

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**

**DEPARTAMENTO DE COMPUTAÇÃO**

**CURSO DE ENGENHARIA DE COMPUTAÇÃO**

**THIAGO LUCAS FERREIRA EVANGELISTA**

**CLASSIFICAÇÃO HIERÁRQUICA DE ESPÉCIES DE PÁSSAROS UTILIZANDO  
SEUS CANTOS**

**TRABALHO DE CONCLUSÃO DE CURSO**

**CORNÉLIO PROCÓPIO**

**2015**

**THIAGO LUCAS FERREIRA EVANGELISTA**

**CLASSIFICAÇÃO HIERÁRQUICA DE ESPÉCIES DE PÁSSAROS  
UTILIZANDO SEUS CANTOS**

Trabalho de Conclusão de Curso apresentado à disciplina de Trabalho de Conclusão de Curso 2, do curso de Engenharia de Computação, da Universidade Tecnológica Federal do Paraná como requisito para obtenção do título de Bacharel em Engenharia de Computação.

Orientador: Prof. Dr. Carlos N. Silla Jr.

**CORNÉLIO PROCÓPIO**

**2015**

Dedico este trabalho a Deus, à minha família e a minha namorada.

## **AGRADECIMENTOS**

Agradeço primeira mente a Deus que me deu forças durante essa longa jornada

“Quando você quer alguma coisa, todo o universo  
conspira para que você realize o seu desejo”.

(Paulo Coelho)

## RESUMO

EVANGELISTA, Thiago. **Classificação Hierárquica de Pássaros Utilizando Seus Cantos**. 79 f. Trabalho de Conclusão de Curso – Curso de Engenharia de Computação, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2015.

Este trabalho teve como objetivo realizar uma análise comparativa entre a abordagem de classificação hierárquica e abordagem de classificação plana, para a tarefa de classificação automática de espécie de pássaros utilizando seus cantos. Além da análise comparativa já citada, este trabalho analisou o efeito do pré-processamento de segmentação na melhoria da tarefa de classificação proposta para ambas abordagens. Para a realização dos experimentos foi utilizada a base de dados da competição CLEF 2014, contendo 501 espécies distintas distribuídas em 9668 arquivos de áudio e 9688 arquivos XML contendo informações sobre os áudios (metadados). Esta base foi clonada e deu origem a outras três bases, sendo a primeira a base que passou pelo processo de segmentação, e a segunda e terceira sendo cópias da base original e segmentada reorganizadas de modo que respeitasse a uma hierarquia de Família, Gênero e Espécie. Nos experimentos foram utilizados quatro classificadores (J48, KNN, Naive Bayes e SVM) distribuídos em três cenários comparativos com uma comparação geral adicional. Através dos resultados concluiu-se que a abordagem de classificação hierárquica obtém uma melhor performance de classificação do que a abordagem de classificação plana, somente para o classificador SVM. Além disso, experimentos unindo a abordagem de classificação hierárquica ao pré-processamento de segmentação, resultaram uma performance superior do que a classificação hierárquica sem o uso do pré-processamento, entretanto, quando comparado a classificação plana utilizando a técnica de pré-processamento à classificação hierárquica, obteve-se um efeito positivo em apenas um dos quatro classificadores utilizados.

**Palavras-chave:** Identificação de espécies de pássaros. Reconhecimento de padrões. Classificação hierárquica. Processamento de Sinais.

## ABSTRACT

EVANGELISTA, Thiago. **Classificação Hierárquica de Pássaros Utilizando Seus Cantos**. 79 f. Trabalho de Conclusão de Curso – Curso de Engenharia de Computação, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2015.

This work aims to present an analytical comparison between the hierarchical classification approach and the plan classification approach, in the automatic bird species classification task. Furthermore, this work analyzed the effect of a segmentation pre-processing technique in the pursuit of the proposed task for both approaches. To conduct the experiments, it was used a database from the CLEF 2014 challenge, with 501 distinct species distributed in 9688 audio files with one meta-data XML file per audio containing information. This database was cloned and rearranged respecting a hierarchy of Family, Genus and Species by using MatLab® scripts. In the experiments it was used four classifiers (J48, KNN, Naïve Bayes and SVM) distributed in three comparative scenarios with one more general comparison. The results suggest that the hierarchical classification approach has better results than the plan classification approach only for the SVM classifier. Moreover, experiments combining the hierarchical classification approach with the segmentation preprocessing technique obtained a superior performance; however, when compared with flat classification using the segmentation preprocessing technique the results only were positive in one of the four classifiers.

**Keywords:** Bird species identification. Pattern recognition. Hierarchical classification. Signal Processing.

## LISTA DE FIGURAS

Figura 1 - A energia do sinal. ....	18
Figura 2 - Exemplo de uma sequência de energia para um sinal de áudio.....	18
<b>Figura 3- Exemplo de uma sequência de centroide de espectro.....</b>	<b>19</b>
Figura 4 – Aplicação do Medfilt1. ....	21
Figura 5 - Exemplo Naive Bayes .....	26
Figura 6 - Representação KNN .....	27
Figura 7 - Exemplo árvore de decisão.....	28
Figura 8 - Ilustração SVM.....	29
Figura 9 - Classificação plana. ....	30
Figura 10 – As três abordagens do modelo local de classificação. ....	31
Figura 11 - Classificação Global.....	32
Figura 12 - Exemplo Base Validação Cruzada.....	32
Figura 13 - Matriz de Confusão .....	33
Figura 14 - Exemplo de Arquivo ARFF.....	38
Figura 15 – Modelo de um sinal a ser segmentado.....	40
Figura 16 – Exemplo hierarquia de diretórios do Windows. ....	40
Figura 17 – Exemplo hierarquia de diretórios do Windows em formato de árvore. ...	41
Figura 18 - Exemplo Resultado Weka.....	43
Figura 19 - Gráfico Resultados Cenário I .....	46
Figura 20 - Gráfico <i>F-Measure</i> Cenário II.....	49
Figura 21 - Comparativo Plano x Hierárquico.....	50
Figura 22 - Gráfico F-measure .....	51
Figura 23 – Comparativo .....	53
Figura 24 - Comparativo Nível 1.....	54
Figura 25 - Comparativo Nível 2.....	54
Figura 26 - Comparativo Nível 3.....	55



## LISTA DE TABELAS

TABELA – 1 Resultados Cenário I .....	45
TABELA – 2 Ranking Classificadores Cenário I .....	47
TABELA – 3 Resultados Cenário II .....	48
TABELA – 4 Ranking Classificadores Cenário II .....	49
TABELA – 5 Resultados Cenário III .....	51
TABELA – 6 Ranking Classificadores Cenário III.....	52
TABELA – 7 Resultados Cenário IV.....	53
TABELA – 8 Resultados Cenário V – Base Não Segmentada.....	55
TABELA – 9 Resultados Cenário V – Base Não Segmentada .....	56
TABELA – 10 Ranking Geral de Classificadores.....	57

## LISTA DE SIGLAS

ARFF	<i>Attribute-Relation File Format</i>
CCAC	<i>Canadian Council on Animal Care</i>
CLEF 2014	<i>Conference and Labs of the Evaluation Forum</i>
FN	<i>False Negative</i>
FP	<i>False Positive</i>
IBk	<i>Instance Based k</i>
KNN	<i>K – Nearest Neighbors</i>
Marsyas	<i>Music Analysis, Retrieval and Synthesis for Audio Signals</i>
MFCCs	<i>Mel-frequency cepstral coefficients</i>
SMO	<i>Sequential Minimal Optimization</i>
SVM	<i>Support Vector Machine</i>
TN	<i>True Negative</i>
TP	<i>True Positive</i>
WAV	<i>Waveform Audio Format</i>
Weka	<i>Waikato Environment for Knowledge Analysis</i>
XML	<i>Extensible Markup Language</i>

## SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	<b>13</b>
1.1. MOTIVAÇÃO .....	13
1.2. JUSTIFICATIVA.....	14
1.3. OBJETIVOS.....	15
1.3.1. OBJETIVO GERAL .....	15
1.3.2. OBJETIVOS ESPECÍFICOS .....	15
1.4. ORGANIZAÇÃO .....	16
<b>2. FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>17</b>
2.1. PRÉ-PROCESSAMENTO – SEGMENTAÇÃO.....	17
2.1.1. CÁLCULO DE ENERGIA DO SINAL.....	17
2.1.2. CÁLCULO DO CENTROIDE DO ESPECTRO.....	19
2.1.3. FILTRO DA MEDIANA .....	20
2.1.4. JANELAMENTO ( <i>SLIDING WINDOW</i> ) .....	21
2.2. EXTRAÇÃO DE CARACTERÍSTICAS DE ÁUDIO .....	22
2.2.1. ESPECTRO DE ROLLOFF .....	22
2.2.2. FLUXO ESPECTRAL.....	23
2.2.3. TAXA DE CRUZAMENTO POR ZERO .....	23
2.2.4. COEFICIENTES CEPSTRAIS DA FREQUÊNCIA MEL.....	23
2.2.5. CARACTERÍSTICAS DE CROMA .....	24
2.3. INTELIGÊNCIA ARTIFICIAL.....	24
2.4. APRENDIZADO DE MÁQUINA .....	24
2.4.1. RECONHECIMENTO DE PADRÕES .....	25
2.5. CLASSIFICADORES .....	25
2.5.1. NAIVE BAYES .....	26
2.5.2. KNN.....	27
2.5.3. DECISION TREE CLASSIFIER J48.....	27
2.5.4. SEQUENTIAL MINIMAL OPTIMIATION (SMO).....	28
2.6. CLASSIFICAÇÃO HIERÁRQUICA .....	29
2.6.1. CLASSIFICAÇÃO PLANA.....	29
2.6.2. MODELO LOCAL DE CLASSIFICAÇÃO HIERÁRQUICA.....	30
2.6.3. MODELO GLOBAL DE CLASSIFICAÇÃO HIERÁRQUICA.....	31
2.7. VALIDAÇÃO CRUZADA.....	32

2.8. MÉTODOS DE AVALIAÇÃO DE CLASSIFICADORES .....	32
2.8.1. MATRIZ DE CONFUSÃO.....	32
2.8.2. MÉTRICAS.....	34
2.9. TRABALHOS RELACIONADOS.....	35
<b>3. METODOLOGIA.....</b>	<b>36</b>
3.1. FERRAMENTAS.....	36
3.1.1. MatLab®.....	36
3.1.2. MARSYAS.....	36
3.1.3. WEKA.....	37
3.1.3.1. ATTRIBUTE-RELATION FILE FORMAT (ARFF).....	37
3.2. A BASE DE DADOS .....	38
3.3. DESENVOLVIMENTO .....	39
3.3.1. SEGMENTAÇÃO .....	39
3.3.2. ORGANIZAÇÃO HIERÁRQUICA DA BASE DE DADOS.....	40
3.3.3. EXTRAÇÃO DE CARACTERÍSTICAS DE ÁUDIO.....	41
3.3.4. CLASSIFICAÇÃO DOS DADOS.....	42
3.3.4.1. CLASSIFICAÇÃO PLANA.....	42
3.3.4.2. CLASSIFICAÇÃO HIERÁRQUICA .....	43
<b>4. RESULTADOS E DISCUSSÕES .....</b>	<b>45</b>
4.1. CENÁRIO I – SEGMENTAÇÃO X ORIGINAL .....	45
4.2. CENÁRIO II – HIERÁRQUICO X PLANO (ORIGINAL) .....	47
4.3. CENÁRIO III – HIERÁRQUICO X PLANO (SEGMENTADO).....	50
4.4. CENÁRIO IV – HIERÁRQUICO SEGMENTADO X HIERÁRQUICO ORIGINAL.....	53
4.5. CENÁRIO V – HIERÁRQUICA DE DOIS NÍVEIS .....	55
4.6. ANÁLISE ADICIONAL .....	56
<b>5. CONSIDERAÇÕES FINAIS .....</b>	<b>58</b>
<b>6. REFERÊNCIAS .....</b>	<b>60</b>
<b>APÊNDICE A – LISTA DE ÁUDIOS POR ESPÉCIE (ORIGINAL) .....</b>	<b>63</b>
<b>APÊNDICE B – LISTA DE ÁUDIOS POR ESPÉCIE (SEGMENTADA) .....</b>	<b>70</b>
<b>APÊNDICE C – LISTA DE CARACTERÍSTICAS EXTRAÍDAS.....</b>	<b>77</b>

## 1. INTRODUÇÃO

Os problemas ambientais e o estudo do meio ambiente têm assumido uma importância cada vez maior, tanto na comunidade científica quanto na sociedade em geral (KAESTNER; LOPES,2010). Cabe à comunidade científica o papel de investigar mudanças e problemas que ocorrem nos ecossistemas. Entre várias necessidades para tal se sobressai a obtenção de informações atualizadas e confiáveis sobre animais silvestres, e neste contexto, por serem uma das mais numerosas classes que tem contato direto com humanos, os pássaros ocupam uma posição importante (KAESTNER; LOPES,2010). Além disso, nos dias atuais, o monitoramento da fauna de pássaros de uma região é um método bem contextualizado na medição da qualidade de vida e da biodiversidade de um determinado ambiente (SILLA; KAESTNER, 2013).

Existe também a preocupação crescente com o bem-estar dos animais que serão monitorados para a obtenção de informações. Levando isto em consideração, o Conselho Canadense de Trato aos Animais (*Canadian Council on Animal Care - CCAC*) desenvolveu uma escala com cinco categorias de invasividade provocada por qualquer procedimento que envolva animais (GRIFFIN; DANSEREAU; GAUTHIER,2007). Segundo a escala, qualquer procedimento indireto, ou seja, um procedimento que não tenha contato algum com os animais, como o procedimento de gravação dos áudios dos pássaros, conta com o nível de invasividade A (menor grau de invasividade), que caracteriza o mínimo possível de interferência no habitat em que os animais vivem, portanto não causando nenhum dano ao bem-estar dos animais.

### 1.1. MOTIVAÇÃO

O reconhecimento de espécies de pássaros através de seus cantos tem sido alvo de estudos, e em geral os métodos lidam com a representação do sinal, remoção de ruídos e pré-processamento do sinal, extração de características e a seleção de classificadores que mais se adequam a tarefa de classificação para aplicação em bases de dados de grandes proporções (SILLA; KAESTNER, 2013).

No geral, sons de pássaros podem ser classificados como cantos ou chamados. Cantos são associados ao acasalamento e tem como característica seu

som melodioso e uma duração mais longa se comparada aos chamados, que geralmente correspondem a um sinal de alerta de duração curta com uma característica transiente (LOPES et al. 2011). De acordo com Catchpole (1995) levando em consideração as características de ambos os sons, os cantos são considerados mais adequados para a classificação de espécies de pássaros, delimitando assim o problema de classificação a apenas cantos.

Com as tecnologias atuais, a gravação de arquivos de áudio em dispositivos digitais se tornou bastante acessível. Estes dispositivos gravam sinais analógicos e os convertem para valores digitais através de várias amostragens por segundo, gerando assim uma sequência de valores numéricos que representam o som que pode ser utilizado para reprodução e ou processos analíticos. Analisando estas sequências de valores numéricos é possível determinar padrões, o que estimula a averiguação e aplicação de técnicas de processamento de sinais e de reconhecimento e classificação de padrões.

Levando em consideração a facilidade de aquisição dos áudios e a crescente quantidade dos mesmos, juntamente com uma maior preocupação com o meio-ambiente e toda sua fauna, a identificação de espécies de pássaros pode se aproveitar da quantidade de dados e então se fazer útil para pesquisas e monitoramento tanto específicas ao estudo dos pássaros quanto para o conhecimento da biodiversidade como um todo.

## 1.2. JUSTIFICATIVA

O pré-processamento de segmentação em muitos casos é realizado manualmente, onde uma pessoa analisa arquivo por arquivo e selecionando as partes a serem segmentadas. Como por exemplo, em (KAESTNER; LOPES,2010) os autores utilizaram a ferramenta Audacity<sup>1</sup> para realizar a segmentação dos arquivos individualmente, o que inviabiliza o estudo de base de dados maiores. Além da segmentação, há também a organização hierárquica, uma etapa imprescindível para a construção do classificador hierárquico. Esta etapa pode demandar um tempo elevado para ser concluída manualmente, inviabilizando o estudo de classificação hierárquica para base de dados maiores. Existem vários trabalhos que abordam a

---

<sup>1</sup> Disponível em <http://audacityteam.org/>

classificação de pássaros, que são descritos na Seção 2.9, entretanto existem poucos trabalhos que fazem uso da abordagem de classificação hierárquica.

### 1.3. OBJETIVOS

A seguir são apresentados o objetivo geral e os objetivos específicos.

#### 1.3.1. OBJETIVO GERAL

O objetivo geral deste trabalho é automatizar, utilizar e aliar técnicas de processamento de sinais, extração de características de áudio e técnicas de classificação hierárquica, afim de investigar se haverá um efeito positivo no acerto da classificação de pássaros silvestres através de uma base de dados com cantos de 501 espécies distintas.

#### 1.3.2. OBJETIVOS ESPECÍFICOS

Para o cumprimento deste objetivo geral, propõem-se os seguintes objetivos específicos:

1. Realizar a técnica de pré-processamento de segmentação de áudio em toda a base de dados.
2. Clonar a base segmentada e original e organizar por ordem hierárquica de Família, Gênero e Espécie.
3. Extrair as características de áudio das bases de dados.
4. Aplicar as técnicas de classificação hierárquica e classificação plana a partir das características extraídas em ambas as bases de dados.
5. Comparar os resultados da classificação.

## 1.4. ORGANIZAÇÃO

Este trabalho está organizado da seguinte forma: Na seção 2 são apresentados os conceitos básicos da técnica de pré-processamento, as características de áudio, abordagem de classificação hierárquica, abordagem de classificação plana, as métricas de avaliação dos classificadores e os classificadores utilizados. A seção 3 descreve a visão geral da metodologia do trabalho sendo que na Seção 3.1 são apresentadas as ferramentas utilizadas em cada uma das etapas, na Seção 3.2 é realizada uma descrição da base utilizada, e na Seção 3.3 as etapas do desenvolvimento realizadas. Na seção 4 são apresentados os resultados e discussões do trabalho. Na seção 5 são apresentadas as considerações finais do trabalho.



## 2. FUNDAMENTAÇÃO TEÓRICA

Nesta seção são apresentados os conceitos básicos envolvidos no desenvolvimento de todo o trabalho.

### 2.1. PRÉ-PROCESSAMENTO – SEGMENTAÇÃO

Em Giannakopoulos (2009), o objetivo da segmentação de áudio é localizar as alterações bruscas em sinais de áudio, em outras palavras, é a busca de mudanças entre regiões de áudio homogêneas e não homogêneas. Nas próximas subseções são descritos os principais conceitos empregados no processo de segmentação utilizado neste trabalho.


#### 2.1.1. CÁLCULO DE ENERGIA DO SINAL

Como comumente pensamos em um sinal como uma função que varia de amplitude no decorrer do tempo, parece razoável que uma boa estimativa da força do sinal seja área abaixo da curva da função. Porém, essa área pode ter uma parte negativa. Essa parte negativa não tem uma menor força do que a parte positiva do sinal (SELIK; BARANIUK; BLAIR, 2004).

