros estimados dos sinais de áudio devem retratar as características que possibilitam a classificação de cada sinal em seu respectivo gênero, conforme descrito adiante. Na Figura 3.1, consta a arquitetura básica do sistema proposto.

3.1 A Base de Dados

As músicas foram todas extraídas a partir de *compact discs* (CDs), por uma questão de qualidade dos dados, tendo sido armazenadas em formato WAV, 44100 amostras por segundo, 16 bits. A base de dados completa inclui seis gêneros musicais: bolero, sertanejo, salsa, forró, valsa e *jazz*, contendo setenta títulos de cada gênero. Todas as músicas foram previamente classificadas por profissionais com inúmeros anos de experiência, vinculados ao Estudio By Tony da cidade de São José do Rio Preto que gentilmente concedeu. As músicas utilizadas foram criteriosamente selecionadas e pré-classificadas pelo Estudio como sendo “puras” em termos de gênero, evitando o treinamento equivocado do classificador.

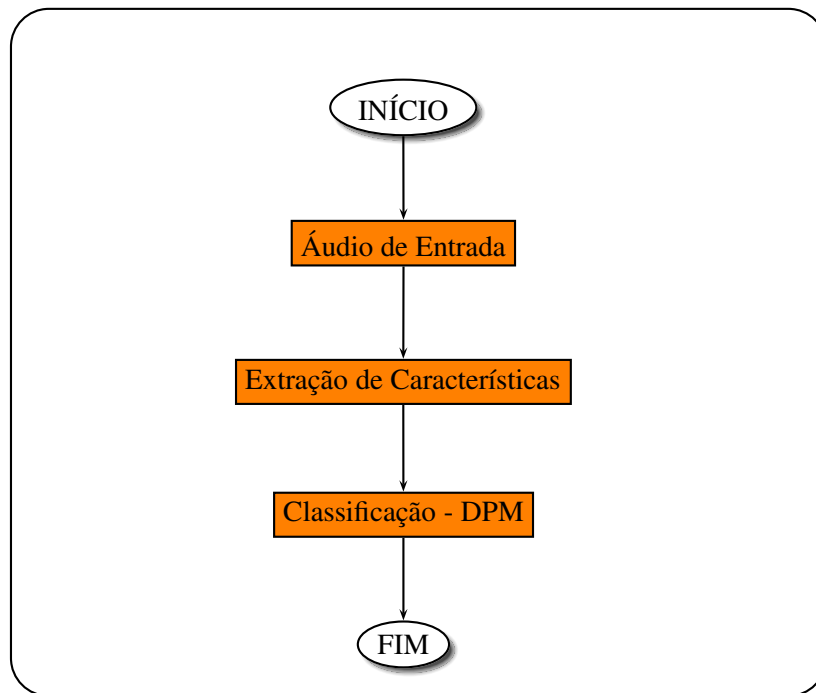


Figura 3.1 – Representação esquemática do processo de classificação: arquitetura elementar do sistema proposto.

3.2 Etapa de Extração de Características

A geração do vetor de características possui vários passos em comum, descritos a seguir. Primeiramente, o cabeçalho do arquivo WAV é removido, por meio de uma rotina desenvolvida em linguagem C/C++, restando apenas os valores das amostras do áudio. Em seguida, para cada música, independente do gênero, o processo de extração produz o vetor de características representante dos dados brutos.

O sistema projetado é baseado em um vetor de 1637 parâmetros para cada sinal musical, formado da seguinte maneira:

- porcentagens de energia das duas metades do sinal em relação à energia do sinal inteiro [total: 2 parâmetros];
- porcentagens de energia de cada quarto do sinal em relação à energia do sinal inteiro [total: 4 parâmetros];

- porcentagens de energia de cada oitavo do sinal em relação à energia do sinal inteiro [total: 8 parâmetros];
- porcentagens de energia de cada dezesseis avos do sinal em relação à energia do sinal inteiro [total: 16 parâmetros];
- porcentagens de energia de cada trinta e dois avos do sinal em relação à energia do sinal inteiro [total: 32 parâmetros];
- porcentagens de energia das 25 faixas de frequência da escala Bark do sinal em relação à energia do sinal inteiro [total: 25 parâmetros];
- porcentagens de energia das 25 faixas de frequência da escala Bark de cada uma das metades do sinal em relação à energia do sinal inteiro [total: 50 parâmetros];
- porcentagens de energia das 25 faixas de frequência da escala Bark de cada um dos quartos do sinal em relação à energia do sinal inteiro [total: 100 parâmetros];
- porcentagens de energia das 25 faixas de frequência da escala Bark de cada um dos oitavos do sinal em relação à energia do sinal inteiro [total: 200 parâmetros];
- porcentagens de energia das 25 faixas de frequência da escala Bark de cada um dos dezesseis avos do sinal em relação à energia do sinal inteiro [total: 400 parâmetros];
- porcentagens de energia das 25 faixas de frequência da escala Bark de cada um dos trinta e dois avos do sinal em relação à energia do sinal inteiro [total: 800 parâmetros].

