

# Characterization and identification of twelve-tone composers

Lucas F. P. Costa<sup>1</sup>, Andrés E. Coca S.<sup>1</sup>

<sup>1</sup>Universidade Tecnológica Federal do Paraná (UTFPR)  
Toledo – PR – Brazil

lucascosta74@gmail.com, andressalazar@utfpr.edu.br

**Abstract.** *The individualism of each composer is shaped in an inherent way to his personality, aiming for recognition of particular form through the own songs. In this way, it is possible to categorize a musical subgenre at a deeper level by identifying the composer from his works. However, the characteristics of each composer are so varied that they are difficult to identify. In this paper it is proposed to use machine learning to classify works of twelve-tone music according to the composer, under the hypothesis that in choosing the twelve-tone series a part of his signature was reflected. Experimental results showed promising performance and confirmed the existence of a relation between composer and series.*

**Resumo.** *O individualismo de cada compositor é plasmado de forma inerente a sua personalidade, visando o seu reconhecimento particular através das suas próprias músicas. Desta forma, é possível categorizar um subgênero musical em um nível mais profundo mediante a identificação do compositor a partir das suas obras. No entanto, as características de cada compositor são tão variadas que dificultam sua identificação. Neste artigo é proposto usar aprendizado de máquina para classificar obras de música dodecafônica segundo o compositor, sob a hipótese de que na escolha da série dodecafônica ficou refletida uma parte da sua assinatura. Resultados experimentais mostraram desempenho promissor e confirmaram a evidência da existência de uma relação entre compositor-série.*

## 1. Introdução

O crescimento constante dos bancos de dados musicais disponíveis digitalmente tem motivado o desenvolvimento de diferentes métodos de classificação automática de música. Tipicamente, tais métodos têm sido direcionados maioritariamente para a classificação de gêneros musicais, a qual tem sido abordada desde diferentes perspectivas [1, 14, 17]. Contudo, outros níveis de classificação são possíveis, como classificação em subgêneros [15] e em estilos [16]. No entanto, após ter classificado determinado banco de dados em algum dos dois anteriores níveis, também é útil discriminar cada categoria obtida em uma subcategoria mais profunda, o compositor, deixando-o assim mais organizado e preparado para ser utilizado em outros sistemas, como sistema de recomendação [13] ou sistemas de análise e extração de dados [18], dentre outros.

O fundamento principal por trás da tarefa de identificação do compositor é que um alvo procurado por quase todos os compositores musicais é impregnar nas suas obras a sua assinatura musical para assim poderem ser reconhecidos através delas. Em muitos casos esse processo é inconsciente, e nasce da essência intrínseca do compositor na sua

tomada de decisões ou no seu gosto pessoal. Desta forma, a classificação de obras musicais segundo o compositor é uma tarefa um pouco mais complicada porque nem sempre o compositor definiu sua assinatura de forma voluntária e concreta, e também, possivelmente, ela foi influenciada por outros compositores ou escolas. Desta forma, pode-se considerar como o nível de classificação mais difuso.

Mesmo assim, alguns esforços têm sido realizados nesse âmbito, por exemplo, Kalliakatsos et al. no seu artigo [8] calculou a similaridade entre 7 compositores da música erudita usando Redes Neurais Probabilísticas (PNN, *Probabilistic Neural Networks*) aplicadas ao vetor do traço dodecafônico (DTV, *Dodecaphonic Trace Vector*), o qual contém a frequência normalizada de cada uma das 12 notas da escala cromática que foram usadas na obra toda. Também foi calculada uma tabela de identificação de sucesso usando uma rede neural não realimentada (FNN, *Feedforward Neural Networks*) e o algoritmo diferencial evolutivo (DEA, *Differential Evolution Algorithm*). Posteriormente, o mesmo autor usou em [9] a informação estrutural das frases musicais e pares de intervalos consecutivos para serem aplicadas a uma variação ponderada de uma cadeia de Markov de primeira ordem visando distinguir as obras de três compositores: Haydn, Mozart e Beethoven. Por sua vez, em [7] foi aplicada modelagem da linguagem usando  $n$ -gramas para modelar o estilo de cinco compositores dos períodos barroco e clássico, e para distinguir entre as fugas de Bach e Shostakovich. Por outro lado, em [4] foram usados três tipos de modelos de classificação: árvores de decisão, conjunto de regras e máquinas de vetor de suporte (SVM) para discriminar as obras de três compositores (Bach, Haydn e Beethoven). Por fim, em [6]  $n$ -gramas calculados a partir de alturas, duração e ritmo foram usadas para extrair características e classificar nove compositores de piano clássico. Nessa pesquisa, um algoritmo cortical (CA, *Cortical Algorithm*) foi usado tanto para a redução da dimensionalidade quanto para a classificação supervisionada dos compositores, obtendo bons resultados com um pequeno conjunto de medidas.

