

# O uso da inteligência artificial na harmonização de músicas\*

Vitor Claudio de Oliveira Santos<sup>1</sup>, Hélio Rubens Soares<sup>1</sup>, Milton Miranda Neto<sup>1</sup>

<sup>1</sup>Ciência da computação– Centro Universitário do Triângulo (UNITRI) – Av. Nicomedes Alves dos Santos, 4545, Bairro Gávea - CEP 38.411-106 – Uberlândia – MG – Brasil

vitorcldeos@gmail.com, hrubens@unitri.com.br,  
milton.miranda@unitri.edu.br

***Abstract.** This article presents a qualitative study about use artificial intelligence (AI) to harmonize and create music. Introducing with important views on AI and music, important partnerships and how the two work within the industry today, in addition to reviewing the main concepts of music theory and important AI models. Finally, the implementation of a software that harmonizes a melody through the use of AI and functions that apply musical theory.*

***Resumo.** Esse artigo apresenta um estudo qualitativo acerca do uso da inteligência artificial (IA) na harmonização e criação de músicas. Introduzindo com visões gerais sobre IA e música, importantes parcerias e como os dois agem dentro da indústria atualmente, além de revisar os principais conceitos da teoria musical e dos importantes modelos de IA. Por fim a implementação de um software que harmoniza uma melodia através do uso de IA e funções que aplica a teoria musical.*

## 1. Introdução

A evolução tecnológica ao longo dos anos trouxe facilidades em muitos aspectos que acompanha a vida das pessoas. A partir do momento que o poder computacional possibilitou implementar efetivamente modelos robustos de inteligência artificial, foi possível automatizar atividades que demanda, tempo, estudo e trabalho. Segundo Ivan S. S. (2004), o objetivo de um sistema de inteligência artificial é entender a natureza de um problema e tomar decisões no qual se encontra cada vez mais necessário reduzir o tempo de resposta, tornando atividades humanas cada vez mais ágeis.

A música se faz presente desde o início da história da humanidade, e é uma arte que leva o ser humano a se expressar. A evolução da música como ciência foi contemporâneo a evolução da matemática, que através das representações do som a partir funções trigonométricas e eventos ondulatórios possibilitou a padronização da harmonia de diferentes notas musicais e suas relações entre diferentes instrumentos, (SILVA, 2018). A intenção de comunicar, compreender e padronizar os diferentes eventos físicos da música, registrando tais acontecimentos em uma simbologia própria, é chamado de Teoria Musical, (DANTAS e CRUZ, 2018).

A música sempre esteve envolvida nos contextos e tendências tecnológicas por meio da comunicação distribuindo e disseminando as novidades musicais, ou por meio da criação através da computação usando diferentes algoritmos, como os de inteligência

artificial que trabalha baseando-se nos conteúdos teóricos da música, buscando auxiliar na composição e na criação da mesma.

Diante do princípio de que toda nova tecnologia busca facilitar a vida de quem a consome, esse artigo apresenta um estudo sobre a inteligência artificial e a teoria musical, além de uma revisão ressaltando a importância da parceria entre a música e a tecnologia, e a influência de como o uso da inteligência artificial pode mudar o jeito de compor novas músicas, possibilitando qualquer pessoa, mesmo sem um profundo conhecimento teórico musical, consiga se expressar através da música com auxílio das novas tecnologias, por fim, a implementação de um software que harmoniza uma melodia através do uso de inteligência artificial e funções aplicando a teoria musical.

A estrutura deste estudo começa na seção 2, que faz um apanhado histórico dos últimos séculos de modo a acompanhar a jornada da música e da tecnologia como meios de comunicação e entretenimento, e como as evoluções tecnológicas disseminaram as músicas da época. Logo depois, o contexto econômico da indústria musical nas últimas décadas. Seguido por uma revisão da teoria musical, dos conceitos de inteligência artificial, aprendizagem de máquina, aprendizagem profunda, e os projetos que juntam a música com sistemas de inteligência artificial. A seção 3 é dedicada a discussão sobre influência da música na vida e cultura das pessoas, ao estudo de importantes vertentes da teoria musical, como o campo harmônico, função harmônica e escalas, além do estudo sobre o modelo Perceptron, MLP e diferentes funções de ativação. Por último um apanhado geral das ferramentas e tecnologias usadas no estudo de caso. A seção 4 é a implementação de um software que usa inteligência artificial e ferramentas de alto nível para harmonizar uma melodia. A motivação desse projeto nasce baseado na necessidade das pessoas se expressarem através da música, e facilitar o processo de composição da mesma. O software desenvolvido no estudo de caso identifica em qual escala está sendo trabalhada a melodia informada nos dados de entrada, e de acordo com esses dados especifica o campo harmônico e seus respectivos conjuntos de acordes para que a melodia seja finalmente harmonizada. No final do artigo a seção 5 apresenta as conclusões.

## **2. Influência da tecnologia na música**

A música é um grande expoente que acompanhou toda a jornada da tecnologia como meio de comunicação e entretenimento, que de forma recíproca segue evoluindo até os dias atuais. A partir do invento do rádio no final do século 19, e das primeiras transmissões radiofônicas como meio regular de entretenimento, que teve início na década de 20 através da emissora americana KDKA, (TUFFANI, 2010), os programas musicais nas rádios americanas começaram a se tornar populares e ser amplamente difundidos na famosa “era de ouro do rádio americano”, que aconteceu entre 1930 e 1940, onde programas que transmitia apresentações de forma remota em salões de bailes nas cidades de Chicago e Nova York ajudaram bastante a disseminação das músicas da época (ENCYCLOPEDIA BRITANNICA, 2017).

Posteriormente o mesmo fenômeno aconteceu com os programas televisivos, que aproveitaram a mídia audiovisual para inovar e alavancar ainda mais o alcance da indústria musical, como o programa “The Ed Sullivan Show” que tinha uma das maiores audiências americanas entre os anos cinquenta e meados dos anos setenta, que ajudou a lançar na América importantes bandas e artistas como Elvis Presley, The Beatles, Rolling Stones e muitos outros, (MCNAMARA, 2019). Nos anos oitenta foi o

começo da era MTV, um canal a cabo com a plataforma totalmente voltada ao entretenimento musical, onde eram apresentados vídeo clipes 24 horas por dia, o que ajudou na popularização do formato (ENCYCLOPEDIA BRITANNICA, 2020).

Nos anos noventa a mídia digital através dos CDs foi uma das grandes evoluções no mercado da música, consistentemente atribuído como a maior porcentagem de vendas e geração de receitas na indústria (FLY, 2016). Nas décadas seguintes a indústria musical aproveitou a popularização dos serviços de *streaming*, e segundo J.P. Friedlander (2020), em seu relatório a Associação Americana da Indústria da Gravação (RIAA), a distribuição das músicas em streaming no ano de 2019 representa 79.5% de toda receita do mercado musical.

### **2.1. Indústria da música no século XXI**

Desde o início do século XXI a economia do mercado da música vem sofrendo altos e baixos. De acordo com a CNN Business (2020), no final do século XX a indústria musical teve seu ápice econômico no ano de 1999, fazendo mais de 14.5 bilhões de dólares nos estados unidos, a maior parte desse valor foi proveniente a partir das vendas de CDs. A próxima década foi marcada pela mudança nas formas de distribuição das mídias, os consumidores começaram a optar pelas mídias digitais, e as vendas das mídias físicas como os CDs diminuíram drasticamente. 2014 foi marcado como o pior ano para a indústria, fazendo somente 6.7 bilhões de dólares, mas em 2016 a indústria fonográfica começava a se restabelecer com o streaming das músicas, que inclui serviços pagos com assinaturas, ou versões gratuitas com suportes de propagandas. Graças ao streaming, em 2019 o mercado musical fez 11.1 bilhões de dólares nos estados unidos, a maior marca desde 2006, (PALOTTA e CNN Business, 2020).