O agrupamento de cada um dos parâmetros resulta no vetor de características representante de cada sinal musical. Conforme será visto adiante, não necessariamente utilizam-se todas as características para as classificações.

No vetor de características, as porcentagens de energia de cada segmento do sinal temporal têm o objetivo de detalhar, de uma escala mais grosseira até uma escala mais fina, isto é de duas até trinta e duas partes, como a concentração de energia varia ao longo da música. Tanto

de modo intuitivo, como por meio de resultados anteriores [47], este procedimento mostra-se propício. Para uma música pertencente a um estilo que contenha variações mais bruscas no conteúdo, por exemplo, existe uma tendência de que as concentrações de energia em uma escala mais fina mostrar-se-ão mais variadas do que para uma música de natureza mais branda. O mesmo ocorre com as concentrações energéticas no domínio da frequência. Assim, justifica-se a escolha dos parâmetros, isto é, das características, em questão.

3.3 Etapa de Classificação

Nesta etapa, será então utilizado um classificador neural chamado Máquina Paraconsistente Discriminativa (*Discriminative Paraconsistent Machine* - DPM), conforme explicado anteriormente. De acordo com Guido et al [1], essa ferramenta é uma combinação da modelagem discriminativa e da lógica paraconsistente, que são utilizadas para o reconhecimento de padrões, podendo ser considerada como uma hipótese de análise que tem o seu grau de confiança e o seu grau de descrédito

O algoritmo 1, apresentado a seguir, descreve o processo de treinamento do sistema baseado na DPM, necessário antes do seu efetivo uso, consistindo-se, este treinamento, em uma abordagem supervisionada [48]. Por outro lado, o algoritmo 2, apresentado na sequência do 1, descreve o procedimento para uso do sistema previamente treinado.

=====

===== **ALGORITMO 1: Treinamento da DPM** =====

=====

- **INÍCIO**
- **PASSO 1:** seleciona-se, aleatoriamente, o conjunto de sinais musicais de cada estilo a serem utilizados para treinamento do sistema. Tais sinais correspondem a uma determinada porcentagem do montante total de músicas disponíveis na base de dados, conforme descrito no próximo capítulo. Para cada sinal, obtém-se o vetor de características corres-

pondente;

- **PASSO 2:** instanciam-se seis DPMs com X entradas e T neurônios na camada discriminativa. T consiste no número total de exemplos de treinamento e X no número total de parâmetros, ou características, utilizadas. T pode variar de 1 até 1637, conforme discutido no Capítulo 4;
- **PASSO 3:** consideram-se duas classes para cada uma das seis DPMs. Para a i -ésima DPM, ($1 \leq i \leq 6$), adota-se o valor 1 como saída para as entradas correspondentes ao i -ésimo estilo e -1 para as entradas correspondentes aos demais estilos. Assim, tem-se:

– **DPM 1:**

- * destinada a avaliar se o estilo a ser testado posteriormente trata-se de **bolero (DPM_bolero)**;
- * primeiras $X/6$ entradas correspondentes a **boleros**;
- * próximas $5X/6$ entradas correspondentes a **sertanejos, salsas, forrós, bossa nova e jazz**, respectivamente;
- * primeiras $X/6$ saídas com *label* 1;
- * próximas $5X/6$ saídas com *label* -1.

– **DPM 2:**

- * destinada a avaliar se o estilo a ser testado posteriormente trata-se de **sertanejo (DPM_sertanejo)**;
- * primeiras $X/6$ entradas correspondentes a **sertanejo**;
- * próximas $5X/6$ entradas correspondentes a **boleros, salsas, forrós, bossa nova e jazz**, respectivamente;
- * primeiras $X/6$ saídas com *label* 1;
- * próximas $5X/6$ saídas com *label* -1.

– **DPM 3:**

- * destinada a avaliar se o estilo a ser testado posteriormente trata-se de **salsa (DPM_salsa)**;

- * primeiras $X/6$ entradas correspondentes a **salsa**;
- * próximas $5X/6$ entradas correspondentes a **boleros, sertanejos, forrós, bossa nova e jazz**, respectivamente;
- * primeiras $X/6$ saídas com *label 1*;
- * próximas $5X/6$ saídas com *label -1*.

– **DPM 4:**

- * destinada a avaliar se o estilo a ser testado posteriormente trata-se de **forró (DPM_forró)**;
- * primeiras $X/6$ entradas correspondentes a **forró**;
- * próximas $5X/6$ entradas correspondentes a **boleros, sertanejos, salsas, bossa nova e jazz**, respectivamente;
- * primeiras $X/6$ saídas com *label 1*;
- * próximas $5X/6$ saídas com *label -1*.

