

UNIWERSYTET IM. ADAMA MICKIEWICZA W POZNANIU  
WYDZIAŁ MATEMATYKI I INFORMATYKI

**Cezary Adam Pukownik**

Kierunek: Analiza i przetwarzanie danych  
Numer albumu: 444337

**Generowanie muzyki  
przy pomocy głębokiego uczenia**

**Music generation with deep learning**

Praca magisterska  
napisana pod kierunkiem  
dr hab. Tomasza Góreckiego

POZNAŃ 2020



Poznań, dnia .....

## OŚWIADCZENIE

Ja, niżej podpisany Cezary Pukownik, student Wydziału Matematyki i Informatyki Uniwersytetu im. Adama Mickiewicza w Poznaniu oświadczam, że przedkładaną pracę dyplomową pt: "Generowanie muzyki przy pomocy głębokiego uczenia", napisałem samodzielnie. Oznacza to, że przy pisaniu pracy, poza niezbędnymi konsultacjami, nie korzystałem z pomocy innych osób, a w szczególności nie zlecałem opracowania rozprawy lub jej części innym osobom, ani nie odpisywałem tej rozprawy lub jej części od innych osób.

Oświadczam również, że egzemplarz pracy dyplomowej w wersji drukowanej jest całkowicie zgodny z egzemplarzem pracy dyplomowej w wersji elektronicznej.

Jednocześnie przyjmuję do wiadomości, że przypisanie sobie, w pracy dyplomowej, autorstwa istotnego fragmentu lub innych elementów cudzego utworu lub ustalenia naukowego stanowi podstawę stwierdzenia nieważności postępowania w sprawie nadania tytułu zawodowego.

[TAK]\* - wyrażam zgodę na udostępnianie mojej pracy w czytelni Archiwum UAM

[TAK]\* - wyrażam zgodę na udostępnianie mojej pracy w zakresie koniecznym do ochrony mojego prawa do autorstwa lub praw osób trzecich

\*Należy wpisać TAK w przypadku wyrażenia zgody na udostępnianie pracy w czytelni Archiwum UAM, NIE w przypadku braku zgody. Niewypełnienie pola oznacza brak zgody na udostępnianie pracy.

.....



---

# Spis treści

---

---

<b>Streszczenie</b> . . . . .	7
<b>Abstract</b> . . . . .	9
<b>Wstęp</b> . . . . .	11
<b>Rozdział 1. Wprowadzenie do sieci neuronowych</b> . . . . .	13
1.1. Regresja liniowa . . . . .	13
1.2. Uczenie modelu . . . . .	14
1.2.1. Funkcja kosztu . . . . .	15
1.2.2. Znajdowanie minimum funkcji . . . . .	15
1.2.3. Metody gradientowe . . . . .	15
1.3. Regresja liniowa jako model sieci neuronowej . . . . .	17
1.4. Funkcje aktywacji . . . . .	19
1.5. Wielowarstwowe sieci neuronowe . . . . .	19
1.5.1. Jednokierunkowe sieci neuronowe . . . . .	20
1.5.2. Autoencodery . . . . .	21
1.5.3. Rekurencyjne sieci neuronowe . . . . .	22
1.5.4. LSTM . . . . .	23
1.5.5. Sequence-to-sequence . . . . .	25
<b>Rozdział 2. Wprowadzenie do teorii muzyki</b> . . . . .	27
2.1. Podstawowe koncepcje . . . . .	27
2.1.1. Dźwięk muzyczny . . . . .	27
2.1.2. Sygnał dźwiękowy . . . . .	27
2.1.3. Zapis nutowy . . . . .	27
2.2. Cyfrowa reprezentacja muzyki symbolicznej . . . . .	31
2.2.1. Standard MIDI . . . . .	31
<b>Rozdział 3. Projekt</b> . . . . .	33
3.1. Koncepcja . . . . .	33
3.2. Wstępne przygotowanie danych do treningu . . . . .	34
3.2.1. Przykład działania One-Hot Encoding . . . . .	34
3.2.2. Muzyczne "słowo" . . . . .	34
3.2.3. Konwersja MIDI na sekwencje słów muzycznych . . . . .	35
3.2.4. Inne aspekty przygotowania danych . . . . .	38
3.2.5. Podział danych na dane wejściowe i wyjściowe . . . . .	38