### **2.2. Música através da teoria musical**

A teoria musical traz algumas definições do que é a música, por meio de linguagens abstratas ou matemáticas. Para Clifton (1983) a música é um arranjo ordenado entre sons e silêncios, que possibilita o humano experimentar um sentimento. P. Dorrell (2005) explica que uma das principais analogias do que é a música são os detalhes mecânicos da própria, como as notas, escalas, ritmos, tempo, acordes, harmonia, baixos e melodia.

Para trabalhar com a teoria musical é preciso primeiro entender os conceitos matemáticos sobre os eventos ondulatórios. As grandezas físicas da música são compostas pelo tempo, frequência, intensidade e timbre. O tempo é a duração das notas musicais, que trabalha de forma relativa entre sons curtos e longos. As frequências classificam os sons em agudos e graves, as ondas onde os sons são mais agudos tem frequências maiores. A intensidade é uma grandeza proporcional a amplitude da onda, que identifica se o som é alto ou baixo. E por fim, o timbre tem a qualidade de diferenciar os diferentes instrumentos que produz o som. (DANTAS e CRUZ, 2018).

Os três principais elementos na arte de criar uma música são a melodia, harmonia e o ritmo, quando sons são combinados e reproduzidos em ordem sucessiva, em diferentes frequências, um após o outro, é chamado de melodia. A base dos estudos das estruturas melódicas são as notas, motivos e estilos musicais. (KIEFER, 1979). A combinação de notas musicais sendo emitidas simultaneamente são chamados de acordes, a harmonia tem a função de organizar os acordes consonantes e dissonantes para criar um acompanhamento para a melodia, (DANTAS e CRUZ, 2018). Os ritmos

em características musicais podem ser relacionados a duração e intensidade do som, que pode sofrer variações na altura e no timbre (DEUSANY, 2011).

### **2.3. Inteligência Artificial e Aprendizado de máquina**

As inteligências artificiais (IAs) estão presentes na grande maioria dos softwares atuais, elas são utilizadas para solucionar problemas, raciocinar de forma lógica, processar linguagem natural, robótica e visão, programação autônoma, aprendizagem, sistemas especialistas, além de várias outras vertentes, R.E Shannon (1985). O princípio da inteligência artificial foi enraizado no começo dos anos 50 por Alan Turing (Turing, 1950), mas segundo R.E Shannon (1985), os estudos sobre as IAs começaram a ser realizados em uma conferência da universidade Dartmouth, em Nova Hampshire, nos Estados Unidos em 1956. Existem várias definições do que é uma inteligência artificial, que flutuam entre conceitos científicos e filosóficos. Segundo Ivan S.S. (2004) IA é a junção de sistemas e máquinas que associados a pessoas, dados, procedimentos e conhecimentos específicos, demonstram um comportamento inteligente.

As primeiras décadas dos estudos das IAs foram importantes pela implementação dos primeiros simuladores de redes neurais e neuro-computadores. Além de modelos como o Perceptron (F. Rosenblatt, 1958), e posteriormente o modelo Adeline. Antes da década de 80 buscava-se estudos para que a IA realizasse tarefas humanas como pensar e compreender linguagem, porém sem sustentações matemáticas. A partir dos meados dos anos oitenta começou os avanços nos estudos de redes neurais artificiais e simulações de sistemas, com seus respectivos modelos matemáticos, a partir disso começou o desenvolvimento dos sistemas especialistas e importantes propostas de novos modelos como o Perceptron multicamadas que aumentava o potencial do modelo Perceptron de modo que superou algumas limitações que o antigo modelo comportava, Ivan S.S. (2004). Durante a década seguinte o estudo da inteligência artificial procrastinou devido a capacidade computacional das máquinas da época que não conseguiam processar uma grande quantidade de dados e demandava muito tempo para alcançar os resultados desejados, de forma que estagnou a evolução e acarretou a perda de interesse no desenvolvimento das IAs. Mas a partir da expansão do poder computacional no começo do século XXI, as técnicas que não eram possíveis de serem implementadas voltaram a ser estudadas, como os conceitos de *Machine Learning* ou aprendizado de máquina, que conseqüentemente originou o surgimento do *Deep Learning* ou aprendizagem profunda que é fundamental na elaboração de diversos sistemas de inteligência artificial, (CHAGAS, 2019).

### **2.4 Redes Neurais artificiais e Aprendizagem profunda**

As Redes Neurais artificiais (RNAs) são uma das importantes especialidades da inteligência artificial, consistindo em modelos matemáticos que buscam reconhecer padrões e solucionar problemas de classificação e regressão. Essa técnica busca de alguma maneira simular de forma análoga a estrutura de um neurônio biológico, e tem a capacidade de construir uma rede baseado nos dados de treinamento, se auto-organizar e coerentemente dar respostas, mesmo se os dados de entrada forem diferentes dos dados que foram usados no treinamento da rede, podendo assim solucionar problemas complexos. (JESS, 2004).

Softwares com modelos de IA que usam uma grande quantidade de dados para o treinamento segue os paradigmas de aprendizagem profunda, que segundo Chagas (2019), é um conjunto de algoritmos de *Machine Learning* formado por diversas

camadas a partir de um processamento hierárquico, que comumente segue três tipos de modelos, que são eles, o não supervisionado que busca aprender, extrair recursos e relacionar padrões, mesmo quando não há dados similares das classes no banco de dados da rede; As redes neurais profundas com aprendizagem supervisionada ou redes profundas discriminativas que depende de uma supervisão e separação dos dados para que seja possível fazer a classificação de padrões; E por último as redes profundas híbridas, que é uma supervisão e discriminação dos dados provenientes das redes profundas não supervisionadas, que pode ser desenvolvidos através de uma evolução ou modificação de uma rede neural profunda supervisionada.

## 2.5. Projetos de IA com música

A partir de 2010 foram desenvolvidos grandes projetos que conciliaram a indústria da música e o mercado de IA, o *Artificial Intelligence Visual Artist* (AIVA) é um dos grandes expoentes dessa vertente, o software é capaz de compor trilhas sonoras que são usadas em filmes, vídeo games, comerciais e qualquer outro tipo de conteúdo de entretenimento. Pierre Barreau (2018), um dos criadores da AIVA em sua palestra sobre “como a IA poderia compor uma trilha sonora para sua vida”, diz que inicialmente usando *Deep Learning* e um banco de dados com mais de 30 mil partituras dos principais artistas da música clássica, foi criado o AIVA, um software que trabalha com compassos de músicas existentes, deduzindo quais serão as próximas notas. Um dos principais progressos no mercado foi a conquista do AIVA ao se tornar o primeiro artista virtual a ter suas criações registradas na sociedade de autores, compositores e publicadores de música (SACEM), isso reflete na ascensão que o uso da IA está tendo na indústria musical (LAUDER, 2017).

Outro popular software no mercado, que usa modelos parecidos com o AIVA, é o MuseNet, o programa usa algoritmos de rede neural profunda para gerar músicas com 10 diferentes instrumentos com uma duração de até 4 minutos, ele é treinado para aprender qual é a próxima informação em um banco de dados com dezenas de milhares de arquivos MIDI, esse arquivo é um padrão que conecta instrumentos, computadores e sintetizadores, possibilitando a comunicação entre eles, (MORIMOTO, 2005). Portanto o treinamento da IA do MuseNet descobre padrões de harmonias, ritmos e estilos (PAYNE, 2019).

No meio acadêmico, o artigo de M. Della Ventura (2015) apresenta uma proposta de um algoritmo capaz de gerar uma ideia musical a partir de uma IA que usa conceitos de harmonia funcional. Nesse estudo Ventura fornece um sistema que automatiza a composição musical de forma aleatória ou baseado em músicas específicas, criando e alterando sequências de acordes que não respeitam as regras da música tonal.