Um subgênero musical da música erudita é o dodecafonismo, a qual baseia-se em uma técnica de composição contemporânea que consiste em criar uma série com as doze notas da escala cromática e a partir desta aplicar transformações para obter uma matriz com 48 séries relacionadas, as quais servem de material composicional para o autor. Essa técnica determina como criar a matriz e define algumas pautas para sua aplicação dentro da obra, mas não diz respeito a como criar a série original, apenas que deve conter todas as notas da escala cromática sem repetição, ficando a seleção dessa a cargo do critério pessoal do autor. Pelo fato da composição estar estruturada na série original e nas suas derivadas, poder-se-ia considerar a série como uma das partes mais relevantes da obra. Consequentemente, em [17] foi usado um algoritmo genético para compor melodias dodecafônicas baseadas na série original.

Contudo, a possibilidade de distinção auditiva entre séries dodecafônicas diferentes tem gerado grandes discussões no campo da musicologia. Por um lado os defensores da música clássica diatônica arguem que esta pode sempre ser percebida como unidades estruturais, não sendo isto possível na música dodecafônica para grandes estruturas perceptivas [2]. Neste sentido, Francès [11] concluiu que as séries não foram escolhidas de forma perceptiva e sim como um sistema puramente conceptual ou intelectual. Argumento que permite estabelecer a grande influência que tem a série na obra toda.

Neste artigo é proposto classificar uma obra musical dodecafônica segundo o com-

positor a partir de características extraídas da série original, sob a hipótese de que a escolha da série por parte do compositor está relacionada com o seu estilo e gosto pessoal. Para tal, visando classificar as amostras de um banco de dados de séries de dois compositores famosos, Schoenberg e Stravinsky, foram usados quatro métodos de aprendizado de máquina divididos equitativamente em supervisionados (*AdaBoost* e árvores de decisão) e não-supervisionados ( $k$ -médias e algoritmo hierárquico aglomerativo), e um conjunto de 14 medidas divididas em dois grupos: descritivas e estatísticas. Os resultados auferidos foram suficientes para ter bons indícios de que é possível identificar o compositor através da série.

Este artigo está organizado como segue: a Seção 2 descreve o método de identificação de compositores dodecafônicos, bem como alguns fundamentos básicos sobre a teoria dodecafônica; a Seção 3 apresenta os resultados experimentais e a Seção 4 as conclusões.

## **2. Método proposto para a identificação de compositores dodecafônicos**

O método proposto para identificação de compositores dodecafônicos consiste dos seguintes passos: análise de sequências dodecafônicas objetivando extração de características das mesmas e utilização dos dados obtidos nas abordagens de aprendizado de máquina, resultando na obtenção de um modelo treinado para predições.

Nesta seção, inicialmente, será apresentada uma contextualização histórica do dodecafonismo, bem como alguns dos seus fundamentos básicos. Seguidamente, continuar-se-á com a descrição do método proposto para a identificação de compositores a partir da série dodecafônica.

### **2.1. Técnica de composição dodecafônica**

O dodecafonismo usa uma técnica de composição contemporânea atonal cujo desenvolvimento foi creditado a Arnold Schoenberg em meados do séc. XX, tendo por seguidores compositores como Stravinsky, Berg, Stockhausen, dentre outros [10]. Essa técnica assume como princípio básico uma ordenação preexistente das doze notas da escala cromática, o que significa que o compositor escolhe as notas com as quais irá trabalhar antes de compor qualquer música real. Essa ordem de notas é chamada por vários autores de série original, e a partir dessa são derivadas novas séries. Todas as partes da peça são referenciáveis à série original de algum modo, sendo esta a implementação fundamental do dodecafonismo [5].

Com o passar dos anos, o método de composição dodecafônico começou a se popularizar e a se desenvolver, gerando novos adeptos. Com o crescimento de compositores deste segmento, as características das séries começam a se alterarem na exploração de novas possibilidades de construção segundo o estilo particular de cada um. Contudo, o dodecafonismo nunca foi uma corrente bem aceita pelo público de forma geral, sendo duramente criticada [10], fato que contribuiu para sua queda e consequente despolarização.