3.2.6. Inne aspekty przygotowania zbioru uczącego . . . . .	41
3.3. Transformacja danych dla modelu . . . . .	43
3.4. Definicja modelu . . . . .	43
3.5. Uczenie modelu . . . . .	43
3.6. Generowanie muzyki przy pomocy wytrenowanego modelu . . . . .	43
3.7. Wyniki . . . . .	43
3.8. Wnioski . . . . .	43
<b>Rozdział 4. Podsumowanie . . . . .</b>	<b>45</b>
<b>Bibliografia . . . . .</b>	<b>47</b>

---

## Streszczenie

---

---





---

# Abstract

---

---



---

# Wstęp

---

---

Uczenie maszynowe w ostatnich latach mocno zyskało na popularności. Zastosowania i możliwości różnych algorytmów uczenia maszynowego czasami przekraczają nasze wyobrażenie o tym co komputer może zrobić. Niektóre aplikacje potrafią wręcz zaskoczyć użytkowników tym co potrafią zrobić. Wśród takich aplikacji znajdują się takie, które potrafią przewidywać następne wartości akcji giełdowych, rozpoznawać na filmie obiekty w czasie rzeczywistym, czy nawet prowadzić samochód. Algorytmy wyuczone proponują nam spersonalizowane reklamy, czy produkty na podstawie naszych upodobań. Najczęstsze zastosowania dotyczą przetwarzania obrazów lub tekstu, natomiast zastosowania w przetwarzaniu muzyki są niszowe i rzadziej spotykane.

Celem tej pracy jest stworzenie modelu sieci neurowej, którego zadaniem będzie generowanie krótkich multiinstrumentalnych klipów muzycznych.

W pierwszej części swojej pracy przedstawię podstawowe koncepcje związane z muzyką oraz sposobami jej reprezentacji. Następnie opiszę w jaki sposób działają sieci neuronowe, jak się uczą oraz podstawowe architektury sieci, które pomogą zrozumieć model który wykorzystałem.

Następnie przedstawię koncepcję działania modelu, jakie idee stały za wyborami, które podjąłem w projektowaniu sieci. W szczególowy sposób opiszę sposób ekstrakcji danych tak aby mogły być one wykorzystane przez model. Opiszę architekturę którą wybrałem oraz przedstawię i opiszę fragmenty kodu w języku python.

W kolejnym rozdziale skupimy się na rezultatach pracy, przedstawię zalety i wady modelu. Przeprowadzę analizę jakie muzyczne koncepcje model się nauczył na podstawie danych oraz doprowadzę do ostatecznej konkluzji czy wygenerowana muzyka może być przyjemna dla odbiorcy.



# Wprowadzenie do sieci neuronowych

---

---

Aby lepiej zrozumieć w jaki sposób odpowiednio skonstruowane sieci neuronowe potrafią sprostać takiemu zadaniu jak generowanie muzyki, w tym rozdziale przedstawię od podstaw zasady działania sieci neuronowych. Opiszę w jaki sposób można od regresji liniowej przejść do prostych sieci oraz w jaki sposób uczy się sieci neuronowe. Ostatecznie przedstawię architektury, które wykorzystałem w projekcie.

## 1.1. Regresja liniowa

Podstawą wszystkich sieci neuronowych jest regresja liniowa. W statystyce wykorzystywana, aby wyjaśnić liniowe zależności między zmiennymi.

Prosty model regresji liniowej dla jednej zmiennej można opisać wzorem


$$y = ax + b + \epsilon,$$

gdzie

- $y$  jest zmienną objaśnianą,
- $x$  jest to zmienna objaśniająca,
- $a$  jest parametrem modelu,
- $b$  jest wyrazem wolnym modelu,
- $\epsilon$  jest składnikiem losowym [7].

Zadaniem jest znalezienie takiego parametru  $a \in \mathbb{R}$  oraz wyrazu wolnego  $b \in \mathbb{R}$ , aby dla znanych wartości  $x \in \mathbb{R}$  oszacowanie zmiennej objasniającej  $\hat{y} \in \mathbb{R}$  najlepiej opisywała zmienną objasnaną  $y \in \mathbb{R}$ . Tak zdefiniowany model opisuje zmienną  $y$  z dokładnością do składnika losowego. W praktyce oznacza to, że szacowane modele będą przybliżeniem opisywanych zależności.