## 3. Considerações sobre a música

A história da música pode ser considerada tão antiga quanto a história da própria humanidade, segundo E. Andrews (2018), o instrumento musical mais antigo já encontrado pelos arqueólogos foi um instrumento de sopro, semelhante a uma flauta feita de osso e marfim fabricada há aproximadamente 43 mil anos atrás, isso mostra que desde muito tempo o humano tenta manipular o som e transforma-lo em música. Para J. Schulkin e G.B. Raglan (2014), a música é fundamental porque promove o bem-estar, facilita o contato humano, estimula a imaginação e a criatividade fornecendo experiências funcionais em que a criação e a reprodução das músicas refletem nas

capacidades cognitivas. Graue (2017) aponta que artisticamente a música é uma importante forma do ser humano se expressar, sendo por meio oral cantando ou cantarolando melodias, ou por meio de instrumentos musicais. A teoria musical busca entender e unir a parte artística e matemática da música, contendo os campos harmônicos uma importante área de estudo, que busca padronizar um conjunto de acordes baseado em escalas. As escalas na música é qualquer sequência graduada de notas, tons e intervalos. (GRAUE, 2017).

### **3.1. Campos harmônicos, funções harmônicas e escalas**

Segundo os estudos do compositor A. Schonberg (1983), uma escala é a sequência de notas ordenadas. Uma das mais conhecidas escalas, a escala cromática, é composta por 12 notas musicais e segue uma sequência com intervalos de semitons, esses intervalos são chamados de sustenido caso seja um semitom acima de uma nota, ou bemol caso seja um semitom abaixo de uma nota, a sequência de semitons da escala cromática é Dó, Dó sustenido ou Ré Bemol, Ré, Ré sustenido ou Mi Bemol, Mi, Fá, Fá sustenido ou Sol Bemol, Sol, Sol sustenido ou Lá Bemol, Lá, Lá sustenido ou Si Bemol, e Si. A escala diatônica por exemplo funciona em cima da escala cromática, é uma escala com 7 notas, cinco intervalos de tons, e dois intervalos de semitons entre cada nota. Uma das mais difundidas escalas é a escala maior natural, ela trabalha em cima da escala diatônica e é composta pelas sequências de tom, tom, semitom, tom, tom, tom, semitom. A escala de dó maior por exemplo seria Dó, Ré, Mi, Fá, Sol, Lá, Si, Dó.

A área dos estudos das harmonias dentro da teoria musical é conhecida como campo harmônico, que consiste na reunião dos acordes a partir de uma escala. Os campos são baseados em um centro tonal. O campo harmônico maior por exemplo, é baseado na escala maior, e trabalha com os mesmos intervalos, possuindo sete graus, sendo que cada grau contém um acorde e uma função harmônica, (SCHONBERG, 1983). A harmonia funcional ou função harmônica é responsável pelas variações emocionais da música, o campo harmônico de Dó maior por exemplo tem o acorde de dó maior como seu primeiro grau, esse grau é chamado de tônica, que produz uma sensação de repouso, o quinto grau é a função dominante que traz a sensação de instabilidade em relação a tônica, a função subdominante tem o papel de transição, ou seja, ela prepara as migrações entre as demais funções. Nos estudos das funções harmônicas existem as classificações das qualidades das funções, que são separados entre as funções fortes e fracas, as fortes sempre tem mais impacto dentro do campo harmônico, entre os graus das funções tônicas o de maior força é o primeiro grau do campo, o terceiro grau e o sexto grau são considerados fracos, a função forte entre os dominantes é o quinto grau, o sétimo grau é considerado um dominante fraco, por fim, entre os subdominantes o quarto grau representa a função forte e o segundo grau a função fraca, (SCHONBERG, 1983).

### **3.2. Perceptron, MLP, e funções de ativação**

O Perceptron é um importante modelo no mundo das redes neurais artificiais, desenvolvido nas décadas de cinquenta e sessenta pelo cientista Frank Rosenblatt. Seu conceito matemático é a possibilidade de receber várias entradas e entregar uma única saída, para que isso aconteça os sinais de entrada chegam em um neurônio artificial contendo um potencial de ativação que faz uma multiplicação de seus pesos sinápticos, além disso existe o viés ou bias, um valor fixo que expressa o resultado de saída sem a influência dos dados de entrada, e a função de ativação que age no resultado de saída

das camadas, funcionando em finalidades específicas, (LEITE, 2018). A função de ativação *rectified linear unit* (ReLU) é uma função computacionalmente leve, que retorna valores no intervalo de 0 e infinito zerando valores negativos, geralmente é usada em camadas ocultas. A função de ativação Sigmoide ou função logística produz valores no intervalo entre 0 e 1, e tende a aproximar os valores para as extremidades desse intervalo. É comum o uso do Sigmoide em camadas de saída já que o resultado entre zero e um pode ser interpretado pela probabilidade da instancia pertencer a uma das classes, (CECCON, 2020). Uma das evoluções do Perceptron é o Perceptron Multicamadas (MLP), muito parecido com o original, mas tendo a possibilidade de implementar mais camadas em seu interior, (LEITE, 2018).

### 3.3. Ferramentas para o desenvolvimento

Na crescente disputa entre as melhores linguagens de programação para desenvolver projetos com IAs, aprendizagem de máquina, e aprendizagem profunda, a linguagem Python se destaca por diversos motivos, segundo J. Protasiewicz (2018), o que torna o Python uma excelente escolha para o desenvolvimento de projetos envolvendo IA é a extensa quantidade de bibliotecas e frameworks disponíveis que facilita a codificação e economiza tempo no desenvolvimento, em questões de agilidade no desenvolvimento, o Python possui uma sintaxe simples que facilita a leitura, aprendizagem e escrita do código, além de ter um grande suporte pois é uma linguagem em código aberto e possui uma documentação de alta qualidade. Devido as abundantes possibilidades que a linguagem dispõe, o Python foi usado para o desenvolvimento do sistema durante o estudo de caso.

Em termos de frameworks e bibliotecas de aprendizado de maquinas, cálculos e análise de dados numéricos, o Anaconda é uma distribuição gratuita de código aberto da linguagem Python que foi usado para viabilizar os pacotes que foram utilizados no projeto (MATHUR, 2016). Para vetorização, indexação, e uso de funções matemáticas foi usado o pacote NumPy (Numpy, 2020), juntamente com a principal biblioteca em código aberto para o desenvolvimento de *Machine Learning* o TensorFlow, (TensorFlow, 2020). Também foi usado o Keras, uma interface de programação de aplicações (API) de aprendizado profundo escrita em Python que roda a partir do TensorFlow, e fornece abstrações para a construção do modelo da IA usado no projeto (TensorFlow, 2020). Para criação de gráficos no ambiente Python, foi usado o Matplotlib (Matplotlib, 2020).

O ambiente de desenvolvimento do software foi o Visual Studio Code (VsCode), ele é um editor de código gratuito da Microsoft, que fornece extensão para Python, possuindo uma variedade de interpretadores, fácil alternância de ambientes, além de ferramentas que auxiliaram o desenvolvimento, como o *IntelliSense* que fornece completações inteligentes com base nos tipos de variáveis, as funções e módulos, testes de unidades para ajudar a manter a integridade do código, e extensões de *linting* e *debugging* para detectar erros e facilitar a depuração do código (Visual Studio Code, 2019).

## 4. Estudo de caso

A proposta do estudo de caso é a que criação de um software que recebe uma lista de notas musicais, a melodia, e entrega um conjunto de acordes que faz parte do seu campo

harmônico. Em um breve resumo do funcionamento do sistema, após a entrada das notas musicais, os dados foram tokenizados e transformados em uma sequência binária de 12 unidades, a sequência binária das notas foram usadas como entrada na rede neural que tem a função de identificar em qual tonalidade na escala maior ela pertence. Sabendo a tonalidade foi possível classificar a função harmônica e os respectivos graus de cada nota que posteriormente foram processados e teve como resultado um conjunto de graus, por fim, baseado na tonalidade, cada grau foi substituído pelo acorde relativo, segue na imagem abaixo a fluxograma do funcionamento do programa.