A formação da série original segue duas regras básicas: 1) usar todas as 12 notas da escala cromática e 2) não repetir nenhuma nota<sup>1</sup>. Com a série original, elabora-se a chamada matriz dodecafônica de  $12 \times 12$  que conterá todas as séries derivadas e servirá de material composicional. A primeira linha da matriz contém a série original, e as

---

<sup>1</sup>Intervalos de oitava nesta seleção são considerados como uma repetição.

|          | $I_0$  | $I_7$  | $I_8$  | $I_3$  | $I_9$  | $I_4$  | $I_5$  | $I_{10}$  | $I_2$  | $I_6$  | $I_1$  | $I_{11}$  |          |
|----------|--------|--------|--------|--------|--------|--------|--------|-----------|--------|--------|--------|-----------|----------|
| $P_0$    | G      | D      | D#     | A#     | E      | B      | C      | F         | A      | C#     | G#     | F#        | $R_0$    |
| $P_5$    | C      | G      | G#     | D#     | A      | E      | F      | A#        | D      | F#     | C#     | B         | $R_5$    |
| $P_4$    | B      | F#     | G      | D      | G#     | D#     | E      | A         | C#     | F      | C      | A#        | $R_4$    |
| $P_9$    | E      | B      | C      | G      | C#     | G#     | A      | D         | F#     | A#     | F      | D#        | $R_9$    |
| $P_3$    | A#     | F      | F#     | C#     | G      | D      | D#     | G#        | C      | E      | B      | A         | $R_3$    |
| $P_8$    | D#     | A#     | B      | F#     | C      | G      | G#     | C#        | F      | A      | E      | D         | $R_8$    |
| $P_7$    | D      | A      | A#     | F      | B      | F#     | G      | C         | E      | G#     | D#     | C#        | $R_7$    |
| $P_2$    | A      | E      | F      | C      | F#     | C#     | D      | G         | B      | D#     | A#     | G#        | $R_2$    |
| $P_{10}$ | F      | C      | C#     | G#     | D      | A      | A#     | D#        | G      | B      | F#     | E         | $R_{10}$ |
| $P_6$    | C#     | G#     | A      | E      | A#     | F      | F#     | B         | D#     | G      | D      | C         | $R_6$    |
| $P_{11}$ | F#     | C#     | D      | A      | D#     | A#     | B      | E         | G#     | C      | G      | F         | $R_{11}$ |
| $P_1$    | G#     | D#     | E      | B      | F      | C      | C#     | F#        | A#     | D      | A      | G         | $R_1$    |
|          | $RI_0$ | $RI_7$ | $RI_8$ | $RI_3$ | $RI_9$ | $RI_4$ | $RI_5$ | $RI_{10}$ | $RI_2$ | $RI_6$ | $RI_1$ | $RI_{11}$ |          |

Figura 1. Exemplo de formação da matriz dodecafônica.

linhas seguintes são transposições da série original denotadas com  $P_i$ , onde  $i$  indica o número do intervalo de transposição em semitons da nota subsequente em relação à primeira nota da série original. Para preencher as outras linhas/colunas da matriz são usadas duas operações: inversão e transposição. A primeira coluna corresponde com a inversão de  $P_i$ , isto é, os intervalos invertidos entre cada par de notas consecutivas. Essa série original invertida é denotada como  $I_i$ . As seguintes linhas da matriz são transposições de  $P_i$  iniciadas na nota indicada pela primeira nota de  $I_i$  da respectiva linha. Da matriz podem ser extraídas 48 séries dodecafônicas, segundo o sentido usado para lê-las, de esquerda para direita tem-se as séries transpostas  $P_i$ , de direita para esquerda as séries transpostas retrogradadas  $R_i$ , de cima para baixo as séries invertidas  $I_i$ , e de baixo para cima as séries invertidas retrogradadas  $RI_i$ . Por exemplo, na Fig. 1 é mostrada a matriz dodecafônica da série original: G, D, D#, A#, E, B, C, F, A, C#, G#, F#.

## 2.2. Extração de características

O vetor de características é formado por diversas medidas calculadas a partir do conjunto intervático da série dodecafônica. Ao todo foram usadas 14 medidas, organizadas em dois grupos. O primeiro grupo, chamado de descritores interváticos, contempla as medidas calculadas usando diretamente os intervalos entre notas consecutivas da série. O segundo grupo corresponde a medidas calculadas usando informação estatística extraída do histograma de intervalos. A seguir são apresentadas as medidas de cada categoria.