O cálculo da energia respeita, segundo Giannakopoulos (2009), a Eq. (1):

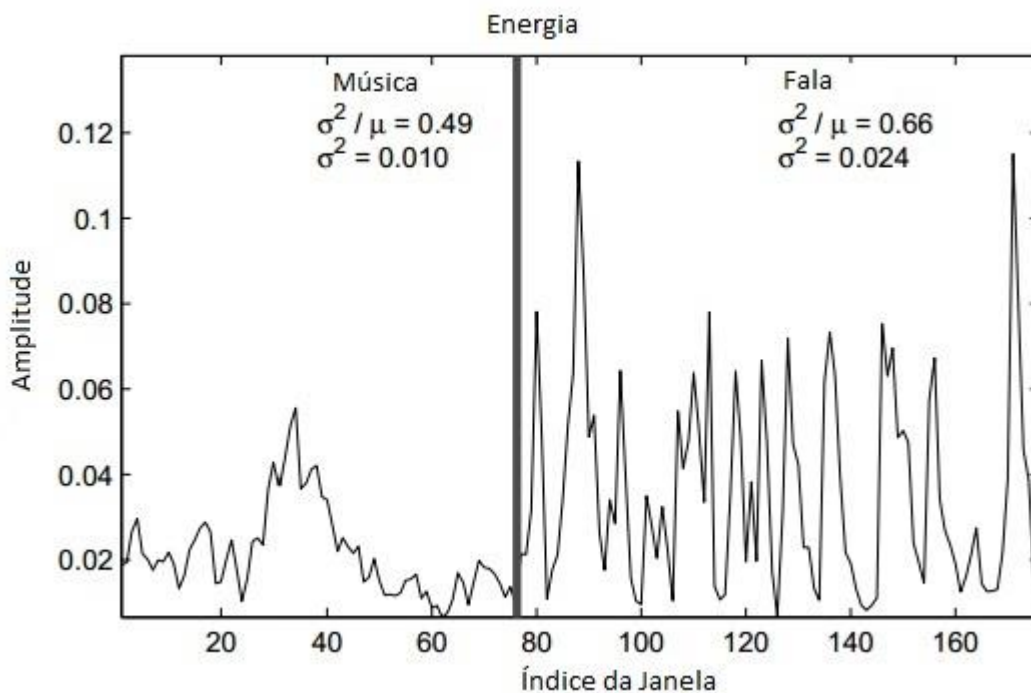
$$E(i) = \frac{1}{N} \sum_{n=1}^N |f_i(n)|^2 \quad (1)$$

Onde  $N$  é o número de amostras de áudio de uma determinada janela de tempo. A Figura 1 ilustra a representação de energia de um sinal no domínio do tempo.



**Figura 1 - A energia do sinal.**  
**Fonte: Selik, Baraniuk e Blair (2004).**

Na Figura 2 é apresentado um exemplo de uma sequência de energia, para um arquivo de áudio que contém uma parte de música e uma parte de fala onde  $\sigma^2$  é o desvio padrão da sequência de energia e  $\mu$  a média.



**Figura 2 - Exemplo de uma sequência de energia para um sinal de áudio.**  
**Fonte: Adaptado de Giannakopoulos (2009).**

No contexto de segmentação dos cantos de pássaros, o cálculo da energia do sinal auxilia a determinar quando há presença do canto propriamente dito e quando

não há o canto, e sim algum outro ruído que por muitas vezes é gerado através de gravações que são realizadas em ambientes com vários outros ruídos externos.

### 2.1.2. CÁLCULO DO CENTROIDE DO ESPECTRO

O centro do espectro é definido como o centro de gravidade do espectro e obedece a Eq. (2) segundo Giannakopoulos (2009):

$$C_i = \frac{\sum_{k=1}^N (k+1) X_i(k)}{\sum_{k=1}^N X_i(k)} \quad (2)$$

Em Giannakopoulos (2009), o Cálculo do Centroide do Espectro é uma estimativa da posição espectral, valores maiores correspondem a sons mais definidos (suaves). Na Figura 3 é mostrado um exemplo de uma sequência de centroide do espectro, para um sinal que contém uma parte de fala e uma parte de grito

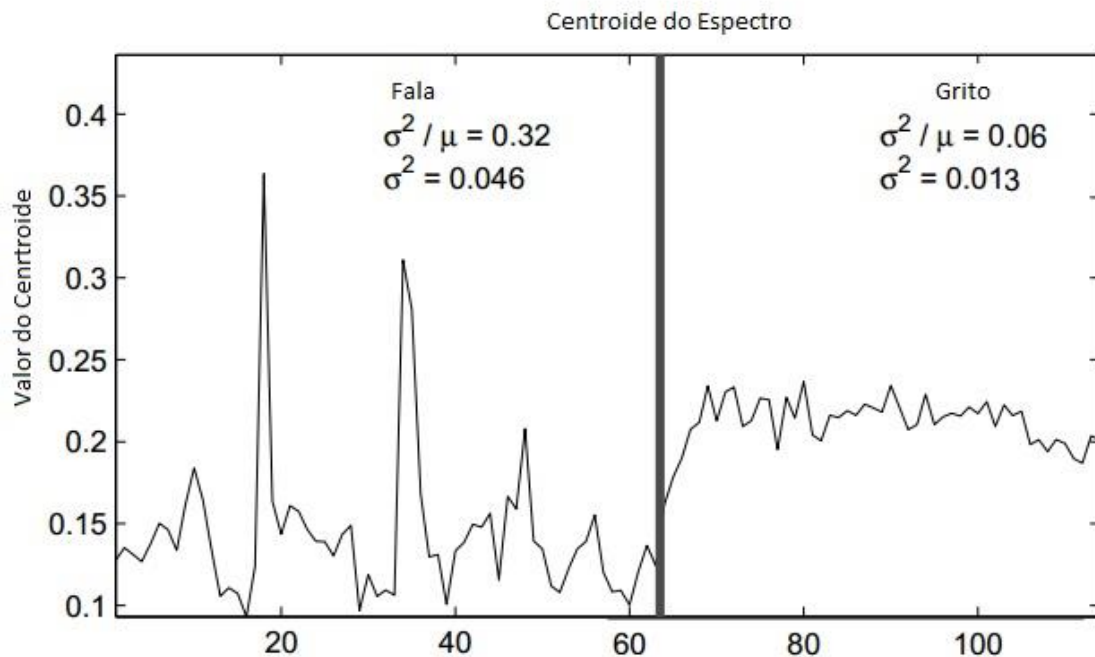


Figura 3- Exemplo de uma sequência de centroide de espectro.

Fonte: Adaptado de Giannakopoulos (2009).

Na segmentação dos cantos de pássaros, o cálculo do centroide do espectro auxilia a determinar quando há presença do canto propriamente dito e quando não há

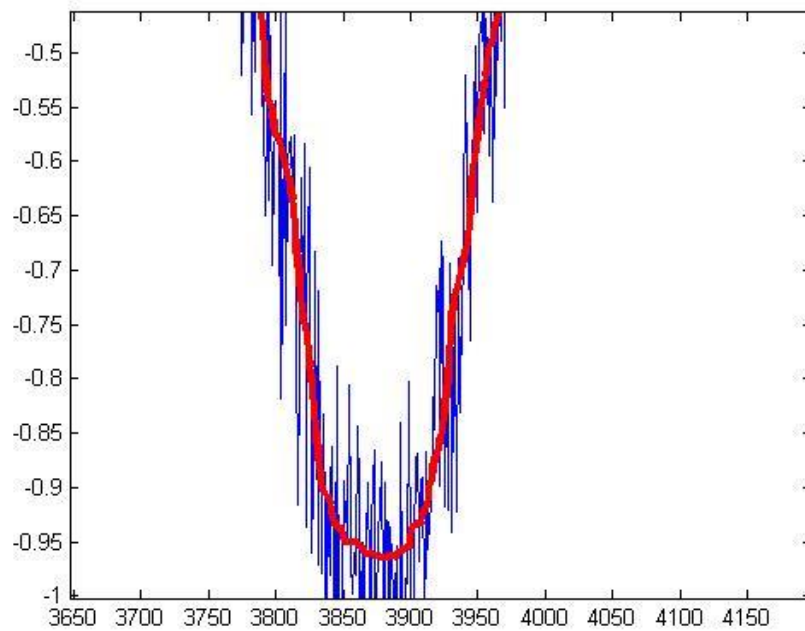
o canto e sim algum outro ruído. Além disso a ferramenta MARSYAS faz uso dessa característica de áudio em seu conjunto de características extraídas.

### 2.1.3. FILTRO DA MEDIANA

A mediana é um conjunto de valores semelhantes que está no meio do conjunto de valores menores que  $m$  e maiores que  $m$ . Para cada vizinhança, ordenam-se os valores em ordem crescente de intensidade e escolhe-se como saída o valor da mediana, aquele que está no centro da sequência. Este filtro é bem eficiente para ruídos localizados com intensidade muito diferente da vizinhança, ou não correlacionado com o sinal (RUSS, 1995).

O filtro de mediana aplicado é um filtro de ordem  $n$  unidimensional aplicado ao sinal através da função  $y = \text{medfilt1}(x [, n])$  existente na ferramenta MatLab®, com o intuito de suavizar os valores das características extraídas. Uma janela deslizante é aplicada aos dados, e para cada passo do valor mediano na janela é retornado o valor de  $x(i-(n-1)/2:i+(n-1)/2)$  caso  $n$  seja ímpar ou  $x(i-n/2:i+n/2-1)$  se  $n$  é par (PRATT, 2007).

Na Figura 4 é ilustrado o efeito do filtro em um sinal, onde o sinal em azul é o original com ruído e a linha em vermelho é o sinal após a aplicação do filtro, o que evidencia uma suavização dos valores do sinal original.



**Figura 4 – Aplicação do Medfilt1.**

**Fonte: Autoria Própria.**

#### 2.1.4. JANELAMENTO (SLIDING WINDOW)

Segundo Rabiner e Shafer (2007), é comum processar os sinais de áudio em blocos (*frames*) devido a sua variação, isto permite manter certas propriedades da forma de onda do sinal.

Isto nos conduz ao princípio básico de análise a curto prazo, que pode ser representada de forma geral pela Eq. (3):

$$X_n = \sum_{m=-\infty}^{\infty} T\{x[m]w[n-m]\} \quad (3)$$

Onde  $X_n$  representa o parâmetro de análise de curto prazo (ou vetor de parâmetros) em um tempo de análise  $n$ . O operador  $T\{\}$  representa a natureza da função de análise, e  $w[n-m]$  representa a sequência de janelas deslocadas no tempo, cujo propósito é selecionar um segmento da sequência  $x[m]$  na vizinhança da amostra  $m = n$  (RABINER; SHAFER,2007).

De acordo com Becerra (1993), a função da janela é suavizar as extremidades do segmento diminuindo o efeito das extremidades, pois na

segmentação do sinal podemos acabar gerando componentes de alta frequência que não pertencem ao sinal.

## 2.2. EXTRAÇÃO DE CARACTERÍSTICAS DE ÁUDIO

Segundo Tzanetakis e Cook (2002), a extração de características de áudio é definida como:

... o processo de calcular uma representação numérica compacta que pode ser usada para dar característica a um trecho de áudio. O desenvolvimento de características descritivas para uma aplicação específica é o principal desafio na construção de sistemas de reconhecimento de padrões. Uma vez que os recursos extraídos podem ser utilizados técnicas padrão de aprendizado de máquina que são independentes da área de aplicação específica (TZANETAKIZ; COOK, 2002).

As características que serão apresentadas nas próximas subseções fazem parte da ferramenta MARSYAS, e formam um conjunto que viabilizam seu uso em diversas tarefas, incluindo a tarefa de classificação de espécie de pássaros. (TZENETAKIS; COOK, 2000).

### 2.2.1. ESPECTRO DE ROLLOFF

Em Tzenetakis e Cook (2002), o espectro de Rolloff é definido como a frequência  $R_t$  apresentada na equação (4), na qual 85% da magnitude da concentração de distribuição está concentrada, e sendo  $Mt[n]$  é a magnitude da transformada de Fourier no frame  $t$ .

$$\sum_{n=1}^{R_t} Mt [n] = 0.85 * \sum_{n=1}^N Mt[n] \quad (4)$$

Rolloff é uma medida da forma espectral que representa a quantidade de energia do sinal que se concentra em baixas frequências.

### 2.2.2. FLUXO ESPECTRAL

Segundo Tzenetakis e Cook (2002), o fluxo espectral é definido como o quadrado da diferença entre as magnitudes normalizadas em uma sucessão de distribuição de espectros e é representada pela equação (5).

$$F_t = \sum_{n=1}^N (N_t[n] - N_{t-1}[n])^2 \quad (5)$$

Sendo  $N_t[n]$  e  $N_{t-1}$  a magnitude normalizada da transformada de Fourier no frame atual  $t$  e no frame anterior  $t-1$ , respectivamente. O fluxo espectral é a medida da quantidade de variação do espectro local.

### 2.2.3. TAXA DE CRUZAMENTO POR ZERO

A taxa de cruzamento por zero dá a informação de quantas vezes a intensidade do sinal cruza o eixo do tempo. Intuitivamente, se o número de ocorrências de cruzamento de zeros é maior em um dado sinal, então o sinal está tendo uma mudança brusca o que pode indicar uma informação de alta frequência. Do mesmo modo, se o número de ocorrências de cruzamento por zero é baixo, há pouca mudança na intensidade do sinal o que pode indicar uma frequência baixa.

$$Z_t = \frac{1}{2} \sum_{n=1}^N |\text{sen}(x[n]) - \text{sen}(x[n-1])| \quad (6)$$

Segundo Tzenetakis e Cook (2002), a taxa de cruzamento por zero segue a equação (6), onde a função seno ( $\text{sen}$ ) é 1 para argumentos positivos e -1 para argumentos negativos e  $x[n]$  é o domínio de tempo do sinal por frame  $t$ .

### 2.2.4. COEFICIENTES CEPSTRAIS DA FREQUÊNCIA MEL

Os MFCCs são coeficientes característicos do som obtidos de um tipo de representação cepstral. O termo cepstral origina de cepstrum, que é o resultado da Transformada de Fourier de um espectro decibel. A escala mel é uma escala perceptual de pitch, que é a frequência fundamental do som

percebida. O nome mel originou-se da palavra melodia para indicar que a escala é baseada em comparação de pitch (QUEIROZ et al., 2006).

Para Tzenetakis e Cook (2002), apesar de usualmente 13 coeficientes serem usados para representação, descobriram que os 5 primeiros coeficientes providenciam a melhor performance em classificação de gênero.

#### 2.2.5. CARACTERÍSTICAS DE CROMA

As características de croma tem o objetivo de representar conteúdo harmônico de uma janela de áudio contendo as magnitudes de cada uma das 12 notas musicais da escala cromática. Estas características são extraídas do espectro da magnitude utilizando a transformada de Fourier de curto termo (RAS; WIECZORKOWSKA, 2010).

### 2.3. INTELIGÊNCIA ARTIFICIAL

De acordo com Feigenbaum (1981 apud FERNANDES, 2003) inteligência artificial é a parte da ciência da computação e da engenharia de computação voltada para o desenvolvimento de sistemas computacionais inteligentes, que podem simular capacidades de raciocinar, planejar, resolver problema, aprender, reconhecer padrões e armazenar conhecimento.

O termo *Artificial Intelligence* foi utilizado pela primeira vez em 1956 por McCarthy, e o seu desenvolvimento foi impulsionado pela necessidade de novas tecnologias para a indústria bélica durante a Segunda Guerra Mundial. Desde então, surgiram interesses de outras áreas de estudo, na qual acreditavam na possibilidade de se beneficiar da habilidade de um computador imitar a maneira humana de raciocinar (RUSSEL; NORVIG, 2013).

### 2.4. APRENDIZADO DE MÁQUINA

O aprendizado de máquina é uma área da inteligência artificial que estuda métodos computacionais, a fim de obter um determinado conhecimento específico através de experiências. Os algoritmos de aprendizado de



máquina possuem o foco em métodos estatísticos e a aplicação prática de máquina inclui o processamento de linguagem natural, buscadores, diagnósticos, entre outras (MELONI; MILIDIÚ,2009).

Algumas partes da aprendizagem de máquina estão relacionadas à mineração de dados e estatística nas quais procuram padrões dentro de um conjunto de dados.

#### 2.4.1. RECONHECIMENTO DE PADRÕES

O reconhecimento de padrões é um tópico de aprendizagem de máquina com o objetivo de classificação de informações baseando-se ou em um conhecimento prévio (supervisionado) ou em informações estatísticas extraídas dos padrões (não supervisionados) (THEODORIDIS; KOUTROUMBAS;1999). Um sistema de reconhecimento de padrões consiste primeiramente em um mecanismo de extração de informações, que processa características semelhantes e depois em um mecanismo capaz de classificar as informações baseando-se nas características extraídas anteriormente (MELONI; MILIDIÚ,2009).

#### 2.5. CLASSIFICADORES

Classificadores são funções que usam reconhecimento de padrões para determinar quais classes (objetos) são mais similares entre elas. Eles podem ser treinados utilizando amostras de dados, o que os tornam muito atrativos para aplicações de inteligência artificial (RUSSEL; NORVIG, 2013). Estas amostras de dados são conhecidas como observações ou padrões, e no aprendizado supervisionado cada um dos padrões pertence a uma classe predefinida. Uma classe pode ser vista como uma decisão a ser realizada, sendo que todas as amostras de dados relacionadas a uma classe são chamadas de base de dados. Quando uma nova amostra é recebida ela é classificada baseada nas amostras anteriores.

Um classificador pode ser treinado de várias maneiras, como por exemplo, com métodos estatísticos, redes neurais, métodos kernel, gaussiano entre outros. Nas próximas subseções são apresentados os métodos de treinamento utilizados no decorrer deste trabalho.

### 2.5.1. NAIVE BAYES

É um classificador probabilístico, baseado no Teorema de Bayes, e assume que a presença (ou ausência) de cada característica em uma classe é independente da presença (ou ausência) das outras. No processo de classificação de uma nova instância todos os atributos são considerados separadamente (PADHYE,2015). Na figura 5 é apresentado um exemplo do funcionamento do classificador.

Outlook	Temperature		Humidity		Windy		Play						
	Yes	No	Yes	No	Yes	No	Yes	No					
Sunny	2	3	Hot	2	2	High	3	4	False	6	2	9	5
Overcast	4	0	Mild	4	2	Normal	6	1	True	3	3		
Rainy	3	2	Cool	3	1								
Sunny	2/9	3/5	Hot	2/9	2/5	High	3/9	4/5	False	6/9	2/5	9/14	5/14
Overcast	4/9	0/5	Mild	4/9	2/5	Normal	6/9	1/5	True	3/9	3/5		
Rainy	3/9	2/5	Cool	3/9	1/5								

- Para um novo dia:

Outlook	Temp.	Humidity	Windy	Play
Sunny	Cool	High	True	?