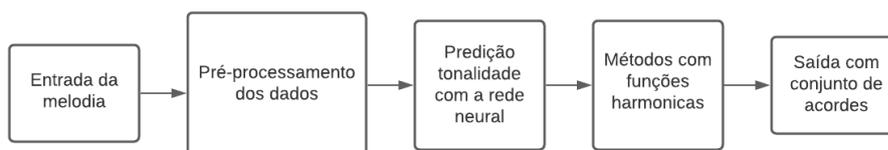


Figura 1: Fluxograma do funcionamento do programa

#### 4.1. Pré-processamento dos dados de entrada

Os dados de entrada são notas musicais em formato de texto que descrevem as sequências das notas de forma aleatória, podendo ter repetições e sem limite de tamanho. Essas notas são as sequências de semitom que compõem a escala cromática, que são: Dó, Dó Sustenido, Ré, Ré Sustenido, Mi, Fá, Fá Sustenido, Sol, Sol Sustenido, Lá, Si Bemol e Si. Para entrar com a melodia foi escrito a sequência com os nomes de cada nota em uma lista no formato de texto. Logo após a entrada da melodia foram chamadas duas funções que retornaram duas diferentes listas baseadas nos dados de entrada. A primeira função tratou de tokenizar o texto usando o *Tokenizer* que é uma classe de processamento de texto do Keras, (TensorFlow, 2020). O objetivo da tokenização é a divisão e serialização do texto que representa cada nota, transformando cada uma em um valor numérico. A Figura 2 mostra as notas musicais numeradas de acordo com o valor de cada uma, e na Figura 3 mostra o resultado da função que converte as notas de uma melodia em seus respectivos números.



Figura 2: Numeração das notas

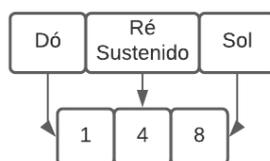
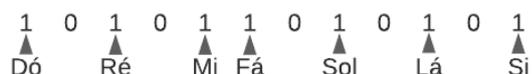


Figura 3: Melodia em formato numérico

A segunda função, usou a lista de notas musicais numeradas da função que a figura 3 retornou, e criou uma lista de 12 elementos com apenas números binários, essa lista é usada como entrada na rede neural.

Baseado na discussão do músico I. Ring (2019), em seu artigo sobre o estudo de escalas, ele relaciona uma escala cromática, que são 12 notas com intervalos de semitons, com um conjunto de 12 bits com valores binários, ou seja, a escala natural maior que é composta por intervalos de tom, tom, semitom, tom, tom, tom, semitom, na representação em binário a escala natural de dó maior é representado como na figura abaixo.



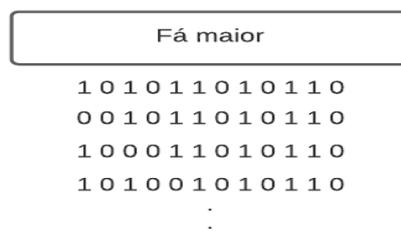
**Figura 4. Escala de dó maior em conjunto binário**

Ian Ring em seu texto aplicou essa metodologia para diferenciar escalas, mas essa representação pode ser utilizada na padronização de diferentes tonalidades dentro de uma só escala. É isso que foi usado para popular os dados de treinamento da rede neural, que são doze classes cada uma representando uma tonalidade da escala maior natural. As notas de cada tonalidade foram representadas em uma lista com conjuntos binários, onde o primeiro elemento da lista é a nota Dó e a cada próximo elemento é um meio-tom a cima. A imagem abaixo exemplifica a diferença entre as tonalidades Ré, Sol, e Si Bemol na escala maior natural na lista de números binários.

Ré maior = 0 1 1 0 1 0 1 1 0 1 0 1  
 Sol maior = 1 0 1 0 1 0 1 1 0 1 0 1  
 Si Bemol = 1 0 1 1 0 1 0 1 0 1 1 0

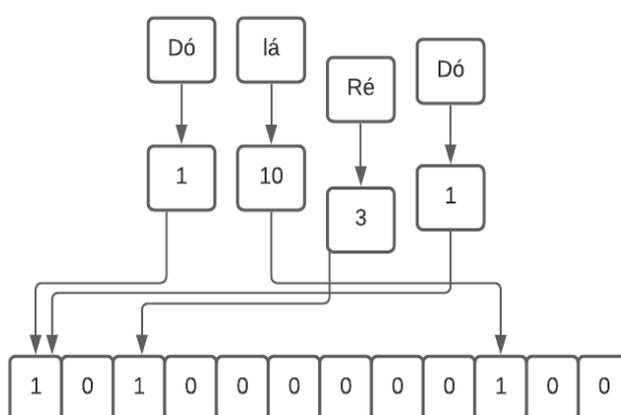
**Figura 5. Escala de Ré, Sol, e Si Bemol em binário**

Para a IA ter mais eficiência na classificação, cada tonalidade sofreu modificações na lista de sequencias binarias para poder popular o banco de dados e definir alguns padrões, para cada binário positivo representado pelo valor 1 na lista da tonalidade, foi criado uma nova lista com um dos binários positivos virando negativos. A imagem abaixo exemplifica algumas modificações na lista da tonalidade de Fá Maior.



**Figura 6. Modificações nas listas binárias em Fá maior**

As 96 listas binárias para o treinamento da rede é a soma das 12 listas das tonalidades originais com as 84 novas listas geradas através das modificações de cada tonalidade. Sendo que cada uma das doze tonalidades da escala maior natural contém sua própria lista binária, e para cada tonalidade foram criadas 7 novas listas com suas modificações. Os dados de entrada da rede são da mesma natureza que os dados de treinamento, e foram gerados por uma função que a partir da lista numérica retornada pela função da figura 3, identificou quais são as notas da melodia, e transformou em uma lista binária com 12 elementos, como representado na figura abaixo.



**Figura 7. Transformação melodia numérica em conjunto binário**

Rotulando qual é a classe das listas de números binários, todos os conjuntos binários contêm outra lista de 12 elementos binários, e que cada índice representa uma tonalidade diferente. Como exemplificado na figura 8, o primeiro índice da lista é a tonalidade de Dó maior, e cada próximo índice é igual a um semitom acima. A lista binária de Si Bemol mostrado na figura 5, terá a classe com uma lista de valores: 0 0 0 0 0 0 0 0 1 0, com o índice de valor 10 positivo que é justamente o índice que representa a tonalidade de Si Bemol.

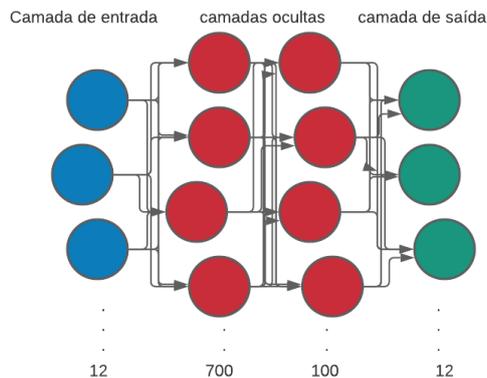


**Figura 8. Index que representa cada classe**

## 4.2. Inteligência Artificial

O objetivo da inteligência artificial foi classificar a tonalidade na escala maior natural da melodia, o modelo da rede neural usado é o Perceptron multicamadas (MLP) que foi

escolhido pelos resultados positivos, funcionando de forma efetiva ao fazer a previsão da classificação. A rede tem quatro camadas, a camada de entrada tem 12 neurônios, as duas camadas ocultas tem tamanho de 700 e 100 respectivamente, e a de saída também tem o tamanho doze, representando as doze classes. A figura abaixo exemplifica a estrutura da rede.



**Figura 9. Estrutura da rede neural**

Na construção do modelo da IA, foi usado o Keras. A codificação do modelo segue na figura abaixo.