– **DPM 5:**

- * destinada a avaliar se o estilo a ser testado posteriormente trata-se de **bossa nova (DPM_bossa nova)**;
- * primeiras $X/6$ entradas correspondentes a **bossa nova**;
- * próximas $5X/6$ entradas correspondentes a **boleros, sertanejos, salsas, forrós e jazz**, respectivamente;
- * primeiras $X/6$ saídas com *label 1*;
- * próximas $5X/6$ saídas com *label -1*.

– **DPM 6:**

- * destinada a avaliar se o estilo a ser testado posteriormente trata-se de **jazz (DPM_jazz)**;
- * primeiras $X/6$ entradas correspondentes a **jazz**;
- * próximas $5X/6$ entradas correspondentes a **boleros, sertanejos, salsas, forrós e bossa nova**, respectivamente;

- * primeiras $X/6$ saídas com *label* 1;
- * próximas $5X/6$ saídas com *label* -1.

- **PASSO 4:** para cada uma das seis DPMs, obtem-se T sistemas lineares que são resolvidos, produzindo os pesos das camadas discriminativa e de mistura, com auxílio das equações (2.6) e (2.7), devidamente explicadas no Capítulo 2;
- **FIM**

=====

===== **ALGORITMO 2: Uso do Sistema Treinado** =====

=====

- **INÍCIO**
- **PASSO 1:** os sinais não utilizados para o treinamento das DPMs são adotados para os testes. Para cada sinal, obtém-se o vetor de características correspondente;
- **PASSO 2:** de posse das seis DPMs treinadas anteriormente, aplicam-se, simultaneamente em todas elas, os parâmetros do sinal musical sob teste, obtendo-se as saídas $[G1, G2]$ de cada uma delas, possibilitando as localizações no plano paraconsistente;
- **PASSO 3:** cada um dos pontos $[G1, G2]$ é plotado em um plano paraconsistente. São possíveis, neste passo, interpretações diversas, conforme descrito no próximo capítulo. Com base nelas, consolidar-se-á este algoritmo frente os resultados apresentados.
- **FIM**

=====

Com base na variação da quantidade de parâmetros utilizados, entre 1 e 1637, na escolha de quais parâmetros são utilizados, na escolha das porcentagens para treinamento e teste do sistema, assim como nas diversas variações da composição dos conjuntos de treinamento e de

teste, possibilitando uma validação cruzada (*cross-validation*), inúmeros testes são possíveis para verificar a acurácia e viabilidade do procedimento proposto. O próximo capítulo descreve tais testes e os resultados correspondentes.

Todo o sistema de extração de características proposto foi implementado em linguagem C/C++ [49], em um computador *Apple Macbook* com processador Intel i5. Tanto a extração das características quanto a DPM estão caracterizadas como sendo algoritmos de baixo custo computacional, com ordens de complexidade lineares em relação aos tamanhos dos sinais musicais digitalizados [50].

Capítulo 4

Testes e Resultados

Para a obtenção dos resultados da etapa de testes, com o uso da técnica proposta, foi desenvolvido um algoritmo para avaliar qual é a melhor combinação de parâmetros de entrada e quantidade destes. Essa avaliação foi realizada para comparar tanto os parâmetros que, combinados, forneceriam melhores resultados, como a quantidade de parâmetros ideal.

Vários testes foram realizados, com diferentes tipos de vetores de características. Para esses testes, foi utilizada a base de dados descrita no Capítulo 3, com 420 músicas, subdivididas em uma coleção de 6 estilos, contendo 70 títulos de cada estilo, do qual foram extraídos 1637 parâmetros para cada título.

Foram instanciados DPMs com a finalidade de analisar os resultados obtidos e localizar as saídas de cada classificação no plano paraconsistente, conforme descrito no Capítulo 2.

Entre os testes realizados, foram utilizados, aleatoriamente, 80% das músicas para treino e 20% restante para testes, em cada estilo, obtendo-se 336 músicas para treino e 84 músicas para testes. Em seguida foram utilizados 70% das músicas para treino e 30% restante para teste, em cada estilo, até atingir 10% das músicas para treino e 90% restante para teste, em cada estilo, obtendo-se 42 músicas para treino e 378 músicas para teste, onde foi obtido o melhor resultado.

Outras avaliações foram realizadas, com diferentes números de parâmetros nos vetores de

Tabela 4.1 – Resultados utilizando 802 parâmetros, 10% da base para treinamento e 90% para testes no reconhecimento da músicas do estilo bolero.