Verossimilhança para as duas classes:

$$\text{Para "yes"} = 2/9 \times 3/9 \times 3/9 \times 3/9 \times 9/14 = 0.0053$$

$$\text{Para "no"} = 3/5 \times 1/5 \times 4/5 \times 3/5 \times 5/14 = 0.0206$$

Convertendo para probabilidades por meio de normalização:

$$P(\text{"yes"}) = 0.0053 / (0.0053 + 0.0206) = 0.205$$

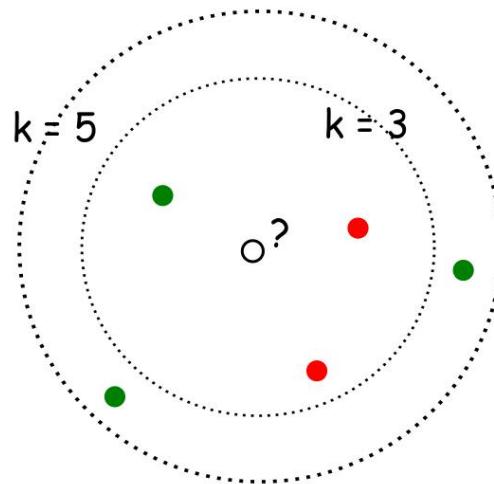
$$P(\text{"no"}) = 0.0206 / (0.0053 + 0.0206) = 0.795$$

**Figura 5 - Exemplo Naive Bayes**  
 Fonte: Adaptado de Wiki ICMC USP

Como pode ser visto na Figura 5, é mostrado um exemplo onde é aplicado o classificador Naive Bayes para se determinar se o dia está propício para a realização de atividades externas. A classificação se dá através de características de condições climáticas, temperatura, umidade e se há ou não a presença de vento. Para cada uma das classes de saída possíveis (Sim ou Não), é calculada a verossimilhança levando em consideração dados prévios (dados de treinamento) das características utilizadas.

### 2.5.2. KNN

O método de classificação KNN é um método baseado em instâncias; utiliza uma votação entre os  $k$  vizinhos mais próximos e baseia-se na similaridade entre eles e a amostra a ser classificada para realizar a classificação.



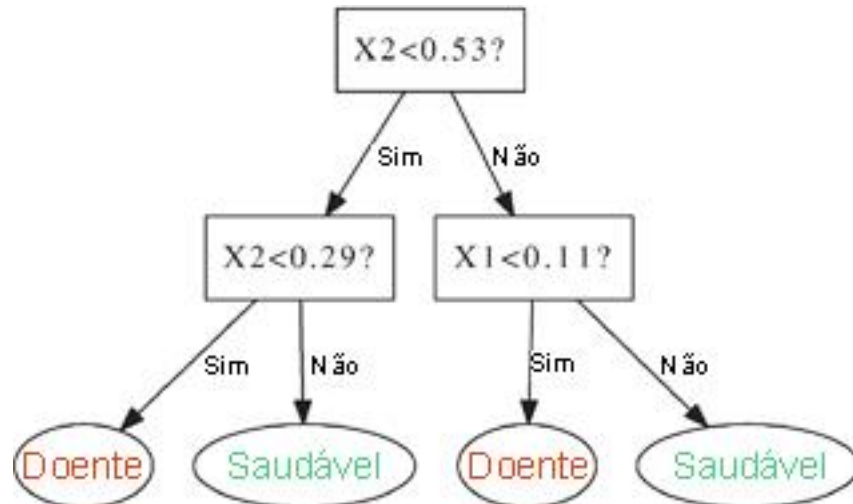
Com  $k = 3$ , ●  
Com  $k = 5$ , ●

Figura 6 - Representação KNN  
Fonte: Autoria própria

Na Figura 6 é apresentado um exemplo do algoritmo KNN para dois valores de  $K$  distintos. Pode se observar que o valor de  $k$  influencia diretamente na decisão da classificação. A instância de teste representada pelo círculo sem cor, é classificada como vermelha para  $K=3$  e como verde para  $K=5$ .

### 2.5.3. DECISION TREE CLASSIFIER J48

O algoritmo J48 é uma implementação do algoritmo C4.5, no qual se constrói uma árvore de decisão com base na organização dos atributos a serem avaliados por meio do ganho de informação que cada amostra de teste proporciona. Os nós internos possuem atributos diferentes, as ramificações entre os nós têm como possibilidades os valores que uma amostra de teste pode ter e no último nível possuem as classes na qual a amostra de teste pode ser classificada (PADHYE,2015).

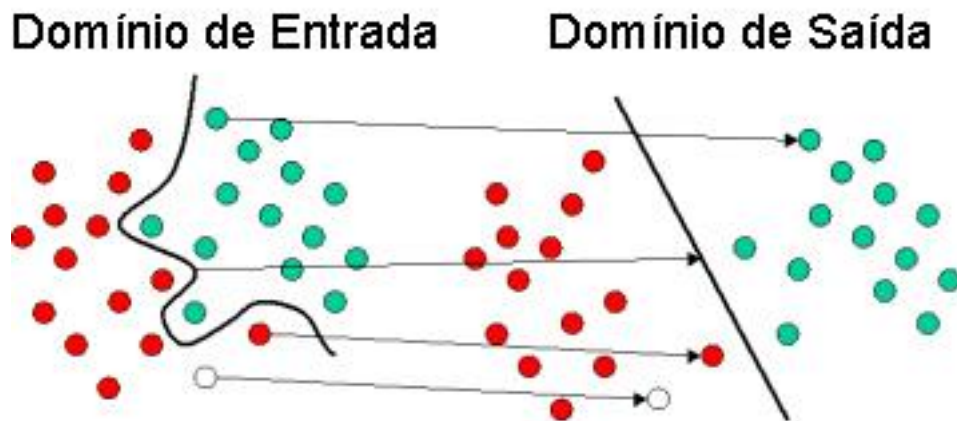


**Figura 7 - Exemplo árvore de decisão**  
**Fonte: Adaptado de Geurts, Irrithum e Louis (2009)**

Na Figura 7 é apresentado um exemplo de árvore de decisão usada pelo algoritmo J48. Pode se observar que a cada nível da árvore são testados os atributos das amostras, e através destes testes (decisões) a amostra é classificada como uma das classes mostradas no nível final da árvore.

#### 2.5.4. SEQUENTIAL MINIMAL OPTIMIATION (SMO)

O SMO é um algoritmo que resolve o problema quadrático da SVM (Support Vector Machine), caracterizando-se como uma variação da SVM, entretanto sem a necessidade de uma matriz de armazenamento extra e sem invocar uma rotina de iteração numérica para cada problema. O SMO decompõe o problema em vários subproblemas e dá preferência em resolver a menor parte possível do problema em cada iteração (PLATT, 2000). As SVMs são classificadores binários, que se baseiam no aprendizado estatístico e estabelece princípios para obtenção de classificadores generalizados. O SVM possui a vantagem da possibilidade de se utilizar kernels para transformação de dados não-linearmente separáveis em um domínio, em outro domínio onde os dados são linearmente separáveis.



**Figura 8 - Ilustração SVM**  
 Fonte: Adaptado de StatSoft

Na Figura 8 é apresentada uma representação do funcionamento de uma SVM, na qual utiliza duas classes distintas em um domínio não linearmente separável e a converte em um domínio linearmente separável em cada iteração para classificar a amostra.

## 2.6. CLASSIFICAÇÃO HIERÁRQUICA

Classificação hierárquica pode ser vista como um caso particular do problema de classificação estruturada, onde a saída do algoritmo de classificação é definida através de uma taxonomia de classes (SILLA JR; FREITAS, 2011).

De acordo com Silla Jr. E Freitas (2011), existem três maneiras para se lidar com problemas de classificação hierárquica, e cada uma dessas maneiras está descrita nas subseções a seguir.


### 2.6.1. CLASSIFICAÇÃO PLANA

Segundo Silla Jr. e Freitas (2011), a classificação plana é a maneira mais simples para se lidar com problemas de classificação hierárquica, consiste basicamente em ignorar a hierarquia das classes comumente prevendo apenas as classes dos nós folhas da árvore.

Apesar de se comportar como um algoritmo de classificação comum durante o treinamento de máquina e o teste, o modelo de classificação plana provê uma solução indireta para o problema da classificação hierárquica devido a atribuição de uma classe ao nó folha, indicando implicitamente que toda hierarquia superior ao nó folha, também faz parte desta mesma classe.

Entretanto, esta abordagem tem a desvantagem da necessidade de construção de um rótulo para diferenciar um grande número de classes, sem explorar informações sobre as relações de classe entre pais e filhos presentes na hierarquia de classes (SILLA JR.; FREITAS, 2011).

Na Figura 9 é apresentado um exemplo de como seria a estrutura e a rotulação de um problema em que as amostras são rotuladas até as folhas de profundidade maior, conhecidos como problemas de previsão de nós folha obrigatórios (2011, SILLA JR.; KAESTNER, 2013):




**Figura 9 - Classificação plana.**  
**Fonte: Adaptado de Silla Jr. E Freitas (2011).**

## 2.6.2. MODELO LOCAL DE CLASSIFICAÇÃO HIERÁRQUICA

Segundo Silla Jr. e Freitas (2011), aparenta-se ter três tipos básicos para se usar as informações locais que são um classificador local por nó, um classificador local por nó pai e um classificador local por nível. Apesar desses três tipos se diferenciarem na fase de treinamento, eles compartilham uma abordagem de nível decrescente similar na fase de teste. Em consequência dessa abordagem de nível

decrecente, existe a desvantagem de que caso haja algum erro em algum nível, esse erro será replicado para os níveis a baixo na hierarquia.


Na Figura 10 são apresentados os modelos de classificador local, onde os nós circulados são os nós nos quais cada tipo de classificador local aplica o algoritmo.



**Figura 10 – As três abordagens do modelo local de classificação.**  
**Fonte: Adaptado de Silla Jr. E Freitas (2011).**

### 2.6.3. MODELO GLOBAL DE CLASSIFICAÇÃO HIERÁRQUICA

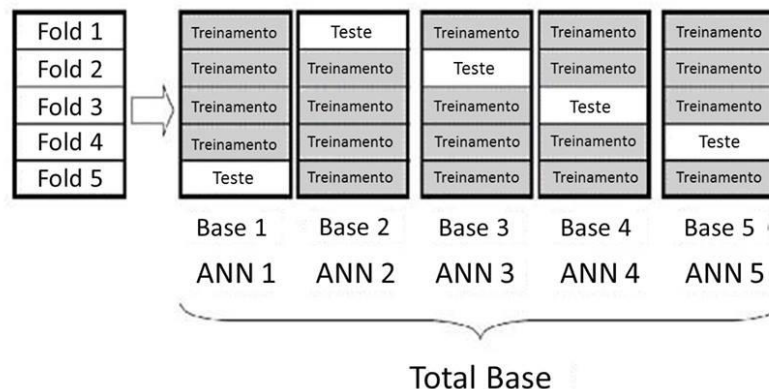
No modelo global de classificação hierárquica, é usado um único algoritmo capaz de prever as classes em qualquer nível da hierarquia (SILLA JR; FREITAS, 2011). Na fase de treinamento o modelo global de classificação hierárquica calcula as probabilidades levando em consideração a informação hierárquica disponível. Quando usado durante a fase de teste, cada arquivo de teste é classificado por um modelo induzido, um processo que pode atribuir classes a todos os níveis da hierarquia (FREITAS; DE CARVALHO, 2007). Na Figura 11 é apresentado o modelo de classificador global.



**Figura 11 - Classificação Global.**  
**Fonte: Adaptado de Silla Jr. E Freitas (2011).**

## 2.7. VALIDAÇÃO CRUZADA

A técnica de validação cruzada visa avaliar como o modelo de treinamento irá ser generalizado para uma base de dados independente. É geralmente usado quando o objetivo é estimar na prática a precisão de um modelo de predições (CORCHADO et al.,2011, p.150). Consiste na divisão da base de dados em n partes (folds) complementares, utilizando n-1 para a base de teste (validação) e o restante para a base de treinamento. Para reduzir a variação o processo é repetido n vezes, de forma que todas as partes sejam usadas ao menos uma vez como base de teste. Na Figura 12 é apresentado um exemplo da divisão da base de dados para validação cruzada.



**Figura 12 - Exemplo Base Validação Cruzada**  
**Fonte: Adaptado de Corchado et al. (2011)**

## 2.8. MÉTODOS DE AVALIAÇÃO DE CLASSIFICADORES

Nesta seção são apresentadas as ferramentas necessárias para a realização e aplicação das métricas de avaliação dos classificadores.

### 2.8.1. MATRIZ DE CONFUSÃO



A Matriz de Confusão é uma tabela geralmente utilizada para descrever a performance de um modelo de classificação ou classificador em uma dada base de testes onde seus valores reais são conhecidos. Na Figura 13 é mostrado um simples exemplo de matriz de confusão.

n=165	PREDITA NÃO	PREDITA SIM
	REAL NÃO	TN= 50
REAL SIM	FN= 5	TP= 100

Figura 13 - Matriz de Confusão  
Fonte: Autoria P

Analisando a Figura 13 pode-se primeiramente inferir que existem duas classes das quais podem ser preditas (Classes SIM e NÃO), como por exemplo se estivermos predizendo se um dia vai chover ou não. Pode-se também notar que o classificador realizou um total de 165 predições, das quais 110 amostras foram preditas como SIM e 55 amostras preditas como NÃO. Por fim inferimos que na realidade 105 amostras deveriam ser preditas como SIM e 60 amostras deveriam ser preditas como NÃO.

A partir dos resultados podemos definir os termos básicos da matriz de confusão que são:

**True Positives (TP)** – Estes são os casos onde a amostra foi predita na classe SIM e de fato faziam parte desta classe.

**True Negatives (TN)** – Estes são os casos onde a amostra foi predita na classe NÃO e de fato faziam parte desta classe.

**False Positives (FP)** – Estes são os casos onde a amostra foi predita na classe SIM, entretanto elas pertencem na realidade a classe NÃO.

**False Negatives (FN)** - Estes são os casos onde a amostra foi predita na classe NÃO, entretanto elas pertencem na realidade a classe SIM.

### 2.8.2. MÉTRICAS

Para avaliação dos classificadores planos empregados neste trabalho serão utilizadas as métricas *precision*, *recall* e *F-measure*, que podem ser obtidas através de uma matriz de confusão e são definidas pelas Equações (7), (8), (9) respectivamente.

*Precision* é a divisão das amostras classificadas corretamente de uma classe sobre o total de amostras previstas para aquela classe. Onde TP é a soma das amostras classificadas corretamente para uma classe e FP são as que foram classificadas incorretamente como pertencentes a esta mesma classe.

$$Precision = \frac{TP}{TP+FP} \quad (7)$$

*Recall* é a divisão das amostras de uma classe que foram classificadas corretamente, sobre a soma das amostras de uma classe que foram classificadas corretamente e incorretamente. Onde FN é a soma das amostras que pertencem a uma classe, mas foram classificadas erroneamente como pertencente outra classe.

$$Recall = \frac{TP}{TP+FN} \quad (8)$$

*F-measure* é uma medida que leva em consideração a *precision* e o *recall* e respeita a seguinte equação.

$$Fmeasure = \frac{2*Precision*Recall}{Precision+Recall} \quad (9)$$

## 2.9. TRABALHOS RELACIONADOS

A tarefa de classificação de pássaros tem sido estudada de diferentes maneiras por vários autores, como no caso de (KAESTNER; LOPES, 2010) e (LOPES et al., 2011) onde são investigados e avaliados diferentes conjuntos de características de áudio para uma base segmentada manualmente utilizando a ferramenta Audacity. Os resultados apresentados indicam que houve uma melhora na classificação quando utilizada a base segmentada em relação à base não segmentada, e que o extrator de características MARSYAS juntamente com o *SoundRuler* obtiveram as melhores porcentagens de acerto. No trabalho de (SILLA JR et al., 2011), foram comparadas as abordagens de classificação plana, classificação hierárquica local por nó pai e classificação hierárquica global para uma base de canto de pássaros com 48 espécies distintas. Os resultados apresentados indicam que a classificação hierárquica global obtém um melhor resultado geral na classificação do que os outros dois métodos analisados.

Em (KWAN et al., 2004) foi proposto um sistema de classificação de espécies de pássaros para a identificação de pássaros perigosos próximos a aeroportos. Foi aplicada uma mistura de Modelos de Markov e Gaussiano no processo de classificação, entretanto obtiveram resultados insatisfatórios devido à proporção baixa entre sinal e ruído no ambiente do aeroporto. No trabalho de (CHOU et al., 2007) foi proposto um sistema de reconhecimento de espécie de pássaros onde os cantos eram segmentados em várias sílabas e destas sílabas eram obtidos valores do espectro da frequência. As sílabas eram obtidas através de clusterização utilizando o método fuzzy e cada grupo silábico era modelado por um modelo de Markov para caracterizar os cantos de cada espécie. Os resultados tiveram uma taxa de 78% de acerto em uma base de dados com 420 espécies de pássaros.

### 3. METODOLOGIA

Nesta seção são apresentadas as ferramentas e métodos utilizados para o desenvolvimento do trabalho.

#### 3.1. FERRAMENTAS

Foram utilizadas ferramentas para criação de scripts de automatização, extração de características e classificação/mineração de dados.

##### 3.1.1. MatLab®

O MatLab® é um ambiente de linguagem interativa de alto nível para cálculo numérico, visualização e programação. Com o MatLab®, é possível analisar dados, desenvolver algoritmos, criar modelos e aplicações. A linguagem, as ferramentas e as funções matemáticas já embarcadas no sistema permitem explorar vários segmentos e alcançar soluções mais rapidamente do que as linguagens de programação tradicionais.

##### 3.1.2. MARSYAS

A ferramenta MARSYAS<sup>2</sup> é um software *open source* para prototipação e experimentos envolvendo análise e sintetização de áudio. Tem ênfase específica em aplicações de extração de informações de áudio. O objetivo básico do MARSYAS é prover uma extensa e flexível arquitetura, que facilite e agilize os experimentos com algoritmos que são muito úteis para o desenvolvimento de ferramentas de análise e síntese em tempo real de áudio.

---

<sup>2</sup> Disponível em <http://marsyas.info/>

### 3.1.3. WEKA

O Weka<sup>3</sup> é uma ferramenta *open source* que contém uma coleção com algoritmos de aprendizado de máquina para tarefas de mineração de dados. Os algoritmos podem também ser aplicados diretamente em uma base de dados ou chamados a partir de um código Java próprio. Weka contém ferramentas para pré-processamento, classificação, regressão, clusterização, regras de associação e visualização de dados.

#### 3.1.3.1. ATRIBUTE-RELATION FILE FORMAT (ARFF)

O ARFF é o tipo de arquivo utilizado pela ferramenta Weka, sendo composto por duas seções distintas, o cabeçalho e a parte dos dados. A primeira é o cabeçalho, na qual contém o nome da relação (nome da base de dados), e também uma lista de atributos seguido de seus respectivos tipos, na segunda seção são apresentados os dados em uma composição de vetor, sendo que cada linha é uma instância (WEKA,2002). Na Figura 14 é apresentado um exemplo de arquivo ARFF.