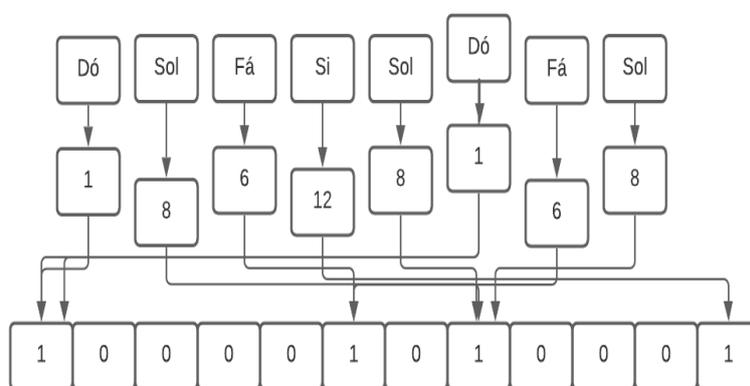
```
model = keras.Sequential()
model.add(keras.layers.Dense(700, input_shape=input_shape, activation='relu'))
model.add(keras.layers.Dense(100, activation='relu'))
model.add(keras.layers.Dense(num_classes, activation='sigmoid'))
model.compile(loss='binary_crossentropy', optimizer='adam', metrics=['accuracy'])
history = model.fit(escalasBinarioTreinamento, labelsTreinamento, epochs=30, batch_size=76, validation_split=0.2)
```

**Figura 10. Modelo da rede neural**

Primeiramente foi usado a classe *Sequential* que é apropriado para criar pilhas simples de camadas, em que toda nova camada tem a saída para a próxima. Logo após foi chamado a classe *Dense*, que faz total ligação entre todas as camadas, (KERAS, 2020). Nos argumentos da primeira camada oculta densa foi passado os parâmetros do tamanho da camada de entrada, que é 12, e a quantidade de neurônios da própria, que é 700, sua função de ativação é a linear retificada (ReLU). A escolha do ReLU foi baseado na eficiência e na simplicidade da implementação da função pois não faz operações exponencialmente caras, se houver gradientes negativos ele os transforma em 0, e teve resultados expressivos nos testes da rede. A segunda camada oculta é similar a primeira, usando também a função de ativação ReLU, mas possuindo 100 neurônios. A última camada, a de saída, tem a dimensão da quantidade de classes, que são 12, e usa a função de ativação *Sigmoid*, que faz a previsão dos valores de cada classe para que seja positivo e limitado entre 0 e 1. Para configurar as métricas, perdas, e otimizador é usado a classe *Compile*. Os otimizadores são algoritmos que melhoram a predição da rede neural, durante o processo de treinamento os otimizadores moldam o modelo de forma precisa mexendo nos pesos das sinapses, a função de perda é o que informa ao otimizador se ele está trabalhando de forma certa ou errada (ALGORITHMIA, 2018). Um otimizador funciona armazenando gradientes anteriores para calcular os gradientes

atuais, os gradientes representam a relação da mudança de um peso com a função de perda. O otimizador usado é o *Adaptive Moment Estimation* (Adam), ele mantém uma média exponencial decrescente dos gradientes anteriores (ALGORITHMIA, 2018). A função de perda é usada como medida para saber se o modelo de previsão é capaz de prever o resultado esperado, a função de entropia cruzada ou *cross-entropy* mede o desempenho do modelo de classificação em que a saída é um valor com probabilidades entre 0 e 1, aumentando a perda quando a probabilidade da predição diverge do resultado esperado, (TRUONG, 2019). A função de perda usada no modelo foi o *binary cossentropy* ou entropia cruzada binária, essa função classifica o resultado entre 0 e 1 e para fazer a classificação entre os 12 rótulos das classes, é calculado individualmente a entropia cruzada binaria de cada rótulo e depois é feito a somatória para chegar a perda completa (MARTINEK, 2020). A função métrica é usada para julgar a performance do modelo, essa função é semelhante a função de perda, só que o resultado da avaliação não é usado para treinar o modelo, a métrica de acurácia calcula em qual frequência a previsão é parecido com o modelo do resultado esperado (KERAS, 2020). O método *Fit* começa o treinamento da rede neural que recebe como parâmetros o banco de dados para o treinamento e suas respectivas classes, a quantidade de épocas, tamanho do lote, e a divisão para validação. Foi dividido 20% das 96 listas de tonalidades em binário que foram treinados na rede, isso porque o Keras pode separar parte dos dados de treinamento em um conjunto de dados para validação e avaliar o desempenho do modelo baseado nesse conjunto a cada época, (BROWNLEE, 2016). As épocas são usadas para separar o treinamento em fases distintas, o que é útil para o registro e avaliações periódica, ou seja, após cada época serão salvos os valores das métricas e reutilizados nas próximas épocas, (KERAS, 2020). O tamanho de lote é o número de amostras processadas antes das atualizações do modelo, nessa rede é usado 76, o mesmo tamanho do banco de treinamento do modelo, (BROWNLEE, 2018).

Testando a rede, com os dados de entrada sendo uma melodia com as sequências das notas Dó, Sol, Fá, Si, Sol, Dó, Fá, Sol, o conjunto foi transformado em sua sequência binária como representado na figura abaixo, sendo usado como entrada na rede neural que trabalhou por 30 épocas.



**Figura 11. Melodia transformado em lista de binários**

Depois de compilado, foi usado a biblioteca Matplotlib para a geração dos gráficos de desempenho da acurácia e perda do treinamento e teste da rede. Observando o gráfico da figura 12, observa-se que há uma melhora progressiva da acurácia do teste

e treinamento até a quinta época, depois disso os gráficos seguem com os mesmos valores, que são 0.9167. Já o modelo de perda do teste e do treinamento representado no gráfico da Figura 13, segue em declínio até aproximadamente 15 épocas, a partir desse momento o valor da perda do teste começa a subir novamente chegando no final das 30 épocas em um valor de 0.4255, já o gráfico do treinamento da rede segue em declínio ao longo de todas as épocas, chegando ao valor de 0.1970 de perda .

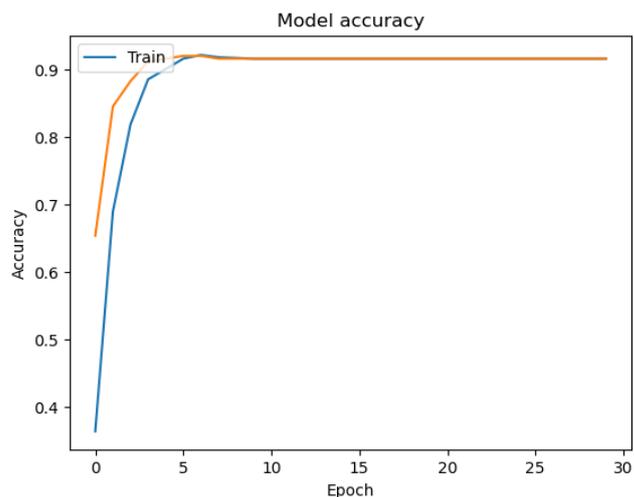


Figura 12. Gráfico da acurácia do teste e treinamento da rede neural

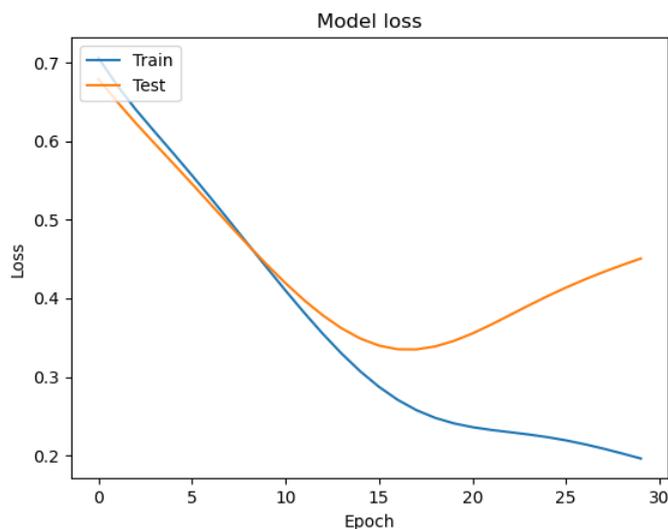


Figura 13. Gráfico de perda da rede neural

Finalmente a predição determinou os valores entre as 12 classes, tendo o maior valor o resultado 0.2768, que se encontra no índice de número 0, portanto, segundo a figura 8, a melodia está em escala de Dó Maior.

```
Epoch 30/30
76/76 [=====] - 0s 714us/sample - loss: 0.1961 - acc: 0.9167 - val_loss: 0.4506 - val_acc: 0.9167
[[0.27684486 0.08620235 0.11027923 0.11477777 0.03367904 0.09706998
 0.11802408 0.13159609 0.13151601 0.0572249 0.02165055 0.0198212 ]]
0
```