### 2.2.1. Descritores interváticos

A partir da série diversas informações podem ser extraídas, analisando-se a sequência de notas ou também os intervalos entre as mesmas. Entretanto, os intervalos demonstraram ser mantenedores de muita riqueza pelo fato de considerarem a direção entre duas notas e permitirem valores repetidos. Pois, a informação do sentido permite obter valores positivos e negativos, indicando assim a ascendência ou descendência da segunda nota considerada no intervalo. Desta forma, o vetor de intervalos foi escolhido porque possibilita uma maior extração de informação dos dados.

As primeiras cinco medidas deste grupo correspondem com medidas que foram usadas em [3] para caracterizar melodias caóticas, sendo estas: Intervalos Dissonantes (*ID*), Estabilidade do Contorno (*EC*), Movimentos por Passo (*MP*), Densidade do Contorno (*DC*) e Saltos de Retorno (*SR*).

As primeiras quatro medidas são calculadas dividindo o número total de intervalos dissonantes, a quantidade de intervalos consecutivos na mesma direção, o total de intervalos diatônicos e o total de intervalos ascendentes e descendentes, sobre o número total de intervalos, que para as séries dodecafônicas é fixo e igual a 11. Enquanto a última medida (*SR*) corresponde com a fração de intervalos longos disjuntos (mais de sete semitons) que não são seguidos por intervalos de retorno, isto é, intervalos um semitom mais curto que o intervalo longo disjunto precedente, sobre o número de total de intervalos longos. Cabe ressaltar que da estabilidade do contorno são derivadas duas medidas quando considerado o sentido, sendo estas a Estabilidade do Contorno Ascendente (*EC<sub>a</sub>*) e Descendente (*EC<sub>d</sub>*), igual acontece com a Densidade de Contorno Ascendente (*DC<sub>a</sub>*) e descendente (*DC<sub>d</sub>*)<sup>2</sup>. As outras medidas deste grupo são descritas a seguir:

- **Tessitura Interválica** (*TI*): indica o maior intervalo do conjunto intervático da série, podendo ser este ascendente (*TI<sub>a</sub>*) ou descendente (*TI<sub>d</sub>*).
- **Maior Diferença Interválica** (*MDI*): é uma medida derivada da anterior, e calculada da seguinte forma:  $TI_a - TI_d$ .
- **Intervalo Global** (*IG*): corresponde com o intervalo entre a primeira e a última nota da série.

### 2.2.2. Medidas estatísticas

Nesta seção são descritas as medidas estatísticas. É calculado o vetor de intervalos *V* e para esses intervalos, o histograma *H* de  $1 \times 24$ , e a partir destes dois são calculadas as seguintes medidas:

- **Média Interválica** ( $\mu_I$ ): conforme o nome o indica corresponde com o intervalo médio do vetor de intervalos, podendo ser também considerado o sentido dos intervalos ou não. Uma derivação desta medida é a Média Interválica Ponderada ( $\bar{\mu}_I$ ), que é calculada adicionando os respectivos pesos aos intervalos, dados pela Razão Intervalar da Escala Igualmente Temperada ( $s_i$ ), calculada como  $s_i = 2^{i/12}$ , onde *i* é o número de semitons contidos no intervalo. Deste forma, a  $\bar{\mu}_I$  é calculada como:

$$\bar{\mu}_I = \frac{\sum_{k=1}^n H_k s_{i_k}}{\sum_{k=1}^n s_{i_k}}. \quad (1)$$

- **Desvio Padrão Intervático** ( $\sigma_I$ ): esta medida corresponde com o desvio padrão do vetor de intervalos. De forma semelhante, também é possível calcular o Desvio Padrão Intervático Ponderado ( $\bar{\sigma}_I$ ) quando for calculado o desvio em torno da média ponderada ( $\bar{\mu}_I$ ).
- **Moda** (*m*), **Frequência Modal** (*f<sub>m</sub>*) e **Multimoda** (*m<sub>m</sub>*): a moda refere-se ao intervalo mais usado na série, enquanto a frequência modal ao número de repetições

<sup>2</sup>Quando consideradas as medidas derivadas se tem ao todo 18 medidas.

da moda. A Multimoda é o número de intervalos com igual  $f_m$ , isto é, indica a existência de outras modas.