Classificação	Bolero	Bossa Nova	Forró	Jazz	Salsa	Sertanejo
<i>Verdadeiro</i>	19	3	4	5	1	3
<i>Falso</i>	12	37	38	34	51	38
<i>Contradição</i>	15	8	5	13	6	12
<i>Indeterminação</i>	17	15	16	11	5	10

entrada da rede. O primeiro grupo, com os 1637 parâmetros, composto com 62 energias temporais e 1575 energias no domínio da frequência, o segundo grupo de teste com 82 parâmetros, composto com as 32 últimas energias temporais e os demais com as 50 primeiras energias no domínio da frequência e um terceiro grupo de teste contendo 802 parâmetros, onde os 2 primeiros parâmetros foram compostos das 2 primeiras energias temporais e os demais com as 800 últimas energias no domínio da frequência.

Considerando os resultados obtidos, o melhor reconhecimento encontrado foi o de 10% das músicas para treino e 90% restante para testes, contendo 802 parâmetros, onde os 2 primeiros parâmetros foram compostos das 2 primeiras energias temporais e o restante com energias no domínio da frequência.

Na Tabela 4.1 foram apresentados os resultados referentes a este grupo de teste, para reconhecimento de músicas com estilo de bolero (DPM_bolero) e a Figura 4.1 apresenta graficamente, no plano paraconsistente, os respectivos resultados do teste citado.

Considerando os resultados obtidos, de acordo com a interpretação no plano paraconsistente, para a saída da DPM_bolero, o melhor resultado é aquele que se aproxima das coordenadas $[1; 0]$ para reconhecimento de bolero, e $[-1; 0]$ para os demais gêneros. Quando o resultado se aproxima da coordenada $[0, -1]$, como ocorreu em alguns casos, implica que a rede está indicando uma situação de entrada que corresponde a ambos os gêneros, sendo mais provável de causar uma indefinição. As Tabelas 4.2 à 4.6 apresentam testes realizados com 802 parâmetros dos demais gêneros musicais e seus gráficos no plano paraconsistente estão sendo mostrado pelas Figura 4.2 à 4.6.




Figura 4.1 – DPM_bolero (Tabela 4.1).

Tabela 4.2 – Resultados utilizando 802 parâmetros, 10% da base para treinamento e 90% para testes no reconhecimento da músicas do estilo bossa nova.

Classificação	Bolero	Bossa Nova	Forró	Jazz	Salsa	Sertanejo
<i>Verdadeiro</i>	8	11	1	6	1	5
<i>Falso</i>	34	13	52	31	36	41
<i>Contradição</i>	12	23	7	10	10	9
<i>Indeterminação</i>	9	16	3	16	16	8

Tabela 4.3 – Resultados utilizando 802 parâmetros, 10% da base para treinamento e 90% para testes no reconhecimento da músicas do estilo forró.

Classificação	Bolero	Bossa Nova	Forró	Jazz	Salsa	Sertanejo
<i>Verdadeiro</i>	11	12	21	17	16	15
<i>Falso</i>	25	24	9	18	18	16
<i>Contradição</i>	19	15	17	8	8	16
<i>Indeterminação</i>	8	12	16	20	21	16

Tabela 4.4 – Resultados utilizando 802 parâmetros, 10% da base para treinamento e 90% para testes no reconhecimento da músicas do estilo jazz.

Classificação	Bolero	Bossa Nova	Forró	Jazz	Salsa	Sertanejo
<i>Verdadeiro</i>	0	2	1	16	2	2
<i>Falso</i>	38	39	38	19	42	48
<i>Contradição</i>	22	16	20	13	19	13
<i>Indeterminação</i>	3	6	4	15	0	0




Figura 4.2 – DPM_bossa nova (Tabela 4.2).




Figura 4.3 – DPM_forró (Tabela 4.3).




Figura 4.4 – DPM_jazz (Tabela 4.4).

Tabela 4.5 – Resultados utilizando 802 parâmetros, 10% da base para treinamento e 90% para testes no reconhecimento da músicas do estilo salsa.

Classificação	Bolero	Bossa Nova	Forró	Jazz	Salsa	Sertanejo
<i>Verdadeiro</i>	4	10	3	9	20	2
<i>Falso</i>	32	30	45	22	20	37
<i>Contradição</i>	17	17	14	23	9	17
<i>Indeterminação</i>	10	6	1	9	14	7

Tabela 4.6 – Resultados utilizando 802 parâmetros, 10% da base para treinamento e 90% para testes no reconhecimento da músicas do estilo sertanejo.