Wartość zmiennej objaśnianej  $y$  można również opisać za pomocą wielu zmiennych objaśniających. Wtedy dla zmiennych objaśniających  $x_1, x_2, \dots, x_p \in \mathbb{R}$  szukamy parametrów  $\theta_1, \theta_2, \dots, \theta_p \in \mathbb{R}$ , gdzie  $p \in \mathbb{N}$  jest liczbą cech. Otrzymany w ten sposób model nazywany jest również hipotezą i oznaczamy go  $h(x)$ .



**Rysunek 1.1.** Regresja liniowa jednej zmiennej

$$h(x) = b + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_p x_p + \epsilon = b + \sum_{i=1}^p \theta_i x_i + \epsilon.$$

Rysunek 1.1 przedstawia przykładowy model regresji liniowej jednej zmiennej, dopasowany do zbioru.

## 1.2. Uczenie modelu

Celem uczenia modelu jest znalezienie ogólnych parametrów, aby model dla wartości wejściowych  $x$  zwracał wartości predykcji  $\hat{y}$  najlepiej opisującej całe zjawisko według pewnego kryterium. Formalnie, aby suma wszystkich różnic między predykcją, a rzeczywistością była najmniejsza.

$$\text{błąd} = \sum_{i=1}^m |\text{predykcja} - \text{rzeczywistość}|,$$

gdzie  $n \in \mathbb{N}$  jest wielkością zbioru danych jakim dysponujemy. Minimalizując błąd dla modelu jesteśmy w stanie znaleźć przybliżenie funkcji  $h(x)$ .

### 1.2.1. Funkcja kosztu

W tym celu używa się funkcji  $J_\theta(h)$ , która zwraca wartość błędu między wartościami  $h(x)$  oraz  $y$  dla wszystkich obserwacji. Taka funkcja nazywana jest funkcją kosztu (*ang. cost function*).

Dla przykładu regresji liniowej funkcją kosztu może być błąd średniokwadratowy (*ang. mean squared error*). Wtedy funkcja kosztu przyjmuje postać:

$$J_\theta(h) = \frac{1}{m} \sum_{i=1}^m (y_i - h(x_i))^2.$$

Przy zdefiniowanej funkcji kosztu proces uczenia sprowadza się do znalezienia takich parametrów funkcji  $h(x)$ , aby funkcja kosztu była najmniejsza. Jest to problem optymalizacyjny sprowadzający się do znalezienia globalnego minimum funkcji.

### 1.2.2. Znajdowanie minimum funkcji

Aby znaleźć minimum funkcji  $f$  możemy skorzystać z analizy matematycznej. Wiemy, że jeśli funkcja  $f$  jest różniczkowalna, to funkcja może przyjmować minimum lokalne, gdy  $f'(x_0) = 0$  dla pewnego  $x_0$  z dziedziny funkcji  $f$ . Dodatkowo jeśli istnieje otoczenie punktu  $x_0$ , że dla wszystkich punktów z tego otoczenia spełniona jest nierówność:

$$f(x) > f(x_0),$$

to znaleziony punkt  $x_0$  jest minimum lokalnym. W teorii należałoby zatem wybrać taką funkcję kosztu, aby była różniczkowalna. Rozwiązać równanie  $J'_\theta(h) = 0$ , następnie dla otrzymanych wyników sprawdzić powyższą nierówność oraz wybrać najmniejszy wynik ze wszystkich [6]. W praktyce rozwiązanie takiego równania ze względu na jego złożoność może się okazać niewykonalne. Aby rozwiązać ten problem powstały inne metody, które pozwalają szukać ekstremów funkcji, jednak nigdy nie będziemy mieli pewności, że otrzymany wynik jest minimum globalnym funkcji kosztu.

### 1.2.3. Metody gradientowe


Metody gradientowe (*ang. gradient descent*) są to iteracyjne algorytmy służące do znajdowania minimum funkcji. Aby móc skorzystać z metod gradientowych analizowana funkcja musi być ciągła oraz różniczkowalna. Sposób ich działania można intuicyjnie opisać w następujących krokach.

1. Wybierz punkt początkowy.
2. Oblicz kierunek, w którym funkcja maleje.

3. Przejdź do kolejnego punktu zgodnie obliczonym kierunkiem o pewną małą wartość.

4. Powtarzamy, aż osiągniemy minimum funkcji.

Wizualizację algorytmu została przedstawiona na rysunku 1.2.