---

<sup>3</sup> Disponível em <http://www.cs.waikato.ac.nz/ml/weka/>

```

% 1. Title: Iris Plants Database
%
% 2. Sources:
%   (a) Creator: R.A. Fisher
%   (b) Donor: Michael Marshall (MARSHALL@PLU@ig.arc.nasa.gov)
%   (c) Date: July, 1988
%
@RELATION iris

@ATTRIBUTE sepallength NUMERIC
@ATTRIBUTE sepalwidth NUMERIC
@ATTRIBUTE petallength NUMERIC
@ATTRIBUTE petalwidth NUMERIC
@ATTRIBUTE class       {Iris-setosa,Iris-versicolor,Iris-virginica}

@DATA
5.1,3.5,1.4,0.2,Iris-setosa
4.9,3.0,1.4,0.2,Iris-setosa
4.7,3.2,1.3,0.2,Iris-setosa
4.6,3.1,1.5,0.2,Iris-setosa
5.0,3.6,1.4,0.2,Iris-setosa
5.4,3.9,1.7,0.4,Iris-setosa
4.6,3.4,1.4,0.3,Iris-setosa
5.0,3.4,1.5,0.2,Iris-setosa
4.4,2.9,1.4,0.2,Iris-setosa
4.9,3.1,1.5,0.1,Iris-setosa

```

**Figura 14 - Exemplo de Arquivo ARFF**  
**Fonte: Adaptado de (WEKA,2002)**

### 3.2. A BASE DE DADOS

A base de dados foi construída e disponibilizada pelo desafio da competição Clef<sup>4</sup> 2014, e contém 14.027 arquivos de áudio divididos em uma base de treinamento (9688 arquivos de áudio) e uma base de testes (4339 arquivos de áudio), que pertencem a 501 espécies de pássaros localizados no Brasil, retiradas da base de dados colaborativa Xeno-Canto<sup>5</sup>.

A base de dados disponibilizada teve todos os arquivos normalizados tanto em banda quanto em frequência de 44.1 kHz, e o formato WAV de 16 bits. Cada arquivo de áudio da base de treinamento foi associado a um arquivo de meta dados com informações como a data e a localização das observações, alguns comentários dos autores, *ID* do áudio gravado, nome da espécie, nome do gênero e nome da família. Todos esses meta-dados são armazenados em um arquivo XML com o mesmo nome do arquivo de áudio. Para este trabalho utilizou-se apenas a base de

<sup>4</sup> Disponível em <http://www.imageclef.org/2014/lifeclef/bird>

<sup>5</sup> Disponível em <http://xeno-canto.org>

treinamento com 9.688 arquivos de áudio, por não haver arquivos de metadados para a base de testes. Uma lista completa com todas as quantidades de arquivos por espécies pode ser encontrada no Apêndice A.

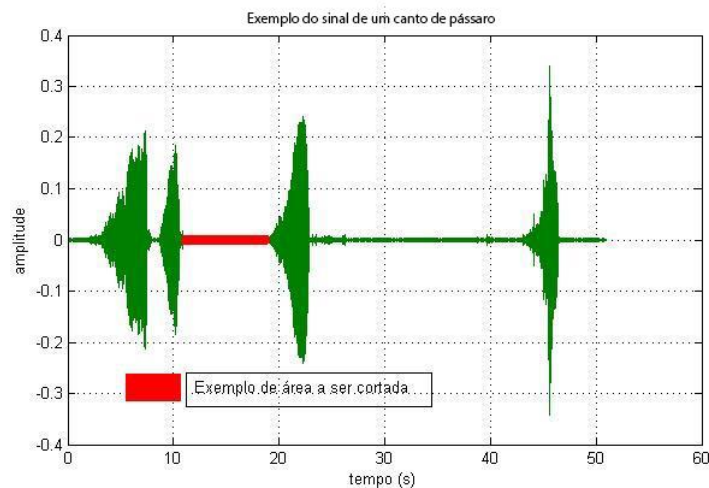
### 3.3. DESENVOLVIMENTO

Nesta seção será abordado o desenvolvimento de cada uma das etapas do projeto.

#### 3.3.1. SEGMENTAÇÃO

O processo de segmentação foi aplicado aos sinais da base de dados utilizando a ferramenta MatLab®, onde foram utilizados os métodos de cálculo de energia do sinal (Seção 2.1.1), cálculo do centroide do espectro do sinal (Seção 2.1.2), filtro da mediana (Seção 2.1.3) e janelamento (Seção 2.1.4) afim de definir os segmentos seguindo os seguintes passos baseados em (GIANNAKOPOULOS, 2009):

- 1 – Define-se o tamanho de cada janela de áudio em 50 milissegundos.
- 2 – Calcula-se as características de Energia do Sinal e Centroide do Espectro para cada janela.
- 3 – Calcula-se o histograma de cada uma das duas características.
- 4 – Através do histograma calcula-se os valores de máxima de cada uma das duas características.
- 5 – Para cada uma das características utiliza a média harmônica dos dois primeiros valores de máxima como limiares das características.
- 6 – O limiar é utilizado para definir quais janelas de áudio vão ser mantidas e quais vão ser descartadas.



**Figura 15 – Modelo de um sinal a ser segmentado.**  
**Fonte: Autoria Própria.**

A Figura 15 representa um sinal de canto de pássaro demonstrando as partes a serem segmentadas do arquivo. Após o processo de segmentação, para este caso específico, seriam gerados quatro pulsos de um mesmo arquivo.

No Apêndice B há uma lista com a relação de pulsos gerados para cada uma das espécies contidas no banco de dados original.

### 3.3.2. ORGANIZAÇÃO HIERÁRQUICA DA BASE DE DADOS.

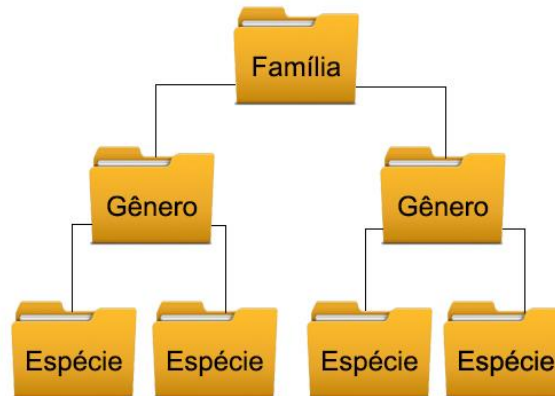
Os novos arquivos (pulsos) gerados pela segmentação, assim como a base de dados original, são organizados automaticamente em pastas que obedecem a hierarquia de Família, Gênero e Espécie através de um *script* criado em MatLab®. Essas pastas foram criadas a partir das informações contidas nos metadados relacionados a cada arquivo. A ordem hierárquica será respeitada seguindo os padrões de hierarquia de diretórios do Windows, na qual é estabelecida como demonstrado no exemplo da Figura 16:

C:\Familia\Genero\Especie\ArquivoSegmentado.wav

**Figura 16 – Exemplo hierarquia de diretórios do Windows.**  
**Fonte: Autoria Própria.**



Para uma melhor visualização da hierarquia entre Família, Gênero e Espécie a Figura 17 demonstra graficamente a distribuição dos diretórios em forma de árvore.



**Figura 17 – Exemplo hierarquia de diretórios do Windows em formato de árvore.  
Fonte: Autoria Própria.**

### 3.3.3. EXTRAÇÃO DE CARACTERÍSTICAS DE ÁUDIO.

Para a extração de áudio foi utilizada a ferramenta bextract do framework MARSYAS através da linha de comando “bextract –sv {nome do conjunto dos arquivos de áudio} –w {nome arquivo.arff}”. A ferramenta extrai características de timbre, como centroide do espectro, *rolloff*, fluxo do espectro, taxa de cruzamento por zero, os 13 primeiros coeficientes cesptrais de frequência mel, e 14 valores dos tons da escala cromática, gerando assim um conjunto de 31 características distintas dos quais são realizados quatro cálculos estatísticos (médias e variâncias) resultando em um conjunto de 124 atributos (Seção 2.2). Para cada amostra é gerado um vetor contendo as informações referentes aos 124 atributos e com comentários sobre sua localização no computador.

A ferramenta MARSYAS exporta os dados do conjunto de 124 atributos para um arquivo de formato ARFF (Seção 3.1.3.1), que é utilizado posteriormente na ferramenta Weka para treinamento e classificação dos dados.

Foram criados quatro arquivos ARFF, sendo um para a base não segmentada não hierárquica, um para base segmentada não hierárquica, um para a base não segmentada hierárquica e o último para a base segmentada hierárquica.

### 3.3.4. CLASSIFICAÇÃO DOS DADOS.

Para a classificação dos dados foi utilizada a ferramenta Weka, que a partir dos arquivos ARFF gerados da extração das características dos cantos dos pássaros, pela ferramenta MARSYAS, utiliza os algoritmos existentes para a classificação dos dados dos cantos de pássaros.

#### 3.3.4.1. CLASSIFICAÇÃO PLANA

Para a classificação plana foi utilizada a interface gráfica da ferramenta Weka utilizando a validação cruzada de 10 folds com todos os parâmetros padrão para cada um dos quatro classificadores (seção 2.5) empregados, os resultados de cada um dos classificadores foram armazenados em arquivos de texto resultando assim em oito arquivos no total (quatro segmentados e quatro não segmentados).

Os arquivos com os resultados trazem informações de *Precision*, *Recall*, *F-Measure* e Acurácia, para cada uma das classes.

Na Figura 18 é mostrado um arquivo de exemplo de um resultado gerado pelo Weka, onde podemos observar os valores das métricas de avaliação sendo detalhados.

audio-bird-bk-segmentado							
1036							
1037	Correctly Classified Instances	50191		71.7804 %			
1038	Incorrectly Classified Instances	19732		28.2196 %			
1039	Kappa statistic	0.717					
1040	Mean absolute error	0.0011					
1041	Root mean squared error	0.0334					
1042	Relative absolute error	28.8609 %					
1043	Root relative squared error	74.9318 %					
1044	Total Number of Instances	69923					
1045							
1046							
1047	=== Detailed Accuracy By Class ===						
1048							
1049		TP Rate	FP Rate	Precision	Recall	F-Measure	ROC Area
1050		0.362	0	0.49	0.362	0.417	0.687
1051		0.586	0.001	0.574	0.586	0.58	0.801
1052		0.451	0.001	0.471	0.451	0.46	0.748
1053		0.69	0.001	0.717	0.69	0.703	0.847
1054		0.691	0.001	0.647	0.691	0.668	0.846
1055		0.357	0	0.476	0.357	0.408	0.671
1056		0.573	0	0.782	0.573	0.662	0.789
1057		0.645	0	0.8	0.645	0.714	0.834
1058		0.781	0	0.909	0.781	0.84	0.881
1059		0.591	0	0.765	0.591	0.667	0.779
1060		0.556	0	0.75	0.556	0.638	0.785
1061		0.766	0	0.85	0.766	0.806	0.875
1062		0.607	0	0.68	0.607	0.642	0.81
1063		0.76	0	0.809	0.76	0.784	0.874
1064		0.891	0	0.9	0.891	0.895	0.936
1065		0.804	0	0.771	0.804	0.787	0.916
1066		0.83	0	0.796	0.83	0.813	0.916
1067		0.828	0	0.759	0.828	0.792	0.913
1068		0.746	0	0.72	0.746	0.733	0.852
1069		0.618	0.001	0.505	0.618	0.556	0.802
1070		0.764	0	0.791	0.764	0.777	0.88
1071		0.793	0.001	0.672	0.793	0.727	0.895
1072		0.667	0.001	0.593	0.667	0.628	0.835
1073		0.785	0.001	0.639	0.785	0.705	0.893
1074		0.444	0	0.526	0.444	0.482	0.683
1075		0.714	0.001	0.621	0.714	0.665	0.848
1076		0.734	0	0.785	0.734	0.758	0.862
1077		0.742	0.001	0.68	0.742	0.71	0.861
1078		0.773	0	0.792	0.773	0.783	0.886
1079		0.636	0	0.797	0.636	0.708	0.828
1080		0.612	0.001	0.514	0.612	0.559	0.815
1081		0.79	0	0.8	0.79	0.795	0.894
1082		0.871	0	0.91	0.871	0.891	0.924
1083		0.808	0	0.859	0.808	0.833	0.902
1084		0.717	0	0.832	0.717	0.77	0.869
1085		0.634	0	0.627	0.634	0.63	0.811
1086		0.681	0.001	0.633	0.681	0.656	0.856
1087		0.669	0.001	0.681	0.669	0.675	0.818
1088		0.642	0.001	0.656	0.642	0.649	0.829
1089		0.799	0	0.897	0.799	0.845	0.904
1090		0.85	0.001	0.708	0.85	0.773	0.94
1091		0.811	0.001	0.738	0.811	0.773	0.913
1092		0.88	0	0.868	0.88	0.874	0.942

Figura 18 - Exemplo Resultado Weka

Fonte: Autoria Própria

### 3.3.4.2. CLASSIFICAÇÃO HIERÁRQUICA

Para a classificação hierárquica foi utilizada uma vertente do modelo local de classificação hierárquica (Seção 2.6.2), a classificação por nó local pai. Nesta abordagem um conjunto de classificadores planos são empregados utilizando uma visão local da hierárquia. Durante a fase de treinamento, um classificador multi classe é treinado para cada nó não folha da hierarquia. A fase de teste inicia-se apresentando

a amostra de teste para o nó raiz da hierarquia. Este classificador realiza uma predição baseado nos seus nós filhos e então selecionamos o próximo classificador baseado na saída do classificado do nó raiz, continuando assim até que seja encontrado um nó folha.

Para essa abordagem os seguintes passos foram realizados:

1. Foram criadas 10 folds;
2. A partir do arquivo ARFF base gerado foram criados novos arquivos ARFF de treinamento para cada um dos níveis da árvore e teste (com amostras distintas) para cada uma das 10 folds garantindo assim a validação cruzada;
3. A partir dos arquivos de treinamento foram criados modelos de classificação para cada um dos nós pais da árvore, sendo o primeiro nó o que define a família da amostra, o segundo nó o que define os gêneros da amostra e terceiro nó que define a espécie da amostra;
4. Foram realizadas a classificação para cada um dos arquivos de teste utilizando o Weka através da linha de comando “-java -classpath weka.jar.weka.classifiers.nomedoclassificador -l nomedomodelodetreino -T nomedoarquivodeteste -p 0 > predicao.txt”;
5. Os resultados das predições eram separados entre os que foram corretamente preditos e os que foram incorretamente preditos em cada nível;
6. Este processo foi realizado até se alcançar um nó folha.

Todos os passos foram realizados através de scripts escritos em MatLab®.

## 4. RESULTADOS E DISCUSSÕES

Os resultados serão divididos em cinco cenários, sendo o primeiro uma comparação entre a base original e a com o pré-processamento de segmentação, o segundo cenário comparando o método hierárquico sem segmentação com o plano sem segmentação, o terceiro o método hierárquico com a base segmentada e o método plano com a base segmentada, o quarto as duas bases hierárquicas e por último é analisado uma hierarquia de apenas dois níveis. Há também uma análise geral que compara o resultado dos três primeiros cenários.

### 4.1. CENÁRIO I – SEGMENTAÇÃO X ORIGINAL

O primeiro cenário buscou investigar o efeito do pré-processamento na melhoria da classificação. Como investigado em (KAESTNER; LOPES,2010) o pré-processamento dos sinais de áudio contribuíram para um maior acerto na classificação de espécies de pássaros através de seus cantos. Na Tabela 1 são apresentados os resultados dos quatro classificadores (Seção 2.5) empregados para as bases original e segmentada ordenados alfabeticamente e utilizando as métricas *Precision*, *Recall*, *F-Measure* e *Acurácia* (Seção 2.8).

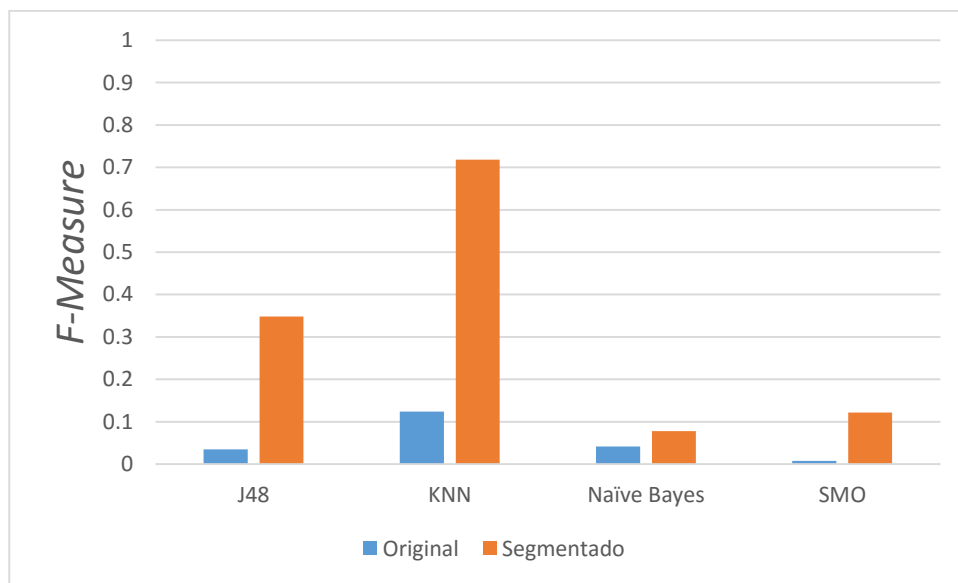
Tabela 1 – Resultados Cenário I

	<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>	<i>Acurácia</i>
<b>J48 - Original</b>	0.038	0.036	0.035	3,627%
<b>J48 - Segmentada</b>	0.356	0.346	0.348	34,645%
<b>KNN- Original</b>	0.139	0.121	0.124	12,058%
<b>KNN - Segmentada</b>	0.721	0.718	0.718	71,780%
<b>Naïve Bayes - Original</b>	0.08	0.043	0.042	4,256%
<b>Naïve Bayes - Segmentada</b>	0.204	0.079	0.078	7,933%
<b>SVM – Original</b>	0.017	0.016	0.008	1,597%
<b>SVM – Segmentada</b>	0.231	0.124	0.122	12,447%

Fonte: Autoria Própria

Os resultados de cada classificador para as bases segmentada e original são apresentados na Tabela 1. Analisando os resultados é possível concluir que o pré-processamento desempenha um papel importante no melhoramento da classificação sendo mais visível no classificador KNN no qual obteve uma melhora de 59,722% na Acurácia.

Na Figura 19, é apresentado um gráfico comparativo dos valores da *F-Measure* com os classificadores agrupados para uma melhor observação dos resultados.



**Figura 19 - Gráfico Resultados Cenário I**  
**Fonte: Autoria Própria**

Na Tabela 2 é apresentado um ranking dos classificadores levando em consideração a Acurácia, no qual pode ser observado que os três melhores resultados foram alcançados empregando a técnica de pré-processamento.

Tabela 2 – Ranking Classificadores Cenário I

	<b>Acurácia</b>	<b>Ranking</b>
<b>KNN - Segmentada</b>	71,780%	1
<b>J48 - Segmentada</b>	34,645%	2
<b>SVM – Segmentada</b>	12,447%	3
<b>KNN- Original</b>	12,058%	4
<b>Naïve Bayes - Segmentada</b>	7,933%	5
<b>Naïve Bayes - Original</b>	4,256%	6
<b>J48 - Original</b>	3,627%	7
<b>SVM – Original</b>	1,597%	8

Fonte: Autoria Própria

#### 4.2. CENÁRIO II – HIERÁRQUICO X PLANO (ORIGINAL)

O segundo cenário buscou investigar o efeito da abordagem hierárquica de classificação por nó pai na melhoria da classificação das espécies de pássaros sem o uso do pré-processamento de segmentação. Na Tabela 3 são apresentados os resultados dos quatro classificadores empregados para cada um dos níveis da hierarquia utilizando as métricas Precision, Recall, F-Measure e Acurácia. No nível 1 os resultados são referentes à classificação das famílias para todas as instâncias, no nível 2 os resultados são referentes a classificação dos gêneros de todas as instâncias e no nível 3 os resultados são referentes a classificação das espécies de todas as instâncias. Pode-se notar como foi mencionado na (Seção 2.6.2), o principal problema dessa abordagem é que as amostras que são classificadas erroneamente no primeiro nível se propagam para todos os níveis subsequentes.