Classificação	Bolero	Bossa Nova	Forró	Jazz	Salsa	Sertanejo
<i>Verdadeiro</i>	6	4	2	4	1	23
<i>Falso</i>	32	29	39	29	41	14
<i>Contradição</i>	14	17	16	18	17	18
<i>Indeterminação</i>	11	13	6	12	5	9

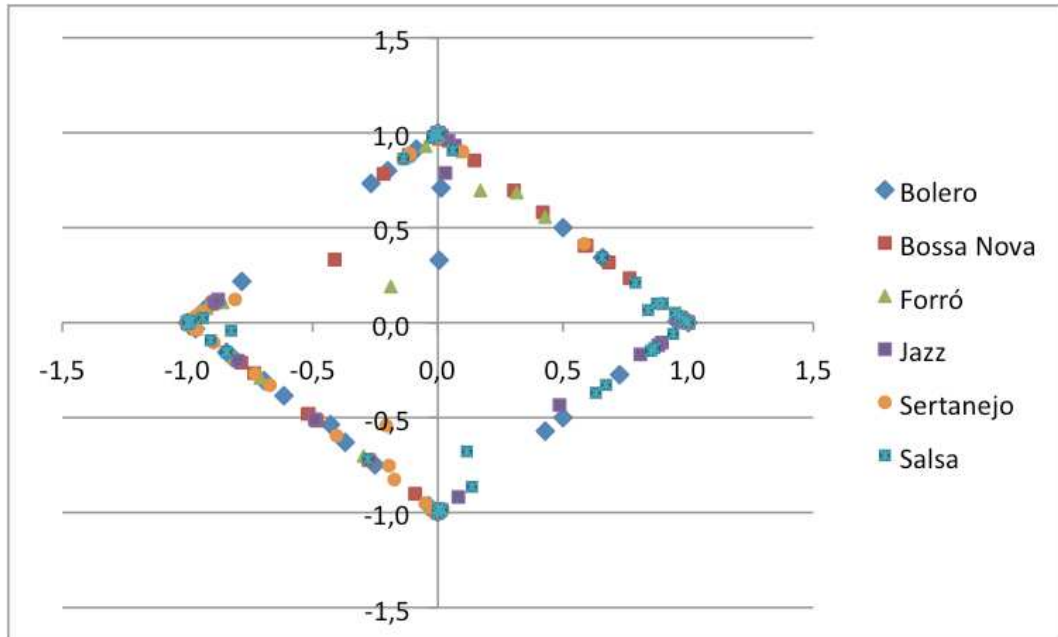


Figura 4.5 – DPM_salsa (Tabela 4.5).




Figura 4.6 – DPM_sertanejo (Tabela 4.6).

Com relação aos resultados apresentados nas Tabelas de 4.1 a 4.6, nota-se uma boa classificação de verdadeiro do gênero treinado pela DPM em relação aos demais gêneros. Na DPM_bolero e DPM_bossa nova, obtiveram uma grande quantidade de classificação falso para os demais gêneros, isto também apresenta um resultado bastante relevante na classificação dos gêneros.

Os casos em que houveram resultados de indefinição ou contradição, se deve ao grande grau de misturas de gêneros que temos atualmente em nossas músicas. Como a música não é um fenômeno estanque, cada músico é constantemente influenciado por outros gêneros, por isso considera-se que a classificação seja correspondente em ambas as classes.

Para cada um dos resultados obtidos, foi possível localizar a saída da DPM no plano paraconsistente, conforme exemplificado no Capítulo 2. Isto fez com que fosse possível obter, não somente uma resposta do tipo “verdadeiro” ou “falso”; dependendo da música, o nível de verdadeiro ou falso estava localizado na saída da DPM.

Na hipótese de uma certa saída da DPM estar relativamente afastada dos vértices esquerdo ou direito, entende-se que a música sob análise não possui um estilo puro, mas sim, uma composição de estilos. Em tais casos, todas as classificações multi-classes foram condizentes com as opiniões dos especialistas em músicas que forneceram a base de dados. Assim, entende-se que, considerando a totalidade das músicas testadas, a técnica proposta classificou coerentemente 100% dos casos.

Capítulo 5

Conclusões

Uma boa classificação de gêneros musicais facilita a distinção e compreensão das obras que fazem parte da história da música. No entanto, a variedade de gêneros e estilos musicais é tão grande e complexa que se faz difícil classificá-los claramente. Além da diversidade de gêneros, existe uma infinidade de sub-gêneros, nascidos da prática individual de cantores e compositores populares que são lançados seguidamente pela mídia, para a conquista das massas populares.

Apesar dessas dificuldades, esse trabalho alcançou a sua proposta de atingir um nível considerável de reconhecimento, contribuindo como uma ferramenta de apoio ao profissional que perde grande parte do seu tempo para realizar manualmente as classificações de gêneros musicais. A implementação do algoritmo que associa uma técnica baseada em aprendizado de máquina com LPA, promovendo uma classificação adequada para o reconhecimento automático de gêneros musicais, proposto em uma plataforma de computação, garante uma velocidade de aplicação do algoritmo, que irá proporcionar uma classificação mais rápida e eficiente. Além disso, caracteriza-se uma contribuição original ao estado-da-arte na área, que consiste no uso da LPA, implementada com base na DPM, para fins de MGC.