**Rysunek 1.2.** Wizualizacja algorytmu gradientu prostego

Dla funkcji  $h(x)$  należy ustalić wartość początkową  $\Theta_0$  dla wszystkich parametrów  $\theta_1 \dots \theta_p$ .

$$\Theta_0 = [\theta_1, \theta_2, \dots, \theta_n].$$

Następnie policzyć wszystkie pochodne częściowe  $\frac{\partial J_\theta(h)}{\partial \theta_i}$ . Otrzymamy w ten sposób gradient  $\nabla J_\theta(h)$ , gdzie

$$\nabla J_\theta(h) = \left[ \frac{\partial J_\theta(h)}{\partial \theta_1}, \frac{\partial J_\theta(h)}{\partial \theta_2}, \dots, \frac{\partial J_\theta(h)}{\partial \theta_n} \right].$$

Następnie obliczyć element  $\Theta_{k+1}$  ze wzoru

$$\Theta_{k+1} = \Theta_k - \alpha \nabla J_\theta(h),$$


gdzie  $\alpha \in \mathbb{R}$  jest współczynnikiem uczenia (*ang. learning rate*), a  $k \in \mathbb{N}$  jest kolejną iteracją algorytmu. Proces ten należy powtarzać do pewnego momentu. Najczęściej z góry określoną liczbę razy lub do momentu, gdy uzysk funkcji kosztu spowodowany następną iteracją jest mniejszy niż ustalona wartość. Otrzymany w ten sposób wektor parametrów  $\Theta_k$  jest wynikiem algorytmu [1].



Wykorzystując metody gradientowe otrzymujemy wyuczony model. Parametry  $\theta_i$  modelu  $h(x)$  zostały ustalone w taki sposób, aby błąd między predykcją, a rzeczywistością był najmniejszy.

### 1.3. Regresja liniowa jako model sieci neuronowej

Omawiany model regresji możemy zapisać w sposób graficzny tak jak przedstawiono na rysunku 1.3.




**Rysunek 1.3.** Regresja liniowa jako model sieci neuronowej

Każdy węzeł z lewej strony reprezentuje zmienną objaśniającą  $x_i$ . Połączenia nazywane są wagami (*ang. weights*) i reprezentują one parametry  $\theta_i$ . Węzeł z prawej strony oznaczony jako  $\hat{y}$  jest sumą iloczynów wag oraz wartości węzłów z prawej strony. Wtedy

$$\hat{y} = \begin{bmatrix} 1 \\ x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} [b \ \theta_1 \ \theta_2 \ \dots \ \theta_p] = b + x_1\theta_1 + x_2\theta_2 + \dots + x_n\theta_n = b + \sum_{i=1}^n x_i\theta_i$$

co jest równoważne omawianemu modelowi regresji liniowej. Węzły sieci nazywane są neuronami, a wyraz wolny modelu  $b$  nazywany jest biasem (*ang. bias*).

W łatwy sposób możemy rozbudować ten model do regresji liniowej wielu zmiennych. Predykcją modelu nie będzie jak do tej pory jedna wartość  $\hat{y}$ , tylko wektor wartości  $\hat{y}_1, \hat{y}_2, \dots, \hat{y}_q$ , który oznaczamy będziemy jako  $\hat{Y}$ . Model ten został przedstawiony na rysunku 1.4.



**Rysunek 1.4.** Regresja liniowa wielu zmiennych jako model sieci neuronowej

Dla uogólnienia pojedyncze wagi modelu zapisywać będą jako  $w_{pq}$ , natomiast macierz wag jako  $W$ . Algebraicznie zapisalibyśmy ten model jako

$$\begin{bmatrix} \mathbf{1} & \mathbf{1} & \dots & \mathbf{1} \\ \mathbf{x}_{11} & \mathbf{x}_{12} & \dots & \mathbf{x}_{1q} \\ \mathbf{x}_{21} & \mathbf{x}_{22} & \dots & \mathbf{x}_{2q} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{x}_{p1} & \mathbf{x}_{p2} & \dots & \mathbf{x}_{pq} \end{bmatrix} \begin{bmatrix} \mathbf{b}_1 & w_{11} & w_{12} & \dots & w_{1p} \\ \mathbf{b}_2 & w_{21} & w_{22} & \dots & w_{2p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \mathbf{b}_q & w_{q1} & w_{q2} & \dots & w_{qp} \end{bmatrix} = \begin{bmatrix} \mathbf{h}_1(\mathbf{x}) \\ \mathbf{h}_2(\mathbf{x}) \\ \vdots \\ \mathbf{h}_q(\mathbf{x}) \end{bmatrix} = \begin{bmatrix} \hat{\mathbf{y}}_1 \\ \hat{\mathbf{y}}_2 \\ \vdots \\ \hat{\mathbf{y}}_q \end{bmatrix}$$