Tabela 3 – Resultados Cenário II

<b>Nível 1</b>	<b><i>Precision</i></b>	<b><i>Recall</i></b>	<b><i>F-Measure</i></b>	<b>Acurácia</b>
<b>J48</b>	0.2257	0.2074	0.2162	12,119%
<b>KNN</b>	0.3389	0.3677	0.3527	21,410%
<b>Naïve Bayes</b>	0.0929	0.0423	0.0581	02,994%
<b>SVM</b>	0.3185	0.5295	0.3978	24,827%
<b>Nível 2</b>	<b><i>Precision</i></b>	<b><i>Recall</i></b>	<b><i>F-Measure</i></b>	<b>Acurácia</b>
<b>J48</b>	0.0678	0.0052	0.0614	03,169%
<b>KNN</b>	0.1756	0.1661	0.1707	09,332%
<b>Naïve Bayes</b>	0.0383	0.0234	0.0291	01,476%
<b>SVM</b>	0.1441	0.1174	0.1294	06,917%
<b>Nível 3</b>	<b><i>Precision</i></b>	<b><i>Recall</i></b>	<b><i>F-Measure</i></b>	<b>Acurácia</b>
<b>J48</b>	0.0530	0.0379	0.0442	02,261%
<b>KNN</b>	0.1656	0.1412	0.1524	08,248%
<b>Naïve Bayes</b>	0.0483	0.0225	0.0319	01,456%
<b>SVM</b>	0.0924	0.1060	0.0987	05,193%

Fonte: Autoria Própria

Na Figura 20, é apresentado um gráfico com os valores de *F-Measure* dos quatro classificadores empregados para cada um dos níveis da árvore. Pode ser observado que na medida em que o classificador chega em um nível mais específico da hierarquia o erro acumulado dos níveis anteriores é propagado.





**Figura 20 - Gráfico *F-Measure* Cenário II**  
**Fonte: Autoria Própria**

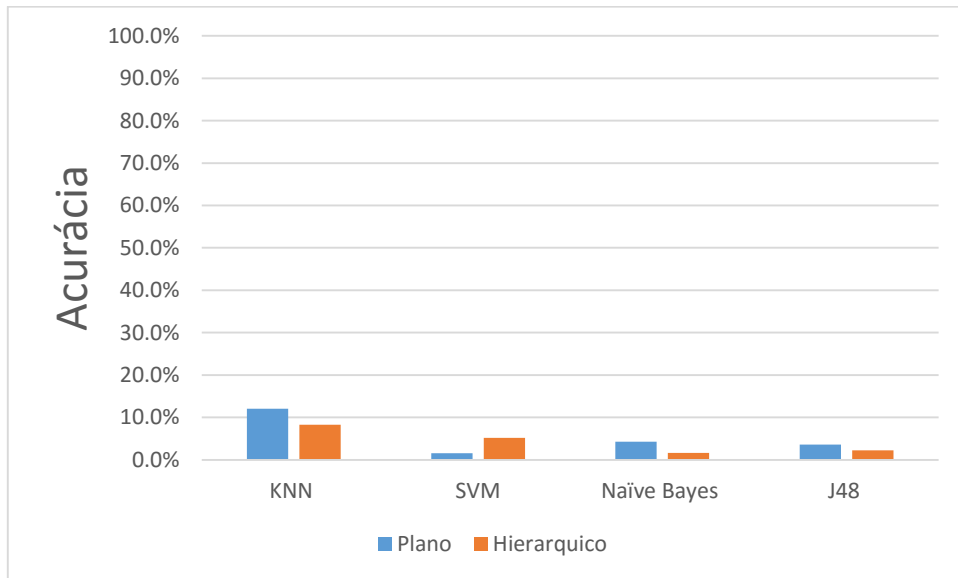
Na Tabela 4 é apresentado um ranking dos classificadores utilizando a abordagem Hierárquica levando em consideração a Acurácia geral (todos os níveis) e a abordagem plana ambos sem o pré-processamento de segmentação. Pode ser observado que, apenas o classificador SVM teve um efeito positivo quando aplicada a abordagem hierárquica, todos os outros classificadores obtiveram um efeito negativo quando se emprega a hierarquia.

Tabela 4 – Ranking Classificadores Cenário II		
	Acurácia	Ranking
<b>KNN - Plano</b>	12,058%	1
<b>KNN - Hierárquico</b>	8,248%	2
<b>SVM - Hierárquico</b>	5,193%	3
<b>Naïve Bayes - Plano</b>	4,256%	4
<b>J48 - Plano</b>	3,627%	5
<b>J48 - Hierárquico</b>	2,261%	6
<b>Naïve Bayes - Hierárquico</b>	1,621%	7
<b>SVM - Plano</b>	1,597%	8

**Fonte: Autoria Própria**

Na Figura 21 é apresentado um comparativo entre a abordagem de classificação plana e a abordagem de classificação hierárquica para a base original. Pode se analisar que a abordagem hierárquica propiciou um melhoramento na

classificação de apenas um dos classificadores sendo esse classificador o SVM, isso pode ser atribuído a sua natureza de binária na qual a medida que se percorre a árvore o número de classes a serem preditas diminui.



**Figura 21 - Comparativo Plano x Hierárquico**  
**Fonte: Autoria Própria**

#### 4.3. CENÁRIO III – HIERÁRQUICO X PLANO (SEGMENTADO)

O terceiro cenário buscou investigar o efeito da abordagem hierárquica de classificação por nó pai aliado ao pré-processamento com o objetivo de melhoria da classificação das espécies de pássaros. Na Tabela 5 são apresentados os resultados dos quatro classificadores empregados para cada um dos níveis da hierarquia utilizando as métricas Precision, Recall, F-Measure e Acurácia. No nível 1 os resultados são referentes à classificação das famílias, no nível 2 os resultados são referentes à classificação dos gêneros e no nível 3 os resultados são referentes à classificação das espécies.

Tabela 5 – Resultados Cenário III

Nível 1	<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>	Acurácia
<b>J48</b>	0.5505	0.5275	0.5387	36,868%
<b>KNN</b>	0.8509	0.8624	0.8566	74,922%
<b>Naïve Bayes</b>	0.0870	0.0492	0.0629	03,245%
<b>SVM</b>	0.3647	0.5629	0.4426	28,422%
Nível 2	<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>	Acurácia
<b>J48</b>	0.3922	0.3430	0.3659	22,395%
<b>KNN</b>	0.7735	0.7170	0.7442	59,260%
<b>Naïve Bayes</b>	0.0429	0.0598	0.0500	02,563%
<b>SVM</b>	0.2713	0.2262	0.2467	14,071%
Nível 3	<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>	Acurácia
<b>J48</b>	0.4024	0.3043	0.3465	20,958%
<b>KNN</b>	0.8154	0.6797	0.7414	58,907%
<b>Naïve Bayes</b>	0.0673	0.0355	0.0465	02,381%
<b>SVM</b>	0.2209	0.2544	0.2365	13,412%

Fonte: Autoria Própria

Na Figura 22, é apresentado um gráfico com os valores de *F-Measure* dos quatro classificadores empregados para cada um dos níveis da árvore.




Figura 22 - Gráfico F-measure

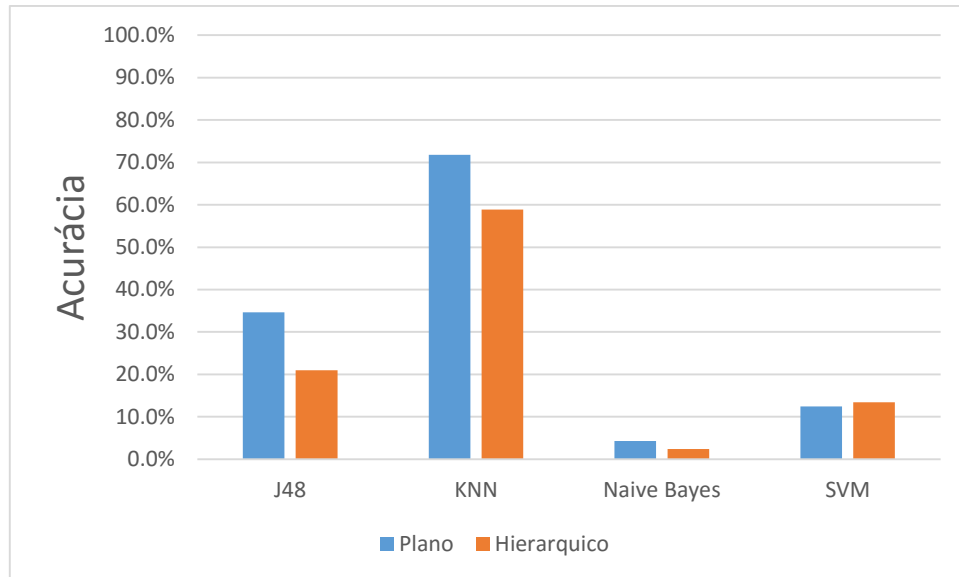
Fonte: Autoria Própria

Na Tabela 6 é apresentado um ranking dos classificadores utilizando a abordagem Hierárquica levando em consideração a Acurácia geral (todos os níveis) e a abordagem Plana, ambos com o pré-processamento de segmentação.

Tabela 6 – Ranking Classificadores Cenário III		
	<b>Acurácia</b>	<b>Ranking</b>
<b>KNN - Plano</b>	71,780%	1
<b>KNN - Hierárquico</b>	58,907%	2
<b>J48 - Plano</b>	34,645%	3
<b>J48 - Hierárquico</b>	20,958%	4
<b>SVM - Hierárquico</b>	13,412%	5
<b>SVM - Plano</b>	12,447%	6
<b>Naïve Bayes - Plano</b>	4,256%	7
<b>Naïve Bayes - Hierárquico</b>	2,381%	8

Fonte: Autoria Própria

Na Figura 23 é apresentado um comparativo entre a abordagem de classificação plana e a abordagem de classificação hierárquica para a base segmentada. Pode se analisar que a abordagem hierárquica na base segmentada propiciou um melhoramento apenas para o classificador SVM. Isto pode ser atribuído a característica binária das SVMs que se beneficiam de uma maior separação entre as classes devido a organização hierárquica. Entretanto os outros três classificadores sofreram uma queda de rendimento quando empregado a abordagem de classificação hierárquica.



**Figura 23 – Comparativo**  
**Fonte: Autoria Própria**

#### 4.4. CENÁRIO IV – HIERÁRQUICO SEGMENTADO X HIERÁRQUICO ORIGINAL


O quarto cenário comparou os resultados das duas bases hierárquicas. Como pode ser visto na Tabela 7.

Tabela 7 – Resultados Cenário IV


Nível 1- Original	<i>F-Measure</i>	Acurácia	Nível 1 - Segmentado	<i>F-Measure</i>	Acurácia
<b>J48</b>	0.2162	12,119%	<b>J48</b>	0.5387	36,868%
<b>KNN</b>	0.3527	21,410%	<b>KNN</b>	0.8566	74,922%
<b>Naïve Bayes</b>	0.0581	02,994%	<b>Naïve Bayes</b>	0.0629	03,245%
<b>SVM</b>	0.3978	24,827%	<b>SVM</b>	0.4426	28,422%
Nível 2 - Original	<i>F-Measure</i>	Acurácia	Nível 2 - Segmentado	<i>F-Measure</i>	Acurácia
<b>J48</b>	0.0614	03,169%	<b>J48</b>	0.3659	22,395%
<b>KNN</b>	0.1707	09,332%	<b>KNN</b>	0.7442	59,260%
<b>Naïve Bayes</b>	0.0291	01,476%	<b>Naïve Bayes</b>	0.0500	02,563%
<b>SVM</b>	0.1294	06,917%	<b>SVM</b>	0.2467	14,071%
Nível 3 - Original	<i>F-Measure</i>	Acurácia	Nível 3 - Segmentado	<i>F-Measure</i>	Acurácia
<b>J48</b>	0.0442	02,261%	<b>J48</b>	0.3465	20,958%
<b>KNN</b>	0.1524	08,248%	<b>KNN</b>	0.7414	58,907%
<b>Naïve Bayes</b>	0.0319	01,621%	<b>Naïve Bayes</b>	0.0465	02,381%
<b>SVM</b>	0.0987	05,193%	<b>SVM</b>	0.2365	13,412%

Fonte: Autoria Própria


Como pode ser visto na Tabela 7 a base Hierárquica tem um desempenho superior a base Hierárquica não segmentada. Nas figuras 24, 25 e 26 são apresentados gráficos de comparação de acurácia para cada um dos níveis da hierarquia das duas bases.



**Figura 24 - Comparativo Nível 1**  
**Fonte: Autoria Própria**



**Figura 25 - Comparativo Nível 2**  
**Fonte: Autoria Própria**



**Figura 26 - Comparativo Nível 3**  
**Fonte: Autoria Própria**

#### 4.5. CENÁRIO V – HIERÁRQUIA DE DOIS NÍVEIS

O quinto cenário comparou os resultados das duas bases hierárquicas, entretanto não levando em consideração o segundo nível referente ao gênero, portanto a classificação se deu apenas para o nível de Família e Espécie. Como pode ser visto na Tabela 8 e 9.

Tabela 8 – Resultados Cenário V – Base Não Segmentada

Nível 1	<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>	Acurácia
<b>J48</b>	0.2257	0.2074	0.2162	12,119%
<b>KNN</b>	0.3389	0.3677	0.3527	21,410%
<b>Naïve Bayes</b>	0.0929	0.0423	0.0581	02,994%
<b>SVM</b>	0.3185	0.5295	0.3978	24,827%
Nível 3	<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>	Acurácia
<b>J48</b>	0.0537	0.0337	0.0414	02,116%
<b>KNN</b>	0.1650	0.1259	0.1428	07,691%
<b>Naïve Bayes</b>	0.0429	0.0598	0.0500	01,600%
<b>SVM</b>	0.0723	0.0824	0.0987	04,733%

**Fonte: Autoria Própria**

Tabela 9 – Resultados Cenário V - Base Segmentada

<b>Nível 1</b>	<b>Precision</b>	<b>Recall</b>	<b>F-Measure</b>	<b>Acurácia</b>
<b>J48</b>	0.5505	0.5275	0.5387	36,868%
<b>KNN</b>	0.8509	0.8624	0.8566	74,922%
<b>Naïve Bayes</b>	0.0870	0.0492	0.0629	03,245%
<b>SVM</b>	0.3647	0.5629	0.4426	28,422%
<b>Nível 3</b>	<b>Precision</b>	<b>Recall</b>	<b>F-Measure</b>	<b>Acurácia</b>
<b>J48</b>	0.3642	0.3230	0.3424	20,372%
<b>KNN</b>	0.7248	0.6946	0.7094	58,434%
<b>Naïve Bayes</b>	0.0403	0.0523	0.0455	02,127%
<b>SVM</b>	0.2345	0.2032	0.2177	13,371%

Fonte: Autoria Própria

Como pode ser visto na Tabela 8 e 9, desconsiderar o nível de Gênero afetou negativamente o desempenho dos classificadores quando os mesmos são comparados as tabelas 3 e 5 respectivamente.

#### 4.6. ANÁLISE ADICIONAL

Nesta seção são apresentados um comparativo geral entre todos os métodos e classificadores empregados.

Na Tabela 7 são apresentados todos os classificadores e métodos abordados ordenados por Acurácia. A partir de sua análise pode se concluir que a abordagem de classificação hierárquica afetou positivamente somente o classificador SVM para base segmentada e não segmentada, já a segmentação afetou positivamente todos os classificadores inclusive quando comparamos os dois cenários Hierárquicos.



Tabela 7 – Ranking Geral de Classificadores

<b>Classificador</b>	<b>Pré-Processamento</b>	<b>Hierárquico</b>	<b>Acurácia</b>	<b>Ranking</b>
KNN	Sim	Não	71,780%	1
KNN	Sim	Sim	58,907%	2
J48	Sim	Não	34,645%	3
J48	Sim	Sim	20,958%	4
SVM	Sim	Sim	13,412%	5
SVM	Sim	Não	12,447%	6
KNN	Não	Não	12,058%	7
KNN	Não	Sim	8,248%	8
Naive Bayes	Sim	Não	7,933%	9
SVM	Não	Sim	5,193%	10
Naive Bayes	Não	Não	4,256%	11
J48	Não	Não	3,627%	12
J48	Não	Sim	2,261%	13
Naive Bayes	Sim	Sim	2,381%	14
Naive Bayes	Não	Sim	1,621%	15
SVM	Não	Não	1,597%	16

**Fonte: Autoria Própria**

## 5. CONSIDERAÇÕES FINAIS

A classificação de espécies de pássaros tem sido amplamente estudada nos últimos tempos. Neste trabalho foi realizada uma análise de qual seria o efeito isolado das técnicas de pré-processamento e classificação hierárquica no melhoramento da classificação das espécies de pássaros. Para a análise foi utilizada uma base de dados contendo 9688 cantos de pássaros com arquivos de meta-dados associados a cada arquivo. Com base nos experimentos, foi possível constatar o efeito das técnicas através dos três cenários propostos, fazendo uso de métricas que asseguraram um parâmetro de comparação confiável.

Analisando o primeiro cenário, onde foi testado o efeito da técnica de pré-processamento isoladamente, é possível verificar que ao se fazer uso do pré-processamento a taxa de acerto (Acurácia) das espécies de pássaro houve um aumento notável para cada um dos classificadores empregados quando comparado à base original sem pré-processamento, demonstrando assim a importância da aplicação desta técnica na tarefa de classificação.

Analisando o segundo cenário onde foram realizados testes do efeito da abordagem da classificação hierárquica (Nó local pai) isoladamente, é possível verificar que houve um aumento na taxa de acerto (Acurácia) das espécies de pássaros para somente um classificador (SVM) empregado quando comparado à base original não hierárquica, entretanto esta melhora não se caracterizou tão impactante quanto a alcançada no primeiro cenário.

No terceiro cenário foram realizados testes aliando as duas técnicas (pré-processamento e classificação hierárquica) onde foi possível verificar que novamente um único classificador dentre os quatro empregados obteve uma taxa de acerto maior, quando comparado com a base segmentada não hierárquica.

Com base nos resultados de cada cenário foi verificado que de fato há uma melhora na tarefa de classificação fazendo uso das técnicas de pré-processamento, entretanto para a classificação hierárquica o único classificador obteve um aumento em sua taxa de acerto.

Como futuras direções de pesquisa podem ser realizadas novos testes utilizando uma gama maior de classificadores, empregar classificadores distintos nos

diferentes níveis de hierarquia (Nó local pai seletivo) e ou fazer uso de outras técnicas de classificação hierárquica.