Baseado nos objetivos de classificação referida e após uma revisão bibliográfica sobre parâmetros utilizados nos conceitos fundamentais para classificação de gêneros musicais, foi dada especial importância às características relevantes encontradas na análise das energias que varia

ao longo da música, trabalhando com energia temporal e energia no domínio da frequência.

Durante os testes, foi possível observar que a lógica utilizada foi eficiente, justamente por possibilitar a combinação e efetiva avaliação da qualidade dos parâmetros, pois em algumas combinações o nível atingido comprometeria a certeza do resultado ou acusaria um nível alto de contradição com relação ao apontamento do profissional. É importante ressaltar que a análise da localização da saída da DPM no plano paraconsistente possibilitou uma indicação adicional àquela obtida com outros classificadores, conforme descrito anteriormente. Destaca-se, ainda, a extrema capacidade de generalização da DPM, pois apenas 10% da base de dados foi utilizada durante os testes para treinar o classificador. Apenas para fins de viabilizar uma classificação binária, possibilitando assim estabelecer comparações elementares, utilizou-se um limiar no eixo x, para os quais resultados maiores que (0,0) foram considerados “verdadeiro” e abaixo desse limiar, “falso”. Com base nessa abordagem, registrou-se uma acurácia de 72%.

É fundamental observar que as comparações constante neste documento, particularmente entre os resultados obtidos com a DPM e os obtidos com outros classificadores tais como SVMs, são de propósito secundário. Isto se deve ao fato de que a DPM foi criada para lidar com características, tais como inconsistências e indefinições, para as quais outros classificadores não podem manipular com perfeição, pois não foram criados para isso. Como exemplo, basta notar que nenhum outro classificador existente na literatura tem condições de localizar uma determinada entrada (música, no caso deste trabalho) no plano paraconsistente, como mostrado anteriormente.

Particularmente, SVMs são ótimas para distinções binárias entre classes. Por outro lado, perceptrons [3], funções de base radial [3], entre outros classificadores, podem ser interpretados como funções de transferência que recebem parâmetros como entrada e produzem um ou mais valores de saída que são utilizados como rótulos para as classificações. De qualquer forma, em ambos os casos, tais classificadores não incorporam, nem mesmo minimamente, as versatilidades da LPA, que existem na DPM.

Como trabalhos futuros, pode-se utilizar técnicas diferentes para extração dos parâmetros, com por exemplo, timbre, ritmo e pitch, mantendo o mesmo classificador DPM.

Referências

- [1] GUIDO, R. C., BARBON, S., SOLGON, R., PAULO, K. C.S., RODRIGUES, L. C., SILVA, I. N., ESCOLA, J. pp. L. Introducing the Discriminative Paraconsistent Machine (DPM). *Information Sciences*, v.221, 2012.
- [2] COSTA, N.C.A., KRAUSE, D., BUENO, O. Paraconsistent Logics and Paraconsistency. *In: Handbook of the Philosophy of Science*, pp. 791-911, 2007.
- [3] SILVA FILHO, J.I. Métodos de Aplicações da Lógica Paraconsistente Anotada de Anotação com Dois Valores LPA 2v com Construção de Algoritmo e Implementação de Circuitos Eletrônicos. *Tese de Doutorado*. Escola Politécnica da USP. 252p., 1999.
- [4] HUHN, J.; HULLERMEIER, E. FR3: A Fuzzy Rule Learner for Inducing Reliable Classifiers. *IEEE Transactions on Fuzzy Systems*, n. 17, pp. 138-149, 2009.
- [5] SILVA FILHO, J.I., ABE, J.M. Fundamentos das redes neurais artificiais paraconsistente. São Paulo: *Arte-Ciência*, 2000.
- [6] LEME NETO, C. M., VENSON, N. Lógica paraconsistente. *Universidade de Santa Catarina*, 2002.
- [7] HAYKIN, S. *Neural Networks and Learning Machines*. 3 ed. *New Jersey: Prentice-Hall*, 2008.
- [8] TIPPING, M.E. Sparse Baysean learning and the relevance vector machine. *Journal of Machine Learning Research*. v.1, pp.211-244, 2001.