$$\mathbf{b} + XW = \hat{Y},$$

gdzie  $p$  jest liczbą zmiennych niezależnych,  $q$  jest liczbą zmiennych zależnych,  $X$  jest rozszerzonym do macierzy o rozmiarach  $q \times p$  wektorem zmiennych objaśniających, w taki sposób że  $x_{i1} = x_{i2} = \dots = x_{ip}$  dla  $i = 1, 2, \dots, q$ ,

$W$  jest macierzą wag o rozmiarach  $p \times q$ , natomiast  $b$  jest sumą wyrazów wolnych  $b_1, \dots, b_q$ . Możemy zauważyć, że model dla wielu zmiennych jest wieloma modelami dla jednej zmiennej, gdzie każdy model operuje na tych samych danych wejściowych. Taki model może być uznany za sieć neuronową i nazywany jest perceptronem.

## 1.4. Funkcje aktywacji

Omawiany model służy rozwiązywaniu problemu regresji, ponieważ wartości predykcji nie są uregulowane i mogą przyjmować wartości z  $\mathbb{R}$ . W celu przekształcenia tego modelu, aby móc go wykorzystać do rozwiązania problemu klasyfikacji, należy dodatkowo na otrzymanym wektorze  $\hat{Y}$  wykonać pewną funkcję, która przekształci wynik. W tym celu używamy funkcji aktywacji (*ang. activation function*). Istnieje wiele różnych funkcji aktywacji, a każda posiada inną charakterystykę i wpływ na model. Najpopularniejszą grupą funkcji są funkcje sigmoidalne (*ang. sigmoid functions*). Jedną z nich jest funkcja logistyczna (*ang. logistic curve*)

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

oraz wykresie przedstawionym na rysunku 1.5

Funkcja logistyczna ma pewne użyteczne właściwości, które pozwolą kontrolować wartości węzłów oraz rzutować wartości z całego  $\mathbb{R}$  do wartości z przedziału  $(0, 1)$ . Dzięki tej właściwości funkcja logistyczna jest często używana, aby otrzymać prawdopodobieństwo wystąpienia pewnego zdarzenia. Dodatkowo funkcja logistyczna szybko przyjmuje wartości skrajne, co oznacza że dla bardzo dużych wartości ujemnych i bardzo dużych wartości dodatnich funkcja staje się mało wrażliwa na zmiany wartości wraz ze zmianą wartości argumentu [4].


W ten sposób możemy w łatwy sposób zmienić model regresji liniowej na model regresji logistycznej.

$$\sigma(b + XW) = \hat{Y}$$

W dalszych częściach pracy, kiedy będę używał funkcji aktywacji nie wskazując na konkretną funkcję, będę wykorzystywał oznaczenie  $AF(x)$ .

## 1.5. Wielowarstwowe sieci neuronowe

Model omawiany wcześniej może posłużyć jako podstawowy element do budowania bardziej skomplikowanych modeli. Aby to zrobić, należy potraktować



**Rysunek 1.5.** Funkcja logistyczna

otrzymany wektor  $\hat{Y}$  jako wektor wejściowy do następnego podstawowego modelu. Składając ze sobą wiele perceptronów w jeden model, tworzymy warstwy (*ang. layers*) sieci neuronowej.

Wyróżniamy trzy rodzaje warstw:


- warstwę wejściową (*ang. input layer*), która jest pierwszą warstwą modelu,
- warstwę wyjściową (*ang. output layer*), która jest ostatnią warstwą modelu,
- warstwy ukryte (*ang. hidden layer*), które są warstwami pomiędzy warstwą wejściową oraz wyjściową.

Na rysunku 1.6 przedstawiono sieć posiadającą warstwę wejściową, dwie warstwy ukryte oraz warstwę wyjściową.

Tego typu modele są głębokimi sieciami neuronowymi (*ang. deep neural networks*). Istnieje wiele różnych architektur głębokich sieci neuronowych, które wykorzystują te podstawowe koncepcje i rozszerzają je o dodatkowe warstwy, połączenia, funkcje aktywacji czy neurony o specjalnych właściwościach.