## 6. REFERÊNCIAS

- BECERRA, Néstor. **Reconhecimento Automático de Palavras Isoladas: Estudo e Aplicação dos Métodos Determinísticos e Estocástico**. Campinas: Unicamp, 1993.
- CHOU, C-H.; LEE, C-H; NI, H-W. **Bird Species Recognition by Comparing the HMMs of Syllables**. International Conference on Innovative Computing, Information and Control, Kumamoto, Japão, 2007.
- C.K. Catchpole and P.J.B. Slater, **Bird Songs: Biological Themes and Variations**, Cambridge University Press, 1995.
- CORCHADO, Emilio S.; SNASEL, Vaclav.; SEDANO, Javier.; Hassanien, Aboul E.; CALVO, Luis.; SLEZAK, Dominiki. **Soft Computing Models in Industrial and Environmental Applications**. 6<sup>th</sup> International Conference SOCO, 2011.
- FERNANDES, Anita Maria da Rocha. **Inteligência Artificial: Noções gerais**. Florianópolis: Visual Books, 2003.
- FREITAS, A. A.; CARVALO, A C.P.F. **A Tutorial on Hierarchical Classification with Applications in Bioinformatics**. p. 176-209, 2007.
- GEURTS, Pierre.; IRRTHUM, Alexandre.; LOUIS, Wehenkel. **Supervised learning with decision tree-based methods in computational and systems biology**. Molecular BioSystems, 2009.
- GIANNAKOPOULOS, Theodoros D. **Study and application of acoustic information for detection of harmful content, and fusion with visual information**. National & Kapodistrian University of Athens School of Science Program Of Postgraduate Studies, Athena's, 2009.
- GRIFFIN, Gilly . DANSEREAU, Maryse. GAUTHIER, Clément . **Categories of Invasiveness a Precautionary Approach**, Canadian Council on Animal Care, 2007. Workshop on Linking Biological Literature, Ontologies and Databases: Mining Biological Semantics, 2005.
- KAESTNER, Celso A. A.; LOPES, Marcelo T. **Identificação Automática de Pássaros Através de Cantos e Chamados**. Seminário de Iniciação Científica e Tecnológica da UTFPR, 2010.
- KWAN, C.; MEI, G.; ZHAO, X.; REN, Z.; XU, R. **Bird Classification Algorithms: Theory and Experimental Results**. IEEE International Conference on Acoustics Speech and Signal Processing, 2004.
- LOPES, Marcelo T.; KAESTNER, Celso A. A. **Montagem da Base de Cantos e Experimentos de Classificação**. Programa Institucional de Iniciação Científica, 2010.

LOPES, Marcelo T.; KAESTNER, Celso A. A.; SILLA JR., Carlos N.; KOERICH, Alessandro L. **Feature Set Comparison for Automatic Bird Species Identification**. IEEE International Conference on Systems, Man, and Cybernetics, 2011.

MELONI, Raphael Belo da Silva; MILIDIÚ, Ruy Luiz. **Classificação de Imagens de Sensoriamento Remoto usando SVM**. Rio de Janeiro, 2009.

PADHYE, A. **Classification methods**. 2015. Disponível em: <<http://www.d.umn.edu/padhy005/Chapter5.html>>. Acesso em: 22 de Setembro de 2015.

PLATT, John C. **Fast Training of Support Vector Machines using Sequential Minimal Optimization**. Microsoft Research, Redmond, 2000.

PRATT, William K. **Digital Image Processing**. 4<sup>th</sup> ed. Hoboken, NJ, 2007.

QUEIROZ, Rafael A. B.; MARAR, João F.; OKIDA, Cleber M. **Investigação dos Coeficientes Cepstrais da Frequência Mel Para Extração de Características de Gêneros Musicais**. UNESP, Faculdade de Ciências, 2006.

RABINER, Lawrence R.; SCHAFER, Ronald W. **Introduction to Digital Speech Processing**. Foundations and Trends in Signal Processing, 2007.

RAS, Zbigniew W.; WIECZORKOWSKA, Alicja A. **Advances in Music Information Retrieval**. Poland, p. 338, 2010.

RUSS, J.C. **The image processing handbook**. 2nd ed. CRC Press, 1995.

RUSSELL, Stuart.; NORVIG, Peter. **Inteligência Artificial**. 3a. edição. Rio Janeiro, Brasil: Campus, 2013.

SELIK, Melissa. BARANIUK, Richard. BLAIR, Adam. **Signal Energy vs. Signal Power**. OpenStax-CNX, 2014.

SILLA JR., Carlos N.; KAESTNER, Celso A. A. **Hierarchical Classification of Bird Species Using Their Audio Recorded Songs**. IEEE International Conference on Systems, Man And Cybernetics, 2013.

SILLA JR., Carlos N; FREITAS, Alex A. **A survey of hierarchical classification across different application domains**. Data Mining and Knowledge Discovery, vol. 22, no. 1-2, pp.31-72, 2011.

StatSoft. **Support Vector Machines (SVM) Introductory Overview**. Disponível em <<http://www.statsoft.com/Textbook/Support-Vector-Machines>>. Acesso em: 08 ago. 2015.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. Academic Press, San Diego, CA, 1999.

TZANETAKIS, George. COOK, Perry. **Musical Genre Classification of Audio Signals**. IEEE Transactions on Speech and Audio Processing, vol 10, 2002.

Wiki ICMC USP. Disponível em  
<[http://wiki.icmc.usp.br/images/6/68/Aula\\_7\\_TEBD\\_2013\\_NB.pdf](http://wiki.icmc.usp.br/images/6/68/Aula_7_TEBD_2013_NB.pdf)>. Acesso em: 08  
ago. 2015.

Xeno-Canto Web Site. Disponível em <<http://xeno-canto.org/>>. Acesso em: 08 mar.  
2014.

## APÊNDICE A – LISTA DE ÁUDIOS POR ESPÉCIE (ORIGINAL)

Família	Gênero	Espécie	Áudios	Família	Gênero	Espécie	Áudios
Accipitridae	Buteo	nitidus	14	Cotingidae	Lipaugus	lanioides	11
Accipitridae	Buteogallus	urubitinga	11	Cotingidae	Lipaugus	vociferans	22
Accipitridae	Leucopternis	kuhli	11	Cotingidae	Procnias	nudicollis	30
Accipitridae	Rupornis	magnirostris	31	Cotingidae	Tijuca	atra	18
Accipitridae	Spizaetus	tyrannus	25	Cracidae	Crax	fasciolata	17
Alcedinidae	Chloroceryle	amazona	13	Cracidae	Ortalis	canicollis	18
Alcedinidae	Megaceryle	torquata	17	Cracidae	Penelope	obscura	17
Anatidae	Dendrocygna	viduata	15	Cuculidae	Crotophaga	ani	18
Anhimidae	Chauna	torquata	11	Cuculidae	Crotophaga	major	13
Aramidae	Aramus	guarauna	11	Cuculidae	Dromococcyx	phasianellus	11
Ardeidae	Butorides	striata	11	Cuculidae	Guira	guira	32
Ardeidae	Zebrilus	undulatus	10	Cuculidae	Piaya	cayana	30
Bucconidae	Malacoptila	striata	11	Cuculidae	Tapera	naevia	23
Caprimulgidae	Lurocalis	semitorquatus	15	Donacobiidae	Donacobius	atricapilla	21
Caprimulgidae	Nyctidromus	albicollis	26	Emberizidae	Ammodramus	humeralis	21
Caprimulgidae	Nyctiphrynus	ocellatus	11	Emberizidae	Arremon	flavirostris	12
Caprimulgidae	Setopagis	parvulus	13	Emberizidae	Arremon	franciscanus	11
Cardinalidae	Amaurospiza	moesta	12	Emberizidae	Arremon	semitorquatus	13
Cardinalidae	Caryothraustes	canadensis	11	Emberizidae	Arremon	taciturnus	13
Cardinalidae	Cyanocompsa	brissonii	19	Emberizidae	Zonotrichia	capensis	37
Cardinalidae	Cyanocompsa	cyanoides	11	Falconidae	Caracara	plancus	15
Cardinalidae	Granatellus	pelzelni	13	Falconidae	Herpetotheres	cachinnans	16
Cardinalidae	Habia	rubica	29	Falconidae	Ibycter	americanus	16
Cardinalidae	Saltator	atricollis	28	Falconidae	Micrastur	mintoni	17
Cardinalidae	Saltator	coerulescens	11	Falconidae	Micrastur	ruficollis	40
Cardinalidae	Saltator	fuliginosus	22	Falconidae	Micrastur	semitorquatus	22
Cardinalidae	Saltator	maximus	19	Falconidae	Milvago	chimachima	23
Cardinalidae	Saltator	similis	38	Formicariidae	Chamaeza	campanisona	24
Cariamidae	Cariama	cristata	17	Formicariidae	Chamaeza	meruloides	25
Charadriidae	Vanellus	chilensis	35	Formicariidae	Chamaeza	ruficauda	27
Coerebidae	Coereba	flaveola	37	Formicariidae	Formicarius	nalis	12
Columbidae	Columbina	squamata	19	Formicariidae	Formicarius	colma	29
Columbidae	Geotrygon	montana	13	Fringillidae	Chlorophonia	cyanea	11
Columbidae	Leptotila	rufaxilla	16	Fringillidae	Euphonia	chalybea	15
Columbidae	Leptotila	verreauxi	24	Fringillidae	Euphonia	chlorotica	25
Columbidae	Patagioenas	picazuro	15	Fringillidae	Euphonia	pectoralis	17
Columbidae	Patagioenas	plumbea	36	Fringillidae	Euphonia	violacea	18
Columbidae	Patagioenas	subvinacea	13	Furnariidae	Anabazenops	fuscus	29
Conopophagidae	Conopophaga	lineata	29	Furnariidae	Anumbius	annumbi	13

Conopophagidae	Conopophaga	melanops	24	Furnariidae	Asthenes	moreirae	22
Corvidae	Cyanocorax	caeruleus	19	Furnariidae	Automolus	leucophthalmus	36
Corvidae	Cyanocorax	chrysops	21	Furnariidae	Automolus	ochrolaemus	17
Corvidae	Cyanocorax	crystalinus	13	Furnariidae	Automolus	paraensis	15
Corvidae	Cyanocorax	cyanopogon	21	Furnariidae	Automolus	rufipileatus	11
Cotingidae	Carpornis	cucullata	19	Furnariidae	Campylorhamphus	falcularius	23
Furnariidae	Campylorhamphus	procurvoides	17	Furnariidae	Xiphorhynchus	guttatus	35
Furnariidae	Campylorhamphus	trochilirostris	13	Furnariidae	Xiphorhynchus	obsoletus	11
Furnariidae	Certhiopsis	cinnamomeus	26	Furnariidae	Xiphorhynchus	spixii	12
Furnariidae	Cichlocolaptes	leucophrus	15	Galbulidae	Galbula	cyanicollis	12
Furnariidae	Clibanornis	dendrocolaptesoides	16	Galbulidae	Galbula	leucogastra	12
Furnariidae	Cranioleuca	obsoleta	12	Galbulidae	Galbula	ruficauda	29
Furnariidae	Cranioleuca	pallida	17	Galbulidae	Jacamerops	aureus	15
Furnariidae	Cranioleuca	vulpina	19	Grallariidae	Grallaria	varia	19
Furnariidae	Deconychura	longicauda	13	Grallariidae	Hylopezus	nattereri	33
Furnariidae	Dendrexetastes	rufigula	14	Grallariidae	Myrmothera	campanisona	16
Furnariidae	Dendrocincla	turdina	12	Hirundinidae	Notiochelidon	cyanoleuca	13
Furnariidae	Dendrocolaptes	certhia	21	Hirundinidae	Progne	chalybea	15
Furnariidae	Dendrocolaptes	platyrostris	13	Hirundinidae	Progne	tapera	13
Furnariidae	Dendroplex	picus	18	Hirundinidae	Stelgidopteryx	ruficollis	11
Furnariidae	Furnarius	figulus	18	Icteridae	Agelaioides	badius	11
Furnariidae	Furnarius	leucopus	13	Icteridae	Cacicus	cela	14
Furnariidae	Furnarius	rufus	23	Icteridae	Cacicus	chrysopterus	21
Furnariidae	Glyphorhynchus	spirurus	16	Icteridae	Cacicus	haemorrhous	25
Furnariidae	Hylexetastes	uniformis	14	Icteridae	Chrysomus	ruficapillus	18
Furnariidae	Hylocryptus	rectirostris	11	Icteridae	Gnorimopsar	chopi	29
Furnariidae	Lepidocolaptes	albolineatus	11	Icteridae	Icterus	pyrrhopterus	14
Furnariidae	Lepidocolaptes	angustirostris	14	Icteridae	Molothrus	bonariensis	12
Furnariidae	Leptasthenura	setaria	10	Icteridae	Psarocolius	decumanus	15
Furnariidae	Lochmias	nematura	31	Icteridae	Pseudoleistes	guirahuro	17
Furnariidae	Phacellodomus	erythrophthalmus	15	Icteridae	Sturnella	superciliaris	13
Furnariidae	Phacellodomus	ferrugineigula	17	Jacanidae	Jacana	jacana	16
Furnariidae	Phacellodomus	rufifrons	13	Mimidae	Mimus	saturninus	29
Furnariidae	Philydor	atricapillus	19	Momotidae	Baryphthengus	ruficapillus	23
Furnariidae	Philydor	rufum	11	Motacillidae	Anthus	hellmayri	21
Furnariidae	Phleocryptes	melanops	11	Motacillidae	Anthus	lutescens	15
Furnariidae	Sclerurus	mexicanus	13	Mysteridae	Mystery	mystery	49
Furnariidae	Sclerurus	scansor	30	Nyctibiidae	Nyctibius	griseus	18
Furnariidae	Sittasomus	griseicapillus	53	Odontophoridae	Odontophorus	capueira	13
Furnariidae	Synallaxis	albescens	15	Parulidae	Basileuterus	culicivorus	45
Furnariidae	Synallaxis	albilora	15	Parulidae	Geothlypis	velata	24
Furnariidae	Synallaxis	cinerascens	24	Parulidae	Myiothlypis	flaveola	32



Furnariidae	Synallaxis	frontalis	29	Parulidae	Myiothlypis	leucoblephara	26
Furnariidae	Synallaxis	ruficapilla	36	Parulidae	Myiothlypis	rivularis	22
Furnariidae	Synallaxis	rutilans	12	Parulidae	Setophaga	pitiayumi	22
Furnariidae	Synallaxis	spixi	30	Picidae	Campephilus	melanoleucos	12
Furnariidae	Syndactyla	rufosuperciliata	23	Picidae	Campephilus	robustus	11
Furnariidae	Xenops	minutus	21	Picidae	Campephilus	rubricollis	11
Furnariidae	Xenops	rutilans	13	Picidae	Celeus	flavescens	17
Furnariidae	Xiphocolaptes	albicollis	15	Picidae	Celeus	flavus	15
Furnariidae	Xiphorhynchus	fuscus	40	Picidae	Celeus	obrieni	26
Picidae	Celeus	torquatus	15	Psophiidae	Psophia	viridis	14
Picidae	Colaptes	campestris	26	Rallidae	Aramides	cajaneus	23
Picidae	Colaptes	melanochloros	17	Rallidae	Aramides	saracura	26
Picidae	Dryocopus	lineatus	25	Rallidae	Gallinula	galeata	15
Picidae	Melanerpes	candidus	17	Rallidae	Laterallus	melanophaius	25
Picidae	Melanerpes	cruentatus	11	Rallidae	Laterallus	viridis	21
Picidae	Melanerpes	flavifrons	13	Rallidae	Pardirallus	nigricans	26
Picidae	Piculus	aurulentus	17	Ramphastidae	Pteroglossus	aracari	13
Picidae	Picumnus	temminckii	11	Ramphastidae	Ramphastos	dicolorus	22
Picidae	Veniliornis	spilogaster	15	Ramphastidae	Ramphastos	toco	12
Pipridae	Antilophia	galeata	22	Ramphastidae	Ramphastos	tucanus	13
Pipridae	Chiroxiphia	caudata	52	Ramphastidae	Ramphastos	vitellinus	32
Pipridae	Chiroxiphia	pareola	28	Rhinocryptidae	Eleoscytalopus	indigoticus	31
Pipridae	Dixiphia	rubrocapilla	22	Rhinocryptidae	Merulaxis	ater	28
Pipridae	Ilicura	militaris	13	Rhinocryptidae	Psilorhamphus	guttatus	19
Pipridae	Manacus	manacus	28	Rhinocryptidae	Scytalopus	novacapitalis	11
Pipridae	Neopelma	pallescens	13	Rhinocryptidae	Scytalopus	speluncae	34
Pipridae	Tyranneutes	stolzmanni	13	Scolopacidae	Gallinago	paraguaiae	11
Polioptilidae	Polioptila	dumicola	27	Strigidae	Asio	flammeus	15
Polioptilidae	Polioptila	plumbea	15	Strigidae	Athene	cunicularia	17
Polioptilidae	Ramphocaenus	melanurus	35	Strigidae	Glaucidium	brasilianum	22
Psittacidae	Amazona	aestiva	17	Strigidae	Glaucidium	hardyi	12
Psittacidae	Amazona	amazonica	14	Strigidae	Glaucidium	minutissimum	19
Psittacidae	Amazona	farinosa	17	Strigidae	Megascops	atricapilla	17
Psittacidae	Amazona	ochrocephala	11	Strigidae	Megascops	choliba	29
Psittacidae	Amazona	vinacea	15	Strigidae	Megascops	watsonii	15
Psittacidae	Anodorhynchus	hyacinthinus	34	Strigidae	Pseudoscops	clamator	12
Psittacidae	Ara	ararauna	19	Strigidae	Pulsatrix	koeniswaldiana	25
Psittacidae	Ara	chloropterus	15	Strigidae	Strix	hylophila	14
Psittacidae	Aratinga	aurea	19	Thamnophilidae	Batara	cinerea	36
Psittacidae	Aratinga	leucophthalma	21	Thamnophilidae	Biatas	nigropectus	21
Psittacidae	Brotogeris	chiriri	19	Thamnophilidae	Cercomacra	cinerascens	17