Figura 14. Resultado da predição da rede neural

### 4.3. Harmonizando a melodia

Com a tonalidade da melodia, é possível saber seu campo harmônico, podendo assim identificar as funções harmônicas de cada nota com seus respectivos graus. Seguindo com a melodia e o resultado do exemplo da rede neural, que são as notas Dó, Sol, Fá, Si, Sol, Dó, Fá, Sol, na tonalidade de Dó Maior. Foi criada uma função que tem como parâmetros a lista de representações numéricas das notas que é retornada na função da Figura 3, e o valor que representa a tonalidade da melodia que foi retornada pela rede neural representado na Figura 14. Através desses parâmetros é gerando uma lista de graus que tem o mesmo tamanho da lista da melodia, e tem como conteúdo o conjunto de graus que representa cada nota no campo harmônico de sua tonalidade. Se houver uma nota na melodia que não pertence a nenhum grau, ele terá o valor 0. A figura abaixo segue o exemplo das notas da melodia e seus respectivos graus no campo harmônico de Dó Maior.

Notas	Dó	Sol	Fá	Si	Sol	Dó	Fá	Sol
N° das notas	1	8	6	12	8	1	6	8
Graus	1	5	4	7	5	1	4	5

**Figura 15. Grau das notas da melodia**

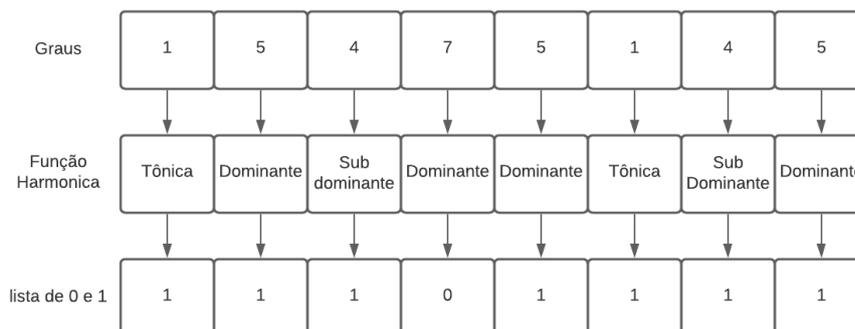
Com a lista dos graus das notas da melodia, representado na Figura 15, foi criada uma nova lista que representa a função harmônica de cada grau dentro do campo harmônico da melodia. A Figura abaixo mostra o exemplo dos nomes, números, graus, e funções harmônicas das notas da melodia.

Notas	Dó	Sol	Fá	Si	Sol	Dó	Fá	Sol
N° das notas	1	8	6	12	8	1	6	8
Graus	1	5	4	7	5	1	4	5
Função Harmônica	Tônica	Dominante	Sub dominante	Dominante	Dominante	Tônica	Sub Dominante	Dominante

**Figura 16. Lista das funções harmônicas da melodia**

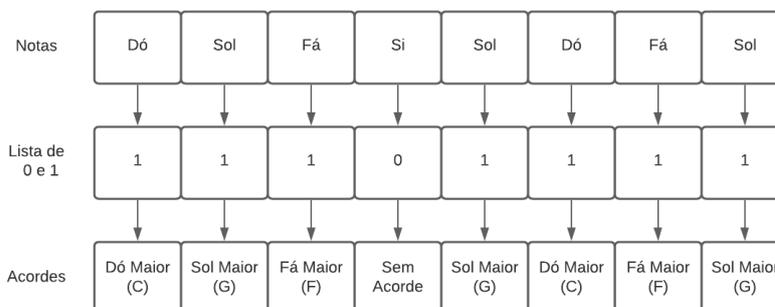
Antes de entregar os acordes relacionados a melodia de entrada, todos os graus da lista de funções harmônicas da Figura 16 foram filtrados por uma função que tem o objetivo de descartar os elementos que se repetem. O propósito dessa função é aplicar o estudo de sensações da harmonia funcional havendo alternâncias nas funções harmônicas trazendo ao conjunto de acordes sentimentos de preparação, instabilidade e repouso. Essa função percorre toda a lista das funções harmônicas e gera uma nova lista

de números entre 0 e 1. Caso um dos elementos da lista das funções for igual ao elemento do index seguinte haverá uma comparação baseado na qualidade funcional de seus respectivos graus, e o grau que representar a função mais forte receberá o valor 1, e o mais fraco valor 0. Para garantir que haja uma sensação de repouso, e não instabilidade no final da harmonia, caso o último elemento da lista da Figura 16 não for uma função tônica, será verificado se a penúltima função é, e caso seja, o último index da nova lista terá de valor 0. A representação da figura abaixo exemplifica o resultado dessa função usando os dados do exemplo das funções anteriores.



**Figura 17. Lista de 0 e 1 das funções harmônicas**

Com a lista de graus que a função da Figura 15 retornou, juntamente com a lista da função da Figura 17, foi finalmente distribuído os acordes em uma nova lista, substituindo os graus positivos pelo seu acorde baseado em seu campo harmônico. Na figura abaixo é retratado o resultado final do processo mostrando a melodia de entrada e os acordes de saída realizado com os mesmos dados das funções anteriores.



**Figura 18. Conjunto de acordes de saída**

#### 4.4. Análise dos resultados e considerações

Dentro da proposta do estudo de caso, que foi criar um software que entrega um conjunto de acordes baseado nas notas musicais de uma melodia, o pré-processamento dos dados, funciona bem com o auxílio da classe *Tokenizer* que padroniza em valores numéricos as notas de entrada, e apesar de pouco intuitivo a inserção dos dados em forma de texto, o *Tokenizer* reduz a probabilidade das notas não serem convertidas em números, pois dispõe de funções práticas como o *texts\_to\_word\_sequences* que pode ser usado pra dividir o texto em uma lista de palavras e por padrão divide as palavras por espaço, filtra pontuações, e converte todo o texto digitado em caixa-baixa, formatando o texto caso haja diferença entre caixa-alta e caixa-baixa, (BROWNLEE, 2017).

Durante a composição de uma música, se a escolha for criar a melodia e depois a harmonia, é preciso identificar em qual escala e tonalidade a melodia está sendo composta. Portanto, no estudo de caso a conversão das tonalidades na escala maior em sequências binárias possibilitou transformar qualquer sequência de acordes da melodia em um conjunto binário de tamanho padrão, mesmo se a lista da melodia for grande e ter repetições de acordes. Além disso, facilitou o processo de criar novas listas para popular o banco de dados para treinamento, que através de pequenos ajustes criou diferentes possibilidades para cada tonalidade.