- **Assimetria Interválica ( $\alpha$ ):** Mensura a assimetria dos dados em torno da média interválica. Se a assimetria for negativa, os dados serão espalhados mais à esquerda da média do que à direita, indicando o contrário em caso de ser positiva. A  $\alpha$  é calculada como:

$$\alpha = \frac{E(V - \mu_I)^3}{\sigma_I^3}, \quad (2)$$

onde  $V$  é o vetor de intervalos e  $E(\cdot)$  representa o operador para calcular o valor esperado da quantidade.

### 2.3. Métodos de aprendizado de máquina

Nesta seção serão descritos os métodos de aprendizado de máquina usados para identificar o compositor dodecafônico a partir da sua série. Na Seção 2.3.1 os métodos supervisionados e na Seção 2.3.2 os não-supervisionados.

#### 2.3.1. Métodos supervisionados

O aprendizado de máquina fazendo uso da metodologia supervisionada funciona de forma a treinar um classificador partindo de exemplos previamente rotulados servindo de base [12]. A seguir serão apresentados os dois métodos supervisionados usados:

- **Árvores de decisão (AdeD):** Uma abordagem simples e bem-sucedida se mostra no uso de árvores de decisão. Uma árvore de decisão cria uma estrutura de árvore para classificação e predição, dividida em nós e ramificações, e se resume a uma função que recebe diferentes atributos como entrada e retorna uma resposta Booleana. As decisões são definidas a partir de vários testes, representados por cada nó interno da árvore, e suas ramificações são classificações de valores possíveis para cada atributo. Entretanto, apenas uma árvore é gerada e apenas um conjunto treinado é retornado.
- **AdaBoost:** O fundamento principal deste método está baseado em uma técnica amplamente utilizada chamada de aceleração, que faz uso do princípio de conjuntos de treinamento ponderados, onde cada dado tem um peso a ele associado. Com o conjunto de dados iniciando com pesos iguais, é gerada a primeira hipótese, que fará classificações corretas e incorretas. As classificações corretas têm, então, seu peso diminuído, enquanto que as incorretas aumentam em peso, criando um novo conjunto de dados ponderado. Partindo deste novo conjunto, uma nova hipótese é gerada. O processo continua a se repetir várias vezes, chegando a uma classificação final melhor que a inicial. Um algoritmo que faz uso desta ideia é denominado *AdaBoost*, que aplica um classificador fraco repetidas vezes, ponderando o resultado a cada iteração e consequentemente melhorando a classificação dos dados de treinamento. Assim, o *AdaBoost* acaba por acelerar a exatidão do modelo [12].

### 2.3.2. Métodos não-supervisionados

O método não-supervisionado de aprendizado não conta com dados rotulados, i.e., não acontece treinamento a partir de exemplos, mas sim a organização de dados em grupos, possibilitando a identificação de padrões e resultando em conclusões sobre o conjunto analisado. A seguir serão apresentados os métodos não-supervisionados usados nesta pesquisa:

- **Algoritmo hierárquico aglomerativo (AHA):** Este algoritmo inicia com cada elemento como um grupo separado e, com isso, começa a fundi-los em grupos gradativamente maiores a partir de medidas de distância e métodos de ligação. O resultado final pode ser representado por um dendrograma. A medida de distância selecionada para ser usada nesta pesquisa denomina-se cosseno, que faz a relação de semelhança entre dois vetores a partir do ângulo de separação entre os mesmos, e a qual é calculada como:

$$d_{ij} = 1 - \frac{\sum_{k=1}^p x_{ik}x_{jk}}{\sqrt{\sum_{i=1}^p x_i^2} \sqrt{\sum_{j=1}^p x_j^2}}. \quad (3)$$


onde  $d_{ij}$  é a distância entre os elementos  $i$  e  $j$  contidos no grupo  $x$ , e  $p$  o número total de elemento desse grupo. Para o método de ligação foi usado o método de ligação completa, o qual une dois grupos quando ocorre a maior distância entre os seus elementos [12].

- **$k$ -médias:** Classificado como um método de particionamento, este método usa uma função que mapeia dados de partições em  $k$  grupos mutuamente exclusivos e retorna o índice do grupo ao qual foi atribuído em cada observação. Diferentemente do agrupamento hierárquico, o agrupamento por  $k$ -médias opera em observações reais e cria um único nível de grupos.