- [9] TORRALBA, A., MURPHY, K.P., FREEMAN, W.T. Sharing features: efficient boosting procedures for multiclass object detection. *In: Proceedings of IEEE Computer Vision and Pattern Recognition Conference (IEEE CVPR)*, v.1, pp. 762-769, 2004.
- [10] FAN, X. Efficient multiclass object detection by a hierarchy of classifiers. *In: Proceeding of IEEE Computer Vision and Pattern Recognition (IEEE CVPR)*, v.1, pp. 716-723, 2005.
- [11] PLATT, J. Probabilistic Outputs for Support Vector Machines and Comparisons to Regularized Likelihood Methods, in Advances. *In: Large-Margin Classifiers*. pp. 61-74, 2000.
- [12] SILVA, I. N., SPATTI, D. H., FLAUZINO, R. A. Redes Neurais Artificiais para engenharia e ciências aplicadas. São Paulo: *Artliber*, 2010.
- [13] NANNI, L. et. al. Combining visual and acoustic features for music genre classification. *Expert Systems with Applications*, v.45, pp. 108-117, 2016.
- [14] CHAPANERI, S.; LOPES, R.; JAYASWAL, D. Evaluation of Music Features for PUK Kernel Based Genre Classification. *Procedia Computer Science*, v.45, pp. 186-196, 2015.
- [15] HUANG, Y.F. et. al. Music genre classification based on local feature selection using a self-adaptive harmony search algorithm. *Data & Knowledge Engineering*, v.92, pp.60-76, 2014.
- [16] DUDA, R.O., HART, pp. E., STORK, D. G. Pattern Classification. 2ed. New York: *John Wiley and Sons*, 2001.
- [17] DANNENBERG, R. B., THOM, B., WATSON, D. A Machine Learning Approach to Musical Style Recognition. *In: Proceedings of the International Computer Music Conference*, pp. 344-347, 1997.
- [18] TZANETAKIS, G., COOK, pp. Musical Genre Classification of Audio Signals. *IEEE Transactions on Speech and Audio Processing*, v. 10, n. 5, pp. 293-3, 2002.
- [19] GOLUB, S. Classifying Recorded Music. *Dissertação de Mestrado*. University of Edinburgh.129p., 2000.

- [20] GOULART, A.J.H. Classificação automática de gênero musical baseada em entropia e fractais. *Dissertação de Mestrado em Ciências*. Escola de Engenharia de São Carlos, USP, São Carlos. 142p., 2012.
- [21] MARTIN, K., KIM, Y. Musical instrument identification: A pattern recognition approach. *In: Proceedings of the 136 th meeting of the Acoustical Society of America - ASA*, 1998.
- [22] SILLA, C. N., KAESTNER, C. A. A., KOERICH, A. L. Automatic Music Genre Classification Using Ensemble of Classifiers. *In: IEEE International Conference on Systems, Man and Cybernetics*. Montreal: ICSMC, pp. 1687-1692, 2007
- [23] DA COSTA, N.C.A., ABE, J.M., SUBRAHMANIAN, V.S. Remarks on annotated logic. *Zeitschrift f. math. Logik und Grundlagen d. Math.* 37, pp. 561-570, 1991.
- [24] RICH, E., KNIGHT, K. Inteligência Artificial. 2ed. São Paulo: *Makron Books*, 1994.
- [25] DU, K-L.; SWAMY, M.N.S. Neural Networks and Statistical Learning. *Springer*, 2014.
- [26] NEDJAHAN, N.; FRANCA, F.M.G.; GREGORIO M.D.; Mourelle, L.M. Weightless Neural Systems. *Neurocomputing*, v. 183, pp.1-2, 2016.
- [27] DUDA, R.O.; Hart, pp.E.; Stork, D.G. Pattern Classification. 2.ed. *Wiley-Interscience*, 2000.
- [28] HULLERMEIER, E., BRINKER, K. Learning Valued Preference Structures for Solving Classification Problems. *Fuzzy Sets and Systems*, v. 159, n. 18, pp. 2337-2352, 2008.
- [29] DEL COZ, J., DIEZ, J. BAHAMONDE, A. Learning Nondeterministic Classifiers. *Journal of Machine Learning Research*, v. 10, pp. 2273-2293, 2009.
- [30] PRIEST, G. Paraconsistency and Dialetheism. *In: Handbook of the History of Logic*, v. 8. Amsterdam: North Holland, pp. 129-204, 2007.
- [31] ABE, J.M., PRADO, J.C.A., NAKAMATSU, K. Paraconsistent Artificial Neural Network: applicability in computer analysis of speech productions. *Lecture Notes in Computer Science*, v. 4252, pp. 844-850, 2006.