Através das abstrações do Keras foi possível, em poucas linhas de código, aplicar o modelo Perceptron Multicamadas. Sendo que as duas camadas ocultas, a quantidade de neurônios de cada camada, o número de épocas, e divisão para validação foram escolhidos através de testes e análises. Fazendo comparações com as possibilidades de cada item, usando a mesma melodia de entrada dos testes no estudo de caso, representados na Figura 11, quando há apenas uma camada oculta de tamanho 700, no final das 30 épocas os resultados da acurácia e perda do treinamento e teste da rede neural foram bons e trouxeram números semelhantes aos do exemplo do estudo de caso mostrado na Figura 14. Acompanhando a Figura 19, a acurácia tem o valor de 0.9167 no treinamento e no teste, e a perda é de 0.2429 no treino, e 0.3211 no teste o que significa que há menos perda no teste que os valores do resultado do estudo de caso, porém os valores de cada classe na predição são muito próximos, tendo uma diferença menor que um décimo. O que não acontece quando há duas camadas como na Figura 14, que mantém um resultado significativo entre o maior e o menor valor da predição.

```
Epoch 30/30
76/76 [=====] - 0s 661us/sample - loss: 0.2429 - acc: 0.9167 - val_loss: 0.3211 - val_acc: 0.9167
[[0.19986495 0.1625785 0.16288027 0.16647029 0.12465635 0.16238096
 0.14001325 0.167238 0.14792675 0.11593783 0.10469529 0.10695875]]
0
```

**Figura 19. Resultados da rede neural com uma camada oculta de tamanho 700**

Analisando os dados de teste no gráfico da Figura 12, a partir da época 17 os valores da perda começam a subir após uma constante decida. Seguindo com o mesmo modelo da Figura 14, apenas mudando a quantidade de épocas para 16, que é o último momento que a perda decresce no gráfico, os resultados ficam como mostrado na Figura 20, a perda do teste é de 0.3185 e do treinamento 0.2786. Os dados de perda e acurácia parecem bem consistentes, mas diferente dos dados da Figura 14 ao compilar o mesmo modelo haver valores e resultados diferentes, como mostrado na Figura 21. Isso acontece porque na escala maior natural há apenas 12 tonalidades, e algumas vezes apenas uma nota difere duas escalas de terem o mesmo conjunto de notas musicais, portanto melodias que possuem duas ou mais notas pertencentes a mesma escala, possuem resultados parecidos na predição da rede neural.

```
Epoch 16/16
76/76 [=====] - 0s 304us/sample - loss: 0.2786 - acc: 0.9167 - val_loss: 0.3185 - val_acc: 0.9167
[[0.3276065 0.17117518 0.12092733 0.18250269 0.239322 0.13885978
 0.1820336 0.17983982 0.15265265 0.20620227 0.20638654 0.10504788]]
0
```

**Figura 20. Resultado da rede neural com 16 épocas**

```

Epoch 16/16
76/76 [=====] - 0s 159us/sample - loss: 0.2901 - acc: 0.9167 - val_loss: 0.3613 - val_acc: 0.9167
[[0.28254825 0.15109247 0.10314381 0.25813 0.18695861 0.25563842
 0.29824567 0.22737104 0.3079348 0.05159625 0.17762661 0.18949646]]
8

```

**Figura 21. Resultado diferente da rede neural com 16 épocas**

Depois das funções que usam os conceitos harmonia e qualidade funcional para gerar sentimentos e sensações no processo da harmonização da melodia, a lista com a sequência de acordes são entregues em forma de texto assim como na Figura 18, acompanhado com a lista das notas da melodia de entrada, o acorde do primeiro índice da lista dos acordes representa a nota musical do primeiro índice da lista melodia, assim seguindo sucessivamente. Na Figura 22, mostra o resultado da melodia da Figura 11, que tem a tonalidade de Dó Maior como mostrado na Figura 14, validando finalmente a harmonização da melodia.

```

[[0.27088636 0.08115029 0.06724313 0.17360243 0.06102818 0.0980269
 0.12968513 0.08680296 0.16446584 0.02903131 0.02909347 0.01788849]]
0
['Do Sol Fa Si Sol Do Fa Sol']
['C', 'G', 'F', 'none', 'G', 'C', 'F', 'G']

```

**Figura 22. Resultado da tonalidade, melodia e harmonia**

## 5. Conclusões

Durante o desenvolvimento do estudo foi verificado que a evolução da tecnologia e consequentemente da inteligência artificial, em termos de facilidade em todos os tipos de âmbitos, possibilitou a abstração de conhecimento musical para as pessoas que querem criar suas próprias músicas. Isso é um benefício, pois se a intenção de toda nova tecnologia é facilitar e auxiliar pessoas em suas atividades, o uso de softwares na criação de músicas oferece a oportunidade para qualquer pessoa, mesmo sem muito conhecimento musical, compor sua música.

Ao longo dos anos foram catalogados padrões na música que atrelados aos conhecimentos físicos e matemáticos foi criado a teoria musical, e embora seja de natureza humana se expressar através da música, com base nos estudos da teoria musical e ao avanço tecnológico, máquinas conseguem auxiliar na composição como apresentado no estudo de caso, ou até mesmo criar suas próprias canções como visto no projeto AIVA. Se o uso das novas tecnologias é para fins profissionais, é verdade que o mercado da música se encontra em uma crescente nos últimos anos, e novas tecnologias buscam deixar mais palpável aos ouvidos humanos a arte de uma inteligência artificial, baseada em obras humanas, criar músicas tão emocionantes e originais quanto.

Atestamos no estudo de caso que baseado em automações das regras e padrões da teoria musical o software recebe um conjunto de notas musicais, reconhece sua tonalidade na escala maior natural usando uma I.A com modelo MLP, que trabalha com uma boa acurácia e com uma perda permissível, tendo assim uma confiável predição. Logo depois, segue com um conjunto de funções que trabalha baseado na teoria das funções harmônicas justamente para que os acordes entregues transmitam diferentes emoções, provando que a implementação do software foi capaz de harmonizar uma melodia.

Boas sugestões para implementações futuras é conseguir trabalhar com mais escalas, além de deixar mais abstrato a inserção dos dados de entrada, de modo que seja possível usar outros tipos de inteligência artificial para identificar quais são as notas tocadas. E criar uma interface gráfica para reproduzir os acordes que foram entregues.

## 6. Referências

- JESS, G.M. (2004) “Inteligência artificial e tecnologias da inteligência – Um repensar Segundo os processos de elaboração matemática”, Universidade Federal do Paraná, Curitiba, Paraná, p. 24-26.
- WALT, S.V.D., COLBERT, S.C., VAROQUAUX, G. (2011) “The NumPy array: a structure for efficient numerical computation”, IEEE Computing in Science and Engineering, p. 1.
- PROTASIEWICZ, J. (2018) “Why Is Python So Good for AI, Machine Learning and Deep Learning?”. Disponível em: <https://www.netguru.com/blog/python-machine-learning>. [acesso em: 10 de set. de 2020]
- TURING, A. (1950) “Computing Machinery and Intelligence” Mind, volume 59, edição 236, p. 433-460.
- BARREAU, P. (2018) “How AI could compose a personalized soundtrack to your life”, TED. Disponível em: [https://www.ted.com/talks/pierre\\_barreau\\_how\\_ai\\_could\\_compose\\_a\\_personalized\\_soundtrack\\_to\\_your\\_life](https://www.ted.com/talks/pierre_barreau_how_ai_could_compose_a_personalized_soundtrack_to_your_life). [acesso em: 2 de set. de 2020].
- SHANNON, R. E., MAYER, R., ADELSBERGER, H. H. (1985) “Expert systems and simulation” Simulation, 44, 6, p. 275-284.
- IVAN, S. S. (2004) “A importância da inteligência artificial e dos sistemas especialistas”, CEFET/RJ, Departamento de Pesquisa e Pós-Graduação em Tecnologia, Rio de Janeiro, Rio de Janeiro.
- ROSENBLATT, F. (1958) “The perceptron: A probabilistic model for information storage and organization in the brain”, Psychological review Vol. 65, No. 6.
- CHAGAS, E. T. O. (2019) “Deep Learning e suas aplicações na atualidade”, Revista Científica Multidisciplinar Núcleo do Conhecimento. Ano 04, Ed. 05, Vol. 04, p. 05-26.
- ANDREWS, E. (2018) “What is the oldest known piece of music?”. Disponível em: <https://www.history.com/news/what-is-the-oldest-known-piece-of-music>. [acesso em: 10 de set. de 2020]
- CLIFTON, T. (1983) “Music as Heard: A Study in Applied Phenomenology”, Yale University, New Haven.
- KIEFER, B. (1979) “Elementos da linguagem musical”, Editora Movimento, Porto Alegre, RS.
- PALOTTA, F., CNN Business. (2020) “The music industry was left for dead a few years ago. Now it’s booming again”. CNN Business. Disponível em: <https://edition.cnn.com/2020/02/28/media/music-industry-streaming/index.html>. [acesso em: 10 de set. de 2020]