## 3. Resultados experimentais

Nesta seção é aplicado o método proposto para a identificação do compositor a partir das séries dodecafônicas usadas nas suas obras. O banco de dados usado para testar o método consiste de 38 séries dodecafônicas extraídas das obras de dois compositores que tiveram forte influência no dodecafonismo, Arnold Schoenberg e Igor Stravinsky, sendo 19 de cada um. Portanto, tem-se duas classes no banco de dados, nomeadas C1 e C2, respectivamente. Inicialmente será feita uma análise direta dos dados e depois serão aplicados quatro métodos de aprendizado de máquina.


O histograma de intervalos de todas as séries do banco de dados separados por compositor é mostrado na Fig.2. Nele é possível enxergar que o intervalo de uníssono (valor 0) não aparece pelo fato de uma regra para a construção de série original proibir a repetição de notas; também, que ambos os compositores evitaram o intervalo -11, porém, sim usaram o de +11, e a causa disso é desconhecida. Dentre as semelhanças, pode-se observar que ambos os compositores têm preferência por intervalos ascendentes e descendentes, destacando-se dentro desta preferência a predileção por intervalos curtos, motivo pelo qual o histograma tem forma de sino. No entanto, a preferência pelos intervalos curtos é levemente maior para os intervalos ascendentes até 4 semitons, o que fica refletido em uma pequena assimetria do sino para a direita. Contudo, algumas diferenças



**Figura 2. Histograma dos intervalos de todas as séries dodecafônicas dos dois compositores do banco de dados.**

também podem ser encontradas. Por exemplo, o intervalo mais usado por Schoenberg foi +1, enquanto Stravinsky usou mais o +2. Cabe ressaltar que a preferência de Stravinsky por este intervalo é forte, tanto que é o maior pico do histograma, superando os seus dois seguintes picos e o máximo pico de Schoenberg em 17.50%, 20% e 30%, respectivamente. Enquanto, o pico máximo de Schoenberg é para o intervalo +1, que supera os seus próprios seguintes picos (+2 e -4) em 17.86% e 32.14%, respectivamente<sup>3</sup>.

Nesta análise é possível perceber que existem tanto diferenças quanto semelhanças nas séries dos dois compositores, porém por se tratar de uma observação direta do histograma de intervalos informação implícita é desconsiderada. Portanto, uma análise mais aprofundada pode ser realizada mediante o cálculo de medidas descritivas e estatísticas usando o vetor de intervalos. Na Fig. 3(a) é mostrada a série dodecafônica original usada por Schoenberg na sua obra *Variações para Orquestra op. 31*, e na Fig. 3(b) a série usada por Stravinsky na sua obra *Double Canon*. Também são mostrados os respectivos intervalos entre notas consecutivas.



**Figura 3. Exemplos de séries do banco de dados de séries dodecafônicas. (a) Schoenberg - *Variações para Orquestra Op.31*; (b) Stravinsky - *Double Canon*.**

<sup>3</sup> A preferência de Schoenberg pelos intervalos de 1 semitom pode ser pelo fato de que ele era fascinado pela numerologia e ter forte superstição pelo número 13, cujo resto da divisão por 12 é igual a 1.



**Tabela 1. Medidas descritivas calculadas para as séries da Fig. 3.**

| Classe     | $ID$ | $EC_a$ | $EC_d$ | $MP$ | $DC_a$ | $TI$ | $MDI$ | $IG$ |
|------------|------|--------|--------|------|--------|------|-------|------|
| Schoenberg | 0.45 | 0.3    | 0.1    | 0.45 | 0.64   | 15   | 9     | 2    |
| Stravinsky | 0.45 | 0.1    | 0.4    | 0.55 | 0.36   | 19   | 11    | 4    |

**Tabela 2. Medidas estatísticas calculadas para as séries da Fig. 3.**

| Classe     | $\bar{\mu}_I$ | $\bar{\sigma}_I$ | $m$ | $f_m$ | $m_m$ | $\alpha$ |
|------------|---------------|------------------|-----|-------|-------|----------|
| Schoenberg | 4.24          | 2.75             | 1   | 3     | 1     | 0.55     |
| Stravinsky | 4.32          | 3.60             | 1   | 4     | 1     | 1.13     |

Para cada série da Fig. 3 foram calculadas 14 medidas experimentais, cujos resultados para as medidas descritivas são mostrados na Tabela 1 e para as medidas estatísticas na Tabela 2. Os dados da tabela revelam que a um nível mais profundo existe uma diferença entre as características descritivas das séries de exemplo de cada classe. Especificamente, a tessitura interváltica ( $TI$ ) e maior diferença interváltica ( $MDI$ ) são maiores para a série de Stravinsky, bem como, para o caso das medidas estatísticas, todas essas medidas são maiores para a série de Stravinsky, com exceção da moda ( $m$ ) e multimoda ( $m_m$ ), que são iguais.