Psittacidae	Brotogeris	chrysoptera	15	Thamnophilid ae	Cercomacra	manu	12
Psittacidae	Brotogeris	tirica	23	Thamnophilid ae	Cercomacra	melanaria	15
Psittacidae	Deroptylus	accipitrinus	12	Thamnophilid ae	Cercomacra	nigrescens	22
Psittacidae	Diopsittaca	nobilis	17	Thamnophilid ae	Cercomacra	tyrannina	12
Psittacidae	Forpus	xanthopterygius	17	Thamnophilid ae	Cymbilaimus	lineatus	12
Psittacidae	Myiopsitta	monachus	11	Thamnophilid ae	Drymophila	ferruginea	36
Psittacidae	Orthopsittaca	manilata	14	Thamnophilid ae	Drymophila	genei	12
Psittacidae	Pionites	leucogaster	12	Thamnophilid ae	Drymophila	malura	31
Psittacidae	Pionus	maximiliani	22	Thamnophilid ae	Drymophila	ochropyga	35
Psittacidae	Primolius	maracana	15	Thamnophilid ae	Drymophila	rubricollis	22
Psittacidae	Pyrrhura	amazonum	13	Thamnophilid ae	Drymophila	squamata	36
Psittacidae	Pyrrhura	frontalis	24	Thamnophilid ae	Dysithamnus	mentalis	39
Psittacidae	Tricharia	malachitacea	13	Thamnophilid ae	Dysithamnus	stictothorax	27
Thamnophilidae	Dysithamnus	xanthopterus	18	Thamnophilid ae	Stymphalornis	acutirostris	11
Thamnophilidae	Formicivora	grisea	19	Thamnophilid ae	Taraba	major	25
Thamnophilidae	Formicivora	rufa	17	Thamnophilid ae	Terenura	maculata	16
Thamnophilidae	Formicivora	serrana	13	Thamnophilid ae	Thamnomanes	caesius	21
Thamnophilidae	Herpsilochmus	atricapillus	17	Thamnophilid ae	Thamnomanes	saturninus	11
Thamnophilidae	Herpsilochmus	longirostris	15	Thamnophilid ae	Thamnophilus	aethiops	23
Thamnophilidae	Herpsilochmus	rufimarginatus	38	Thamnophilid ae	Thamnophilus	amazonicus	17
Thamnophilidae	Herpsilochmus	sellowi	12	Thamnophilid ae	Thamnophilus	ambiguus	17
Thamnophilidae	Hylophylax	naevius	17	Thamnophilid ae	Thamnophilus	caerulescens	35
Thamnophilidae	Hylophylax	punctulatus	13	Thamnophilid ae	Thamnophilus	doliatus	29
Thamnophilidae	Hypocnemis	cantator	12	Thamnophilid ae	Thamnophilus	palliatu	20
Thamnophilidae	Hypocnemis	hypoxantha	15	Thamnophilid ae	Thamnophilus	pelzelni	15
Thamnophilidae	Hypocnemis	peruviana	23	Thamnophilid ae	Thamnophilus	punctatus	11
Thamnophilidae	Hypocnemis	striata	24	Thamnophilid ae	Thamnophilus	ruficapillus	16
Thamnophilidae	Hypoedaleus	guttatus	31	Thamnophilid ae	Thamnophilus	schistaceus	12
Thamnophilidae	Isleria	hauwelli	18	Thamnophilid ae	Thamnophilus	stictocephalus	14
Thamnophilidae	Mackenziaena	leachii	19	Thamnophilid ae	Thamnophilus	torquatus	14
Thamnophilidae	Mackenziaena	severa	30	Thamnophilid ae	Willisornis	vidua	16
Thamnophilidae	Microrhopias	quixensis	20	Thraupidae	Cissopis	leverianus	12
Thamnophilidae	Myrmeciza	atrothorax	19	Thraupidae	Conirostrum	speciosum	13
Thamnophilidae	Myrmeciza	hemimelaena	13	Thraupidae	Coryphospiza	melanotis	11
Thamnophilidae	Myrmeciza	loricata	14	Thraupidae	Coryphospingus	pileatus	13
Thamnophilidae	Myrmeciza	ruficauda	12	Thraupidae	Dacnis	cayana	11

Thamnophilidae	Myrmeciza	squamosa	31	Thraupidae	Emberizoides	herbicola	16
Thamnophilidae	Myrmoborus	leucophrys	11	Thraupidae	Embernagra	platensis	13
Thamnophilidae	Myrmoborus	myotherinus	27	Thraupidae	Haplospiza	unicolor	23
Thamnophilidae	Myrmorchilus	strigilatus	12	Thraupidae	Hemithraupis	guira	19
Thamnophilidae	Myrmotherula	axillaris	18	Thraupidae	Hemithraupis	ruficapilla	13
Thamnophilidae	Myrmotherula	brachyura	15	Thraupidae	Nemosia	pileata	13
Thamnophilidae	Myrmotherula	longipennis	16	Thraupidae	Orchesticus	abeillei	14
Thamnophilidae	Myrmotherula	luctuosa	17	Thraupidae	Orthogonys	chloricterus	13
Thamnophilidae	Myrmotherula	menetriesii	13	Thraupidae	Oryzoborus	angolensis	12
Thamnophilidae	Myrmotherula	multostriata	13	Thraupidae	Paroaria	dominicana	11
Thamnophilidae	Myrmotherula	unicolor	17	Thraupidae	Pipraeidea	melanonota	11
Thamnophilidae	Percnostola	ruffrons	13	Thraupidae	Poospiza	cabanisi	15
Thamnophilidae	Phlegopsis	nigromaculata	12	Thraupidae	Pyrrhocomma	ruficeps	12
Thamnophilidae	Pygmytila	stellaris	15	Thraupidae	Ramphocelus	bresilius	26
Thamnophilidae	Pyriglena	atra	11	Thraupidae	Sicalis	citrina	11
Thamnophilidae	Pyriglena	leuconota	22	Thraupidae	Sicalis	flaveola	25
Thamnophilidae	Pyriglena	leucoptera	41	Thraupidae	Sporophila	caerulescens	25
Thamnophilidae	Rhegmatorhina	gymnops	11	Thraupidae	Sporophila	falcirostris	23
Thamnophilidae	Rhopias	gularis	35	Thraupidae	Sporophila	frontalis	25
Thamnophilidae	Sakesphorus	luctuosus	12	Thraupidae	Sporophila	leucoptera	15
Thamnophilidae	Schistocichla	ruffacies	18	Thraupidae	Sporophila	lineola	13
Thamnophilidae	Sclateria	naevia	12	Thraupidae	Sporophila	nigricollis	15
Thraupidae	Stephanophorus	diadematus	16	Troglodytidae	Microcerculus	marginatus	18
Thraupidae	Tachyphonus	coronatus	26	Troglodytidae	Odontorchilus	cinereus	16
Thraupidae	Tangara	cyanocephala	12	Troglodytidae	Pheugopedius	coraya	12
Thraupidae	Tangara	desmaresti	12	Troglodytidae	Pheugopedius	genibarbis	29
Thraupidae	Thraupis	ornata	17	Troglodytidae	Troglodytes	aedon	36
Thraupidae	Thraupis	palmarum	23	Trogonidae	Trogon	curucui	14
Thraupidae	Thraupis	sayaca	25	Trogonidae	Trogon	melanurus	15
Thraupidae	Tiaris	fuliginosus	19	Trogonidae	Trogon	rufus	26
Thraupidae	Trichothraupis	melanops	21	Trogonidae	Trogon	surrucura	29
Thraupidae	Volatinia	jacarina	22	Trogonidae	Trogon	viridis	24
Threskiornithidae	Theristicus	caudatus	20	Turdidae	Turdus	albicollis	25
Tinamidae	Crypturellus	cinereus	14	Turdidae	Turdus	amaurochalinus	22
Tinamidae	Crypturellus	noctivagus	11	Turdidae	Turdus	flavipes	34
Tinamidae	Crypturellus	obsoletus	29	Turdidae	Turdus	leucomelas	35
Tinamidae	Crypturellus	parvirostris	14	Turdidae	Turdus	rufiventris	51
Tinamidae	Crypturellus	soui	16	Turdidae	Turdus	subalaris	18

Tinamidae	Crypturellus	strigulosus	13	Tyrannidae	Attila	cinnamomeus	11
Tinamidae	Crypturellus	tataupa	18	Tyrannidae	Attila	phoenicurus	20
Tinamidae	Crypturellus	undulatus	18	Tyrannidae	Attila	rufus	35
Tinamidae	Nothura	maculosa	11	Tyrannidae	Attila	spadiceus	15
Tinamidae	Taoniscus	nanus	17	Tyrannidae	Camptostoma	obsoletum	41
Tityridae	Onychorhynchus	coronatus	11	Tyrannidae	Capsiempis	flaveola	20
Tityridae	Pachyramphus	castaneus	23	Tyrannidae	Cnemotriccus	fuscatus	18
Tityridae	Pachyramphus	marginatus	17	Tyrannidae	Colonia	colonus	15
Tityridae	Pachyramphus	polychopterus	24	Tyrannidae	Contopus	cinereus	17
Tityridae	Pachyramphus	viridis	19	Tyrannidae	Corythopsis	delalandi	21
Tityridae	Schiffornis	turdina	13	Tyrannidae	Elaenia	cristata	15
Tityridae	Schiffornis	virescens	29	Tyrannidae	Elaenia	flavogaster	24
Trochilidae	Aphantochroa	cirrochloris	12	Tyrannidae	Elaenia	mesoleuca	14
Trochilidae	Clytolaema	rubricauda	18	Tyrannidae	Elaenia	obscura	10
Trochilidae	Colibri	serrirostris	19	Tyrannidae	Elaenia	parvirostris	13
Trochilidae	Florisuga	fusca	11	Tyrannidae	Elaenia	spectabilis	21
Trochilidae	Hylocharis	cyanus	15	Tyrannidae	Empidonomus	varius	17
Trochilidae	Leucochloris	albicollis	13	Tyrannidae	Euscarthmus	meloryphus	13
Trochilidae	Phaethornis	eurynome	25	Tyrannidae	Euscarthmus	rufomarginatus	13
Trochilidae	Phaethornis	ruber	17	Tyrannidae	Fluvicola	nengeta	13
Trochilidae	Ramphodon	naevius	15	Tyrannidae	Gubernetes	yetapa	13
Trochilidae	Stephanoxis	lalandi	14	Tyrannidae	Hemitriccus	diops	18
Trochilidae	Thalurania	glaucopis	17	Tyrannidae	Hemitriccus	furcatus	13
Troglodytidae	Campylorhynchus	turdinus	21	Tyrannidae	Hemitriccus	griseipectus	17
Troglodytidae	Cantorchilus	guarayanus	15	Tyrannidae	Hemitriccus	margaritaceiventris	23
Troglodytidae	Cantorchilus	leucotis	21	Tyrannidae	Hemitriccus	minus	13
Troglodytidae	Cantorchilus	longirostris	56	Tyrannidae	Hemitriccus	minor	19
Troglodytidae	Cistothorus	platensis	13	Tyrannidae	Hemitriccus	obsoletus	12
Troglodytidae	Cyphorhinus	arada	11	Tyrannidae	Hemitriccus	orbitatus	17
Tyrannidae	Hirundinea	ferruginea	17	Tyrannidae	Myiodynastes	maculatus	29
Tyrannidae	Lathrotriccus	euleri	39	Tyrannidae	Myiopagis	caniceps	24
Tyrannidae	Legatus	leucophaeus	25	Tyrannidae	Myiopagis	viridicata	19
Tyrannidae	Leptopogon	amaurocephalus	19	Tyrannidae	Myiophobus	fasciatus	23
Tyrannidae	Lophotriccus	galeatus	19	Tyrannidae	Myiornis	auricularis	24
Tyrannidae	Machetornis	rixosa	16	Tyrannidae	Myiornis	ecaudatus	14
Tyrannidae	Megarynchus	pitangua	30	Tyrannidae	Myiozetetes	similis	35
Tyrannidae	Mionectes	oleagineus	13	Tyrannidae	Ornithion	inermis	17
Tyrannidae	Mionectes	rufiventris	13	Tyrannidae	Phaeomyias	murina	15
Tyrannidae	Muscipira	vetula	16	Tyrannidae	Phyllomyias	burmeisteri	15
Tyrannidae	Myiarchus	ferox	19	Tyrannidae	Phyllomyias	fasciatus	22
Tyrannidae	Myiarchus	swainsoni	21	Tyrannidae	Phyllomyias	virescens	12
Tyrannidae	Myiarchus	tyrannulus	19	Tyrannidae	Phylloscartes	kronei	11
Tyrannidae	Phylloscartes	oustaleti	12	Tyrannidae	Pitangus	sulphuratus	33

Tyrannidae	Piprites	chloris	24	Tyrannidae	Platyrinchus	mystaceus	27
Tyrannidae	Platyrinchus	platyrhynchus	16				
Tyrannidae	Poecilotriccus	plumbeiceps	18				
Tyrannidae	Ramphotrigon	megacephalum	21				
Tyrannidae	Rhytipterna	simplex	15				
Tyrannidae	Serpophaga	subcristata	21				
Tyrannidae	Sirystes	sibilator	23				
Tyrannidae	Suiriri	suiriri	13				
Tyrannidae	Todirostrum	cinereum	12				
Tyrannidae	Todirostrum	poliocephalum	20				
Tyrannidae	Tolmomyias	assimilis	12				
Tyrannidae	Tolmomyias	flaviventris	22				
Tyrannidae	Tolmomyias	poliocephalus	17				
Tyrannidae	Tolmomyias	sulphurescens	42				
Tyrannidae	Tyrannus	melancholicus	23				
Tyrannidae	Zimmerius	acer	15				
Vireonidae	Cyclarhis	gujanensis	62				
Vireonidae	Hylophilus	amaurocephalus	19				
Vireonidae	Hylophilus	poicilotis	21				
Vireonidae	Hylophilus	semicinereus	13				
Vireonidae	Hylophilus	thoracicus	11				
Vireonidae	Vireo	olivaceus	37				

## APÊNDICE B – LISTA DE ÁUDIOS POR ESPÉCIE (SEGMENTADA)

Accipitridae	Buteo	nitidus	69	Cotingidae	Lipaugus	lanioides	52
Accipitridae	Buteogallus	urubitinga	99	Cotingidae	Lipaugus	vociferans	178
Accipitridae	Leucopternis	kuhli	71	Cotingidae	Procnias	nudicollis	375
Accipitridae	Rupornis	magnirostris	213	Cotingidae	Tijuca	atra	125
Accipitridae	Spizaetus	tyrannus	178	Cracidae	Crax	fasciolata	161
Alcedinidae	Chloroceryle	amazona	56	Cracidae	Ortalis	canicollis	97
Alcedinidae	Megaceryle	torquata	75	Cracidae	Penelope	obscura	169
Anatidae	Dendrocygna	viduata	62	Cuculidae	Crotophaga	ani	80
Anhimidae	Chauna	torquata	64	Cuculidae	Crotophaga	major	79
Aramidae	Aramus	guarauna	44	Cuculidae	Dromococcyx	phasianellus	84
Ardeidae	Butorides	striata	54	Cuculidae	Guira	guira	222
Ardeidae	Zebrius	undulatus	111	Cuculidae	Piaya	cayana	192
Bucconidae	Malacoptila	striata	84	Cuculidae	Tapera	naevia	128
Caprimulgidae	Lurocalis	semitorquatus	100	Donacobiidae	Donacobius	atricapilla	77
Caprimulgidae	Nyctidromus	albicollis	211	Emberizidae	Ammodramus	humeralis	111
Caprimulgidae	Nyctiphrynus	ocellatus	46	Emberizidae	Arremon	flavirostris	86
Caprimulgidae	Setopagis	parvulus	94	Emberizidae	Arremon	franciscanus	99
Cardinalidae	Amaurospiza	moesta	99	Emberizidae	Arremon	semitorquatus	143
Cardinalidae	Caryothraustes	canadensis	114	Emberizidae	Arremon	taciturnus	70
Cardinalidae	Cyanocompsa	brissonii	89	Emberizidae	Zonotrichia	capensis	236
Cardinalidae	Cyanocompsa	cyanoides	89	Falconidae	Caracara	plancus	103
Cardinalidae	Granatellus	pelzelni	116	Falconidae	Herpetotheres	cachinnans	264
Cardinalidae	Habia	rubica	219	Falconidae	Ibycter	americanus	121
Cardinalidae	Saltator	atricollis	149	Falconidae	Micrastur	mintoni	216
Cardinalidae	Saltator	coerulescens	45	Falconidae	Micrastur	ruficollis	699
Cardinalidae	Saltator	fuliginosus	147	Falconidae	Micrastur	semitorquatus	193
Cardinalidae	Saltator	maximus	154	Falconidae	Milvago	chimachima	131
Cardinalidae	Saltator	similis	186	Formicariidae	Chamaeza	campanisona	141
Cariamidae	Cariama	cristata	163	Formicariidae	Chamaeza	meruloides	118
Charadriidae	Vanellus	chilensis	154	Formicariidae	Chamaeza	ruficauda	243
Coerebidae	Coereba	flaveola	178	Formicariidae	Formicarius	analis	93
Columbidae	Columbina	squamata	162	Formicariidae	Formicarius	colma	166
Columbidae	Geotrygon	montana	70	Fringillidae	Chlorophonia	cyanea	102
Columbidae	Leptotila	rufaxilla	151	Fringillidae	Euphonia	chalybea	172
Columbidae	Leptotila	verreauxi	187	Fringillidae	Euphonia	chlorotica	157
Columbidae	Patagioenas	picazuro	82	Fringillidae	Euphonia	pectoralis	114
Columbidae	Patagioenas	plumbea	251	Fringillidae	Euphonia	violacea	175
Columbidae	Patagioenas	subvinacea	121	Furnariidae	Anabazenops	fuscus	208
Conopophagidae	Conopophaga	lineata	193	Furnariidae	Anumbius	annumbi	34
Conopophagidae	Conopophaga	melanops	174	Furnariidae	Asthenes	moreirae	127

Corvidae	Cyanocorax	caeruleus	120	Furnariidae	Automolus	leucophthalmus	308
Corvidae	Cyanocorax	chrysops	285	Furnariidae	Automolus	ochrolaemus	171
Corvidae	Cyanocorax	cristatellus	75	Furnariidae	Automolus	paraensis	158
Corvidae	Cyanocorax	cyanopogon	167	Furnariidae	Automolus	rufipileatus	74
Cotingidae	Carpornis	cucullata	100	Furnariidae	Campylorhamphus	falcularius	126
Furnariidae	Campylorhamphus	procurvoides	247	Furnariidae	Xiphorhynchus	guttatus	234
Furnariidae	Campylorhamphus	trochilirostris	50	Furnariidae	Xiphorhynchus	obsoletus	53
Furnariidae	Certhiaxis	cinnamomeus	105	Furnariidae	Xiphorhynchus	spixii	67
Furnariidae	Cichocolaptes	leucophrus	190	Galbulidae	Galbula	cyanicollis	93
Furnariidae	Clibanornis	dendrocolaptoides	128	Galbulidae	Galbula	leucogastra	79
Furnariidae	Cranioleuca	obsoleta	68	Galbulidae	Galbula	ruficauda	230
Furnariidae	Cranioleuca	pallida	115	Galbulidae	Jacamerops	aureus	106
Furnariidae	Cranioleuca	vulpina	135	Grallariidae	Grallaria	varia	97
Furnariidae	Deconychura	longicauda	86	Grallariidae	Hylopezus	nattereri	261
Furnariidae	Dendrexetastes	rufigula	76	Grallariidae	Myrmothera	campanisona	115
Furnariidae	Dendrocincla	turdina	46	Hirundinidae	Notiochelidon	cyanoleuca	56
Furnariidae	Dendrocolaptes	certhia	177	Hirundinidae	Progne	chalybea	152
Furnariidae	Dendrocolaptes	platyrostris	71	Hirundinidae	Progne	tapera	81
Furnariidae	Dendroplex	picus	80	Hirundinidae	Stelgidopteryx	ruficollis	103
Furnariidae	Furnarius	figulus	81	Icteridae	Agelaioides	badius	88
Furnariidae	Furnarius	leucopus	33	Icteridae	Cacicus	cela	122
Furnariidae	Furnarius	rufus	63	Icteridae	Cacicus	chrysopterus	162
Furnariidae	Glyphorhynchus	spirurus	99	Icteridae	Cacicus	haemorrhous	237
Furnariidae	Hylexetastes	uniformis	146	Icteridae	Chrysomus	ruficapillus	109
Furnariidae	Hylocryptus	rectirostris	93	Icteridae	Gnorimopsar	chopi	222
Furnariidae	Lepidocolaptes	albolineatus	49	Icteridae	Icterus	pyrrhopterus	189
Furnariidae	Lepidocolaptes	angustirostris	58	Icteridae	Molothrus	bonariensis	40
Furnariidae	Leptasthenura	setaria	77	Icteridae	Psarocolius	decumanus	79
Furnariidae	Lochmias	nematura	276	Icteridae	Pseudoleistes	guirahuro	110
Furnariidae	Phacellodomus	erythrophthalmus	128	Icteridae	Sturnella	superciliaris	84
Furnariidae	Phacellodomus	ferrugineigula	100	Jacanidae	Jacana	jacana	65
Furnariidae	Phacellodomus	rufifrons	28	Mimidae	Mimus	saturninus	217
Furnariidae	Philydor	atricapillus	184	Momotidae	Baryphthengus	ruficapillus	197
Furnariidae	Philydor	rufum	73	Motacillidae	Anthus	hellmayri	156
Furnariidae	Phleocryptes	melanops	49	Motacillidae	Anthus	lutescens	84
Furnariidae	Sclerurus	mexicanus	76	Mysteridae	Mystery	mystery	221
Furnariidae	Sclerurus	scansor	281	Nyctibiidae	Nyctibius	griseus	72
Furnariidae	Sittasomus	griseicapillus	361	Odontophoridae	Odontophorus	capueira	70
Furnariidae	Synallaxis	albescens	226	Parulidae	Basileuterus	culcivorus	250
Furnariidae	Synallaxis	albilora	190	Parulidae	Geothlypis	velata	111
Furnariidae	Synallaxis	cinerascens	347	Parulidae	Myiothlypis	flaveola	142
Furnariidae	Synallaxis	frontalis	222	Parulidae	Myiothlypis	leucoblephara	183