- PAYNE, C. (2019). “MuseNet”. OpenAI. Disponível em: <https://openai.com/blog/musenet/>. [acesso em: 2 de set. de 2020]
- SCHULKIN, J., RAGLAN, G.B. (2014) “The evolution of music and human social capability”. Frontiers. Disponível em: <https://www.frontiersin.org/articles/10.3389/fnins.2014.00292/full>. [acesso em: 20 de out. de 2020]
- GRAUE, J.C. (2017) “Scale Music”. Britannica. Disponível em: <https://www.britannica.com/art/scale-music>. [acesso em: 20 de out. de 2020].
- Visual Studio Code (2019) “Python in Visual Studio Code”, Disponível em: <https://code.visualstudio.com/docs/languages/python>. [acesso em: 22 de out. de 2020].
- TUFFANI, M. (2010). “O verdadeiro inventor do rádio”. Revista Ponto Critico, Edição 14, P. 50.
- Encyclopedia Britannica. (2017). “Golden Age of American Radio”. Britannica. Disponível em: <https://www.britannica.com/topic/Golden-Age-of-American-radio>. [acesso em: 23 de out. de 2020].
- MCNAMARA, R. (2019) “Ed Sullivan Host of Variety Show Influenced American Culture”. ThoughtCo., Disponível em: <https://www.thoughtco.com/ed-sullivan-4589827>. [acesso em: 23 de out. de 2020].
- Encyclopedia Britannica. (2020) “MTV”. Britannica. Disponível em: <https://www.britannica.com/topic/MTV>. [acesso em: 23 de out. de 2020].
- FLY, B. (2016) “How Does Music Consumption Impact The Music Industry and Benefit Artists”, University of Arkansas, Fayetteville, Arkansas, p. 9-10.
- FRIEDLANDER, J. P. (2020) “YEAR-END 2019 RIAA MUSIC REVENUES REPORT”, Senior Vice Presindet, Research & Economics, RIAA.
- RING, I. (2019) “A Study of Scales”. The Exciting Universe of Music Theory, Disponível em: <https://ianring.com/musictheory/scales> . [acesso em: 10 de nov. de 2020].
- Keras (2020) “The Sequential Model”, Keras, Disponível em: [https://keras.io/guides/sequential\\_model](https://keras.io/guides/sequential_model) . [acesso em: 10 de nov. de 2020].
- Keras (2020) “The Model Class”, Keras, Disponível em: <https://keras.io/api/models/model/> . [acesso em: 10 de nov. de 2020].
- Algorithmia. (2018). “Introduction to Optimizers”. Algorithmia. Disponível em: <https://algorithmia.com/blog/introduction-to-optimizers> . [acesso em: 10 de nov. de 2020].
- TRUONG, P. (2019) “Loss function: Why, what, where or when?”. Medium, Disponível em: <https://medium.com/@phucrt/loss-functions-why-what-where-or-when-189815343d3f> . [acesso em: 10 de nov. de 2020].
- Keras (2020) “Metrics”, Keras, Disponível em: <https://keras.io/api/models/model/> . [acesso em: 10 de nov. de 2020].
- BROWNLEE, J. (2016) “Evaluate the Performance of Deep Learning Models in Keras”,

- Machine Learning Mastery, Disponível em: <https://machinelearningmastery.com/evaluate-performance-deep-learning-models-keras/> . [acesso em: 10 de nov. de 2020].
- BROWNLEE, J. (2016) “Difference Between a Batch and an Epoch in a Neural Network”, Machine Learning Mastery, Disponível em: <https://machinelearningmastery.com/difference-between-a-batch-and-an-epoch/> . [acesso em: 10 de nov. de 2020].
- Keras (2020) “Keras FAQ”, Keras, Disponível em: [https://keras.io/getting\\_started/faq/](https://keras.io/getting_started/faq/) . [acesso em: 10 de nov. de 2020].
- TensorFlow (2020) “Tokenizer”, TensorFlow, Disponível em: [https://www.tensorflow.org/api\\_docs/python/tf/keras/preprocessing/text/Tokenizer](https://www.tensorflow.org/api_docs/python/tf/keras/preprocessing/text/Tokenizer) . [acesso em: 10 de nov. de 2020].
- CECCON, D. (2020) “Funções de ativação: definição, características, e quando usar cada uma”, Expert Academy, Disponível em: <https://iaexpert.academy/2020/05/25/funcoes-de-ativacao-definicao-caracteristicas-e-quando-usar-cada-uma/> . [acesso em: 10 de nov. de 2020].
- LEITE, T. M. (2018) “Redes Neurais, Perceptron, Multicamadas e o algoritmo Backpropagation”, Ensina AI, Disponível em: <https://medium.com/ensina-ai/redes-neurais-perceptron-multicamadas-e-o-algoritmo-backpropagation-eaf89778f5b8> . [acesso em: 10 de nov. de 2020].
- MATHUR, P. (2016) “What is Anaconda and why should I bother about it?”, Medium, Disponível em: <https://medium.com/pankajmathur/what-is-anaconda-and-why-should-i-bother-about-it-4744915bf3e6> . [acesso em: 10 de nov. de 2020].
- Schonberg, A. (1983) “Theory of Harmony”, University of California Press.
- NumPy (2020) “What is Numpy”, NumPy, Disponível em: <https://numpy.org/doc/stable/user/whatisnumpy> . [acesso em: 10 de nov. de 2020].
- TensorFlow (2020) “keras”, TensorFlow, Disponível em: <https://www.tensorflow.org/guide/keras?hl=pt-br> . [acesso em: 10 de nov. de 2020].
- Matplotlib (2020) “Matplotlib: Visualization with Python”, Matplotlib, Disponível em: <https://matplotlib.org/> . [acesso em: 10 de nov. de 2020].
- SILVA, L. T. (2018) “Matemática e Música: a história da relação e evolução de duas Ciências através dos tempos”, RBECM, Passo Fundo, Volume 1, p. 130-141.
- BROWNLEE, J. (2019) “How to prepare Text data for deep learning with Keras”, Machine Learning Mastery, Disponível em: <https://machinelearningmastery.com/prepare-text-data-deep-learning-keras/> . [acesso em: 15 de nov. de 2020].
- DELLA VENTURA, M. (2015) “Automatic Tonal Music Composition Using Functional Harmony”, Social Computing, Behavioral-Cultural Modeling, and Prediction. p. 290-295.
- LAUDER, E. (2017) “AIVA is the first AI to Officially be Recognised as a Composer”, AI Business, Disponível em: [https://aibusiness.com/document.asp?doc\\_id=760181](https://aibusiness.com/document.asp?doc_id=760181) . [acesso em: 15 de nov. de 2020].

MORITOTO, C. E. (2005) “MIDI”, Hardware.com.br, Disponível em: <https://www.hardware.com.br/termos/midi> . [acesso em: 29 de nov. de 2020].

MARTINEK, V. (2020) “Cross-entropy for classification”, Towards data science, Disponível em: <https://towardsdatascience.com/cross-entropy-for-classification-d98e7f974451> . [acesso em: 29 de nov. de 2020].