As análises anteriores permitem estabelecer a hipótese de que existe uma diferença representativa entre o conteúdo interváltico das séries de cada compositor. A comprovação de tal hipótese permitirá identificar os compositores a partir das séries, e classificar obras musicais do subgênero dodecafônico segundo o compositor. Para testar essa hipótese serão usados métodos de aprendizado de máquina supervisionados e não-supervisionados.

Visando enxergar melhor os dados multidimensionais no plano bidimensional foi aplicada a técnica de análise de componentes principais ( $PCA$ ), cujo resultado é apresentado na Fig. 4. A Fig. 4 mostra o gráfico do primeiro componente principal contra o segundo, aqui é possível ver como as amostras da classe C1 estão mais próximas, enquanto as de C2 mais dispersas entre si, porém afastadas daquelas da outra classe. A análise de componentes principais também foi usada para reduzir a dimensionalidade. A Fig. 5 apresenta a porcentagem de variância de cada componente principal, bem como a porcentagem de variância acumulada. Essa figura revela que somente são necessários 5 componentes para representar 98% da variância explicada, portanto serão usados esses componentes em todas as técnicas de aprendizado de máquina.

A partir das medidas, diversos métodos de aprendizado de máquina foram aplicados para discriminar os dados entre as duas classes. Na Fig. 6 são mostrados os resultados obtidos em porcentagem de acurácia usando no aprendizado de máquina o vetor de características diretamente e as componentes principais obtidas mediante a análise com  $PCA$ . Pode-se enxergar facilmente que o melhor resultado foi obtido usando as componentes de  $PCA$ , o que confirma a vantagem da redução da dimensionalidade. Consequentemente, essas componentes principais serão as únicas usadas nas posteriores análises.

Na Tabela 3, pode-se ver a acurácia de identificação para duas técnicas de amostragem: ressubstituição e validação cruzada 10-fold. Pode-se observar que o melhor resultado na abordagem supervisionada corresponde ao método *AdaBoost*, obtendo




Figura 4. Gráfico do primeiro contra o segundo componente principal.




Figura 5. Porcentagem de variância acumulada pelos vetores de componentes principais.




Figura 6. Histograma comparativo entre as acurácias obtidas com cada abordagem de aprendizado usando a dimensão completa e a reduzida com *PCA*.

**Tabela 3. Porcentagem de acurácia obtida com cada uma das técnicas de aprendizado de máquina utilizadas e para dois diferentes tipos de reamostragem.**

|                                   | Supervisionados |       | Não-supervisionados |       |
|-----------------------------------|-----------------|-------|---------------------|-------|
|                                   | <i>AdaBoost</i> | AdeD  | <i>k</i> -médias    | AHA   |
| Ressubstituição                   | 94.74           | 92.11 | 60.53               | 63.16 |
| Validação cruzada 10- <i>fold</i> | 62.50           | 55.26 | 31.59               | 25.42 |

**Tabela 4. Matriz de confusão calculada para o melhor resultado de cada abordagem (*AdaBoost* e AHA) quando usada a técnica de reamostragem de resubstituição.**

|            | <i>AdaBoost</i> |            | AHA        |            |
|------------|-----------------|------------|------------|------------|
|            | Schoenberg      | Stravinsky | Schoenberg | Stravinsky |
| Schoenberg | 17              | 2          | 13         | 6          |
| Stravinsky | 0               | 19         | 8          | 11         |

uma acurácia de 94.74% e 62,50% para as duas técnicas de reamostragem, respectivamente. Com relação à abordagem não-supervisionada o melhor resultado foi obtido com o método AHA, com o qual foi obtida uma acurácia de 63.16% e 25.42% nas duas técnicas de reamostragem, respectivamente. Na Tabela 4 é mostrada a matriz de confusão do melhor resultado de cada abordagem (*AdaBoost* e AHA) quando usada a técnica de reamostragem de resubstituição. Com relação à matriz de confusão obtida pelo método *AdaBoost*, pode-se perceber que existem duas séries de Schoenberg que foram classificadas na classe de Stravinsky. Uma quantidade maior de erros pode ser notada na matriz de confusão para o método de AHA.