Furnariidae	Synallaxis	ruficapilla	285	Parulidae	Myiothlypis	rivularis	101
Furnariidae	Synallaxis	rutilans	85	Parulidae	Setophaga	pitiayumi	101
Furnariidae	Synallaxis	spixi	284	Picidae	Campephilus	melanoleucos	59
Furnariidae	Syndactyla	rufosuperciliata	174	Picidae	Campephilus	robustus	68
Furnariidae	Xenops	minutus	184	Picidae	Campephilus	rubricollis	81
Furnariidae	Xenops	rutilans	80	Picidae	Celeus	flavescens	73
Furnariidae	Xiphocolaptes	albicollis	103	Picidae	Celeus	flavus	126
Furnariidae	Xiphorhynchus	fuscus	187	Picidae	Celeus	obrieni	91
Picidae	Celeus	torquatus	42	Psophiidae	Psophia	viridis	164
Picidae	Colaptes	campestris	176	Rallidae	Aramides	cajaneus	165
Picidae	Colaptes	melanochloros	108	Rallidae	Aramides	saracura	246
Picidae	Dryocopus	lineatus	92	Rallidae	Gallinula	galeata	86
Picidae	Melanerpes	candidus	182	Rallidae	Laterallus	melanophaius	162
Picidae	Melanerpes	cruentatus	61	Rallidae	Laterallus	viridis	151
Picidae	Melanerpes	flavifrons	59	Rallidae	Pardirallus	nigricans	258
Picidae	Piculus	aurulentus	49	Ramphastidae	Pteroglossus	aracari	92
Picidae	Picumnus	temminckii	79	Ramphastidae	Ramphastos	dicolorus	231
Picidae	Veniliornis	spilogaster	79	Ramphastidae	Ramphastos	toco	132
Pipridae	Antilophia	galeata	127	Ramphastidae	Ramphastos	tucanus	112
Pipridae	Chiroxiphia	caudata	582	Ramphastidae	Ramphastos	vitellinus	436
Pipridae	Chiroxiphia	pareola	278	Rhinocryptidae	Eleoscytalopus	indigoticus	184
Pipridae	Dixiphia	rubrocapilla	118	Rhinocryptidae	Merulaxis	ater	179
Pipridae	Ilicura	militaris	48	Rhinocryptidae	Psilorhamphus	guttatus	89
Pipridae	Manacus	manacus	281	Rhinocryptidae	Scytalopus	novacapitalis	169
Pipridae	Neopelma	pallescens	105	Rhinocryptidae	Scytalopus	speluncae	242
Pipridae	Tyranneutes	stolzmanni	99	Scolopacidae	Gallinago	paraguaiae	27
Poliptilidae	Poliptila	dumicola	220	Strigidae	Asio	flammeus	62
Poliptilidae	Poliptila	plumbea	99	Strigidae	Athene	cunicularia	80
Poliptilidae	Ramphocaenus	melanurus	229	Strigidae	Glaucidium	brasilianum	167
Psittacidae	Amazona	aestiva	112	Strigidae	Glaucidium	hardyi	113
Psittacidae	Amazona	amazonica	62	Strigidae	Glaucidium	minutissimum	108
Psittacidae	Amazona	farinosa	145	Strigidae	Megascops	atricapilla	98
Psittacidae	Amazona	ochrocephala	92	Strigidae	Megascops	choliba	165
Psittacidae	Amazona	vinacea	117	Strigidae	Megascops	watsonii	69
Psittacidae	Anodorhynchus	hyacinthinus	469	Strigidae	Pseudoscops	clamator	74
Psittacidae	Ara	ararauna	164	Strigidae	Pulsatrix	koenigswaldiana	189
Psittacidae	Ara	chloropterus	101	Strigidae	Strix	hylophila	74
Psittacidae	Aratinga	aurea	83	Thamnophilidae	Batara	cinerea	209
Psittacidae	Aratinga	leucophthalma	136	Thamnophilidae	Biatas	nigropectus	171
Psittacidae	Brotogeris	chiriri	182	Thamnophilidae	Cercomacra	cinerascens	128
Psittacidae	Brotogeris	chrysoptera	87	Thamnophilidae	Cercomacra	manu	164



Psittacidae	Brotogeris	tirica	196	Thamnophilid ae	Cercomacra	melanaria	166
Psittacidae	Deroptylus	accipitrinus	100	Thamnophilid ae	Cercomacra	nigrescens	172
Psittacidae	Diopsittaca	nobilis	157	Thamnophilid ae	Cercomacra	tyrannina	80
Psittacidae	Forpus	xanthopterygius	92	Thamnophilid ae	Cymbilaimus	lineatus	80
Psittacidae	Myiopsitta	monachus	54	Thamnophilid ae	Drymophila	ferruginea	345
Psittacidae	Orthopsittaca	manilata	77	Thamnophilid ae	Drymophila	genei	88
Psittacidae	Pionites	leucogaster	170	Thamnophilid ae	Drymophila	malura	194
Psittacidae	Pionus	maximiliani	154	Thamnophilid ae	Drymophila	ochropyga	227
Psittacidae	Primolius	maracana	83	Thamnophilid ae	Drymophila	rubricollis	151
Psittacidae	Pyrrhura	amazonum	106	Thamnophilid ae	Drymophila	squamata	279
Psittacidae	Pyrrhura	frontalis	93	Thamnophilid ae	Dysithamnus	mentalis	347
Psittacidae	Triclaria	malachitacea	51	Thamnophilid ae	Dysithamnus	stictocephalus	170
Thamnophilida e	Dysithamnus	xanthopterus	115	Thamnophilid ae	Stymphalornis	acutirostris	93
Thamnophilida e	Formicivora	grisea	130	Thamnophilid ae	Taraba	major	171
Thamnophilida e	Formicivora	rufa	111	Thamnophilid ae	Terenura	maculata	81
Thamnophilida e	Formicivora	serrana	84	Thamnophilid ae	Thamnomanes	caesius	153
Thamnophilida e	Herpsilochmus	atricapillus	127	Thamnophilid ae	Thamnomanes	saturninus	88
Thamnophilida e	Herpsilochmus	longirostris	176	Thamnophilid ae	Thamnophilus	aethiops	146
Thamnophilida e	Herpsilochmus	rufimarginatus	286	Thamnophilid ae	Thamnophilus	amazonicus	183
Thamnophilida e	Herpsilochmus	sellowi	74	Thamnophilid ae	Thamnophilus	ambiguus	110
Thamnophilida e	Hylophylax	naevius	148	Thamnophilid ae	Thamnophilus	caerulescens	191
Thamnophilida e	Hylophylax	punctulatus	124	Thamnophilid ae	Thamnophilus	doliatus	170
Thamnophilida e	Hypocnemis	cantator	140	Thamnophilid ae	Thamnophilus	palliatus	72
Thamnophilida e	Hypocnemis	hypoxantha	89	Thamnophilid ae	Thamnophilus	pelzelni	113
Thamnophilida e	Hypocnemis	peruviana	268	Thamnophilid ae	Thamnophilus	punctatus	68
Thamnophilida e	Hypocnemis	striata	184	Thamnophilid ae	Thamnophilus	ruficapillus	117
Thamnophilida e	Hypoedaleus	guttatus	201	Thamnophilid ae	Thamnophilus	schistaceus	98
Thamnophilida e	Iseria	hauxwelli	97	Thamnophilid ae	Thamnophilus	stictocephalus	112
Thamnophilida e	Mackenziaena	leachii	84	Thamnophilid ae	Thamnophilus	torquatus	52
Thamnophilida e	Mackenziaena	severa	172	Thamnophilid ae	Willisornis	vidua	125
Thamnophilida e	Microrhopias	quixensis	160	Thraupidae	Cissopis	leverianus	63
Thamnophilida e	Myrmeciza	atrothorax	202	Thraupidae	Conirostrum	speciosum	83
Thamnophilida e	Myrmeciza	hemimelaena	78	Thraupidae	Coryphospiza	melanotis	121
Thamnophilida e	Myrmeciza	loricata	135	Thraupidae	Coryphospingus	pileatus	87
Thamnophilida e	Myrmeciza	ruficauda	69	Thraupidae	Dacnis	cayana	49
Thamnophilida e	Myrmeciza	squamosa	269	Thraupidae	Emberizoides	herbicola	185

Thamnophilida e	Myrmoborus	leucophrys	62	Thraupidae	Embernagra	platensis	89
Thamnophilida e	Myrmoborus	myotherinus	202	Thraupidae	Haplospiza	unicolor	135
Thamnophilida e	Myrmorchilus	strigilatus	52	Thraupidae	Hemithraupis	guira	192
Thamnophilida e	Myrmotherula	axillaris	148	Thraupidae	Hemithraupis	ruficapilla	83
Thamnophilida e	Myrmotherula	brachyura	98	Thraupidae	Nemosia	pileata	61
Thamnophilida e	Myrmotherula	longipennis	92	Thraupidae	Orchesticus	abeillei	151
Thamnophilida e	Myrmotherula	luctuosa	128	Thraupidae	Orthogonys	chloricterus	137
Thamnophilida e	Myrmotherula	menetriesii	66	Thraupidae	Oryzoborus	angolensis	63
Thamnophilida e	Myrmotherula	multostriata	154	Thraupidae	Paroaria	dominicana	121
Thamnophilida e	Myrmotherula	unicolor	116	Thraupidae	Pipraeidea	melanonota	94
Thamnophilida e	Percnostola	rufifrons	108	Thraupidae	Poospiza	cabanisi	95
Thamnophilida e	Phlegopsis	nigromaculata	72	Thraupidae	Pyrrhocomma	ruficeps	54
Thamnophilida e	Pygmytila	stellaris	118	Thraupidae	Ramphocelus	bresilius	143
Thamnophilida e	Pyriglena	atra	34	Thraupidae	Sicalis	citrina	76
Thamnophilida e	Pyriglena	leuconota	143	Thraupidae	Sicalis	flaveola	177
Thamnophilida e	Pyriglena	leucoptera	273	Thraupidae	Sporophila	caerulescens	162
Thamnophilida e	Rhegmatorhina	gymnops	81	Thraupidae	Sporophila	falcirostris	127
Thamnophilida e	Rhopias	gularis	194	Thraupidae	Sporophila	frontalis	180
Thamnophilida e	Sakesphorus	luctuosus	69	Thraupidae	Sporophila	leucoptera	137
Thamnophilida e	Schistocichla	ruffacies	148	Thraupidae	Sporophila	lineola	64
Thamnophilida e	Sclateria	naevia	68	Thraupidae	Sporophila	nigricollis	65
Thraupidae	Stephanophorus	diadematus	96	Troglodytidae	Microcerculus	marginatus	392
Thraupidae	Tachyphonus	coronatus	247	Troglodytidae	Odontorchilus	cinereus	121
Thraupidae	Tangara	cyaenocephala	97	Troglodytidae	Pheugopedius	coraya	94
Thraupidae	Tangara	desmaresti	76	Troglodytidae	Pheugopedius	genibarbis	230
Thraupidae	Thraupis	ornata	83	Troglodytidae	Troglodytes	aedon	211
Thraupidae	Thraupis	palmarum	129	Trogonidae	Trogon	curucui	134
Thraupidae	Thraupis	sayaca	132	Trogonidae	Trogon	melanurus	79
Thraupidae	Tiaris	fuliginosus	137	Trogonidae	Trogon	rufus	191
Thraupidae	Trichothraupis	melanops	285	Trogonidae	Trogon	surrucura	248
Thraupidae	Volatinia	jacarina	131	Trogonidae	Trogon	viridis	130
Threskiornithid ae	Theristicus	caudatus	127	Turdidae	Turdus	albicollis	238
Tinamidae	Crypturellus	cinereus	154	Turdidae	Turdus	amaurochalinus	251
Tinamidae	Crypturellus	noctivagus	67	Turdidae	Turdus	flavipes	446
Tinamidae	Crypturellus	obsoletus	268	Turdidae	Turdus	leucomelas	288
Tinamidae	Crypturellus	parvirostris	63	Turdidae	Turdus	rufiventris	351
Tinamidae	Crypturellus	soui	122	Turdidae	Turdus	subalaris	185
Tinamidae	Crypturellus	strigulosus	134	Tyrannidae	Attila	cinnamomeus	99
Tinamidae	Crypturellus	tataupa	98	Tyrannidae	Attila	phoenicurus	180

Tinamidae	Crypturellus	undulatus	150	Tyrannidae	Attila	rufus	257
Tinamidae	Nothura	maculosa	75	Tyrannidae	Attila	spadiceus	83
Tinamidae	Taoniscus	nanus	130	Tyrannidae	Camptostoma	obsoletum	252
Tityridae	Onychorhynchus	coronatus	97	Tyrannidae	Capsiempis	flaveola	157
Tityridae	Pachyramphus	castaneus	134	Tyrannidae	Cnemotriccus	fuscatus	139
Tityridae	Pachyramphus	marginatus	88	Tyrannidae	Colonia	colonus	104
Tityridae	Pachyramphus	polychopterus	163	Tyrannidae	Contopus	cinereus	122
Tityridae	Pachyramphus	viridis	159	Tyrannidae	Corythopsis	delalandi	109
Tityridae	Schiffornis	turdina	84	Tyrannidae	Elaenia	cristata	73
Tityridae	Schiffornis	virescens	120	Tyrannidae	Elaenia	flavogaster	114
Trochilidae	Aphantochroa	cirrochloris	43	Tyrannidae	Elaenia	mesoleuca	113
Trochilidae	Clytolaema	rubricauda	204	Tyrannidae	Elaenia	obscura	68
Trochilidae	Colibri	serrirostris	147	Tyrannidae	Elaenia	parvirostris	101
Trochilidae	Florisuga	fusca	44	Tyrannidae	Elaenia	spectabilis	181
Trochilidae	Hylocharis	cyanus	123	Tyrannidae	Empidonomus	varius	154
Trochilidae	Leucochloris	albicollis	67	Tyrannidae	Euscarthmus	meloryphus	175
Trochilidae	Phaethornis	eurynome	264	Tyrannidae	Euscarthmus	rufomarginatus	126
Trochilidae	Phaethornis	ruber	98	Tyrannidae	Fluvicola	nengeta	69
Trochilidae	Ramphodon	naevius	125	Tyrannidae	Gubernetes	yetapa	49
Trochilidae	Stephanoxis	lalandi	133	Tyrannidae	Hemitriccus	diops	102
Trochilidae	Thalurania	glaucopis	95	Tyrannidae	Hemitriccus	furcatus	62
Troglodytidae	Campylorhynchus	turdinus	118	Tyrannidae	Hemitriccus	griseipectus	141
Troglodytidae	Cantorchilus	guarayanus	130	Tyrannidae	Hemitriccus	margaritaceivent er	195
Troglodytidae	Cantorchilus	leucotis	135	Tyrannidae	Hemitriccus	minimus	65
Troglodytidae	Cantorchilus	longirostris	408	Tyrannidae	Hemitriccus	minor	136
Troglodytidae	Cistothorus	platensis	105	Tyrannidae	Hemitriccus	obsoletus	84
Troglodytidae	Cyphorhinus	arada	155	Tyrannidae	Hemitriccus	orbitatus	128
Tyrannidae	Hirundinea	ferruginea	54	Tyrannidae	Myiarchus	tyrannulus	147
Tyrannidae	Lathrotriccus	euleri	250	Tyrannidae	Myiodynastes	maculatus	249
Tyrannidae	Legatus	leucophaius	281	Tyrannidae	Myiopagis	caniceps	142
Tyrannidae	Leptopogon	amaurocephalus	83	Tyrannidae	Myiopagis	viridicata	168
Tyrannidae	Lophotriccus	galeatus	122	Tyrannidae	Myiophobus	fasciatus	91
Tyrannidae	Machetornis	rixosa	87	Tyrannidae	Myiornis	auricularis	160
Tyrannidae	Megarynchus	pitangua	225	Tyrannidae	Myiornis	ecaudatus	113
Tyrannidae	Mionectes	oleagineus	127	Tyrannidae	Myiozetetes	similis	216
Tyrannidae	Mionectes	rufiventris	112	Tyrannidae	Ornithion	inermis	127
Tyrannidae	Muscipipra	vetula	86	Tyrannidae	Phaeomyias	murina	126
Tyrannidae	Myiarchus	ferox	129	Tyrannidae	Phyllomyias	burmeisteri	171
Tyrannidae	Myiarchus	swainsoni	187	Tyrannidae	Phyllomyias	fasciatus	108
Tyrannidae	Phyllomyias	virescens	53				
Tyrannidae	Phylloscartes	kronei	77				
Tyrannidae	Phylloscartes	oustaleti	115				
Tyrannidae	Piprites	chloris	154				

Tyrannidae	Pitangus	sulphuratus	249
Tyrannidae	Platyrinchus	mystaceus	238
Tyrannidae	Platyrinchus	platyrhynchus	206
Tyrannidae	Poecilotriccus	plumbeiceps	125
Tyrannidae	Ramphotrigon	megacephalum	179
Tyrannidae	Rhytipterna	simplex	66
Tyrannidae	Serpophaga	subcristata	90
Tyrannidae	Sirystes	sibilator	144
Tyrannidae	Suiriri	suiriri	43
Tyrannidae	Todirostrum	cinereum	36
Tyrannidae	Todirostrum	poliocephalum	109
Tyrannidae	Tolmomyias	assimilis	110
Tyrannidae	Tolmomyias	flaviventris	141
Tyrannidae	Tolmomyias	poliocephalus	174
Tyrannidae	Tolmomyias	sulphurescens	320
Tyrannidae	Tyrannus	melancholicus	102
Tyrannidae	Zimmerius	acer	74
Vireonidae	Cyclarhis	gujanensis	378
Vireonidae	Hylophilus	amaurocephalus	98
Vireonidae	Hylophilus	poicilotis	122
Vireonidae	Hylophilus	semicinereus	88
Vireonidae	Hylophilus	thoracicus	47
Vireonidae	Vireo	olivaceus	297