- [32] BROWN, B. On Paraconsistency. *In: A Companion to Philosophical Logic*. Oxford: Blackwell, pp. 628-650, 2002.
- [33] ÁVILA, B. C. Uma Abordagem Paraconsistente Baseada em Lógica Evidencial para Tratar de Exceções em Sistemas de Frames com Múltipla Herança. *Tese de Doutorado, Escola Politécnica da Universidade de São Paulo*. São Paulo, 1996.
- [34] BARBON Jr, S. Identificação de patologias na laringe com base na Discriminative Paraconsistent Machine. *Tese de Doutorado em Ciências. Instituto de Física de São Carlos, USP*. São Carlos. 94p., 2011.
- [35] HANSEN, pp. C., PEREYRA, V., SCHERER, G. Least Squares Data Fitting with Applications. *Johns Hopkins University Press*: Baltimore, 2013.
- [36] BOSSI, M.; GGOLDBERG, E. Introduction to Digital Audio Coding and Standards. *Kluwer*, 2003.
- [37] RABINER, L. R., SCHAFER, R. W. Digital Processing of Speech Signals. *Upper Saddle River, New Jersey: Prentice Hall*, 1978.
- [38] XU, J. et. al. A Multi-label Feature Extraction Algorithm via Maximizing Feature Variance and Feature-label Dependence Simultaneously. *Knowledge-based System*, v.98, pp.172-184, 2016.
- [39] YIGING, L. et. al. Adapted Ensemble Classification Algorithm Based on Multiple Classification Systems and Feature Selection for Classifying Multi-class Unbalanced Data. *Knowledge-based System*, v.94, pp.88-104, 2016.
- [40] GARCIA, S.; LEUENGO J.; HERRERA, F. Tutorial on Practical Tips of the Most Influential Data Preprocessing Algorithm in Data Mining. *Knowledge-based System*, v.98, pp.1-29, 2016.
- [41] MENG, Y.; LIANG, J.; QIAN, Y. Comparison Study of Orthonormal Representations of Functional Data in Classification. *Knowledge-based System*, v.97, pp.224-236, 2016.

- [42] ALESSIO, S.M. Digital Signal Processing and Spectral Analysis for Scientists: Concepts and Applications. 1.ed., *Springer*, 2016.
- [43] OPPENHEIM, A. V.; Schafer, R.W. Discrete-time Signal Processing. 3.ed. *Prentice-Hall*, 2009.
- [44] HAYKIN, S.; Veen, B.V. Signals and Systems, 2.ed. *Wiley*, 2002.
- [45] GUIDO, R.C. A Tutorial on Signal Energy and its Applications. *Neurocomputing*, v. 179, pp.264-282, 2016.
- [46] DELLER Jr. R., PROAKIS, J. G., HANSEN, J. H. L. Discrete-time Processing of Speech Signals. *New York: Macmillan Publishing Co.*, 1993.
- [47] GOULART A. J. H., MACIEL C. D., GUIDO R. C., PAULO K. C. S., Silva I. N. Music Genre Classification based on entropy and fractal lacunarity. *In: IEEE International Symposium on Multimedia*, pp. 533-536, 2011
- [48] RUSSEL, S., NORVIG, P. Artificial Intelligence: A Modern Approach. *New Jersey: Prentice Hall*, 1995.
- [49] STROUSTRUP, B. The C++ Programming Language, 4. ed. *Addison-Wesley Professional*, 2013.
- [50] ARORA, S. Computational Complexity: a modern approach. *Cambridge University Press*, 2009.

Apêndice I - Publicações durante o doutorado

Durante o curso de doutorado do autor, os seguintes artigos foram publicados:

- GOULART, A.J.H. ; MACIEL, C.D. ; GUIDO, R.C. ; PAULO, K.C.S. ; SILVA, I.N. Music Genre Classification Based on Entropy and Fractal Lacunarity. *In: IEEE International Symposium on Multimedia (ISM)*, pp. 533 - 536, 2011.
- GUIDO, R. C., BARBOSA, S. J., PAULO, K. C. S., SOLGON, R. D., RODRIGUES, L. C., SILVA, I. N., ESCOLA, J. P. L. Introducing the Discriminative Paraconsistent Machine (DPM). *Information Sciences*, pp. 389-402, v.221, 2012.
- PAULO, K. C. S., BASSI, R. D. S., DELORME, A. L., GUIDO, R. C., SILVA, I. N. Music Genre Classification Based on Paraconsistency. *In: 2nd International Conference on Advanced Education Technology and Management Science, AETMS*, pp. 427-431, 2014.
- SOLGON, R. D. S., PAULO, K. C. S., DEZANI, H., GUIDO, R. C., SILVA, I. N., MARRANCHELOO, N. . Pattern recognition with applications to pre-diagnosis of pathologies in the Vocal Tract. *In: 2nd International Conference on Advanced Education Technology and Management Science, AETMS*, pp. 20-23, 2014.
- IGAWA, R. A., BARBON, S. J., PAULO, K. C. S., KIDO, G. S., GUIDO, R. C., PROENÇA, M. L. J., SILVA, I. N. Account classification in online social networks with LBCA and wavelets. *Information Sciences*, pp. 72-83, v.332, 2016.