#### 4. Conclusões

Um método para a identificação de compositores dodecafônicos a partir das séries usadas nas suas obras foi apresentado e testado. Para tal, foi usado um banco de dados de séries dodecafônicas extraídas das obras de dois compositores representativos desse estilo. O melhor resultado foi obtido com o modelo treinado pelo método de aprendizado *AdaBoost*, o qual permitiu fazer identificações com 94.74% de acerto quando usada a técnica de reamostragem resubstituição, e 62.50% quando usado validação cruzada. Os resultados experimentais mostraram que é possível discriminar o compositor mediante os intervalos característicos das séries escolhidas para as suas obras, evidenciando que a escolha da série não seguiu um processo arbitrário e sim um procedimento conceptual e sistemático sustentado pelo gosto particular do compositor. De maneira intrínseca também é possível concluir que as medidas baseadas no vetor de intervalos permitem a extração de informação implícita que caracterizam com boa riqueza a série escolhida. Como trabalho futuro é proposto estender o banco de dados com mais compositores e com mais séries tanto originais quanto derivadas, e extrair características não apenas para a série original, e sim para todas as séries da matriz dodecafônica derivada dessa série.

#### Referências

- [1] Coca A. and Zhao L., *Identification of music genres by using communities detection in complex networks*, In Proc. National Meeting on Artificial and Computational Intel-

ligence (ENIAC), 2015, pp. 95–100.

- [2] Lannoy C., *Detection and discrimination of dodecaphonic series*, Interface **1** (1972), no. 1, 13–27.
- [3] Coca A., Olivar G., and Zhao L., *Characterizing chaotic melodies in automatic music composition*, Chaos - An Interdisciplinary Journal **20** (2010), no. 3, 033125.
- [4] Herremans D., Martens D., and Sörensen K., *Composer classification models for music-theory building*, pp. 369–392, Springer, 2016.
- [5] Covach J., *Twelve-tone theory*, The Cambridge History of Western Music Theory, 2002.
- [6] Hajj N. Filo M. and Awad M., *Automated composer recognition for multi-voice piano compositions using rhythmic features, n-grams and modified cortical algorithms*, Complex & Intelligent Systems **4** (2018), no. 1, 55–65.
- [7] Hontanilla M., Pérez C., and Iñesta J., *Modeling musical style with language models for composer recognition*, Pattern Recognition and Image Analysis (Berlin, Heidelberg) (Sanches M., Micó L., and Cardoso J., eds.), Springer Berlin Heidelberg, 2013, pp. 740–748.
- [8] Kaliakatsos P., Maximos A., Epitropakis M., and Vrahatis N., *Musical composer identification through probabilistic and feedforward neural networks*, Applications of Evolutionary Computation (Berlin, Heidelberg) (Di Chio C. et al.), Springer Berlin Heidelberg, 2010, pp. 411–420.
- [9] Kaliakatsos P., Epitropakis M., and Vrahatis N., *Weighted markov chain model for musical composer identification*, Applications of Evolutionary Computation. (Berlin, Heidelberg) (Di Chio C. et al.), Springer Berlin Heidelberg, 2011, pp. 334–343.
- [10] Candé R., *História universal da musica*, Martins Fontes, 2001.
- [11] Francès R., *La perception de la musique*, Librairie Philosophique J. Vrin, Paris, 1958.
- [12] Russel S. and Norvig P., *Artificial intelligence*, Prentice Hall, 2009.
- [13] Y. Song, S. Dixon, and M. Pearce, *A survey of music recommendation systems and future perspectives*, In Proc. International Symposium on Computer Music Modelling and Retrieval (CMMR), 2012, pp. 395–410.
- [14] B. Sturm, *A survey of evaluation in music genre recognition*, In Proc. Adaptive Multimedia Retrieval (AMR), 2012, pp. 1–41.
- [15] Tsatsishvili V., *Automatic subgenre classification of heavy metal music*, Master’s thesis, University Of Jyväskylä., 2011.
- [16] Nie Y.-B., *Data mining applied to music style classification*, International Journal of Simulation Systems, Science & Technology (IJSSST) **17** (2016), no. 2, 19.1–19.6.
- [17] De Prisco R., Zaccagnino G. and Zaccagnino R., *A Genetic Algorithm for Dodecaphonic Compositions*, Applications of Evolutionary Computation (Berlin, Heidelberg) (Di Chio C. et al.), Springer Berlin Heidelberg, 2011, pp. 244–253.
- [18] Coca A. and Zhao L. *Musical rhythmic pattern extraction using relevance of communities in networks*, Information Sciences, vol. 329, 2016, pp. 819–848.