### 1.5.1. Jednokierunkowe sieci neuronowe

Jednokierunkowe sieci neuronowe (*ang. feedforward neural networks*) są to najprostrze sieci neuronowe, które wprost czerpią z omówionych wcześniej



**Rysunek 1.6.** Przykład modelu wielowarstwowej sieci neuronowej

podstawowych warstw. Możemy się również spotkać z nazwą wielowarstwowego perceptronu (*ang. multi layer perceptron - MLP*) ze względu na fakt, że jest zbudowany z wielu perceptronów zaprezentowanych w rozdziale 1.3. Działają one w taki sposób, że zasila się je danymi do warstwy wejściowej, następnie sukcesywnie wykonuje się obliczenia do momentu dotarcia do końca sieci. Każdy krok z warstwy  $k - 1$  do warstwy  $k$  obliczany jest zgodnie ze wzorem [1]

$$X_k = AF(b_k + W_k X_{k-1}).$$


### Propagacja wsteczna błędów

Kiedy używamy jednokierunkowych sieci neuronowych, zasilamy je danymi wejściowymi  $x$  ostatecznie otrzymując predykcję  $\hat{y}$ . Taki sposób działania nazywa się propagacją wprzód (*ang. forward propagation*). Podczas uczenia sieci kontynuuje się ten proces obliczając koszt  $J(h)$ . Propagacja wsteczna (*ang. back-propagation*) pozwala na przepływ informacji od funkcji kosztu wstecz wzdłuż sieci neuronowej, aby ostatecznie obliczyć gradient. Zasada działania algorytmu propagacji wstecznej błędów polega na sukcesywnym aktualizowaniu wag i biasów oraz przesyłaniu wstecz po warstwach sieci. Dzięki temu jesteśmy w stanie wyuczyć sieć oraz obliczyć optymalne wagi i biasy dla całej sieci neuronowej.

#### 1.5.2. Autoencodery

Autoencoder jest szczególnym przypadkiem sieci neuronowej. Posiada jedną warstwę ukrytą, a rozmiar warstwy wejściowej musi być równy rozmiarowi warstwy wyjściowej, tworząc w ten sposób symetryczną sieć, której kształt przypomina klepsydrę. Przykład autoencodera przedstawiono na rysunku 1.8.

Podczas uczenia autoencodera przedstawia się dane wejściowe jako cel. W ten sposób ta architektura stara się odtworzyć funkcje identycznościowe. Zada-



**Rysunek 1.7.** Przykład modelu autoencodera

nie jest trywialne jak mogło by się zdawać, ponieważ zazwyczaj ukryta warstwa jest mniejszego rozmiaru niż dane wejściowe. Z tego względu autoencoder jest zmuszony do wydobycia istotnych cech danych wejściowych, skompresowania, a następnie jak najwierniejszego ich odtworzenia. Część kompresująca dane nazywana jest encoderm, natomiast część dekompresująca decoderem. Cechy, które zostały odkryte przez autoencoder nazywane są zmiennymi utajnionymi (*ang. latent variables*). Zarówno encoder jak i dekoder można wyodrębnić z autoencodera i wykorzystywać go jako osobną sieć neuronową.


Ciekawą cechą decodera jest jego generatywny charakter, ponieważ dostarczając zupełnie nowe informacje jako zmienne wejściowe, dekoder odtworzy je na podobieństwo danych, na których został nauczony.

### 1.5.3. Rekurencyjne sieci neuronowe

Rekurencyjne sieci neuronowe (*ang. recurrent neural networks; RNN*) w uproszczeniu są to MLP posiadające pamięć. Wykorzystywane są do analizowania i przewidywania sekwencji wartości uporządkowanych w czasie. Rekurencyjne sieci neuronowe znalazły zastosowanie w przetwarzaniu języka naturalnego, np. tłumaczenia na różne języki świata. Potrafią poradzić sobie z różnej długości sekwencjami od krótkich zawierających kilka elementów do bardzo długich jak próbki audio, czy tekst zawierający dziesiątki tysięcy kroków czasu.

Rekurencyjne sieci neuronowe działają podobnie do omawianych w sek-

cji 1.5.1 sieci jednokierunkowych z tym wyjątkiem, że kierunek przepływu informacji płynie również wstecz sieci. Jeden neuron sieci RNN otrzymuje dane wejściowe  $x(t)$ , wytwarza dane wyjściowe  $y(t)$ , a następnie wysyła te dane wyjściowe z powrotem do samego siebie. W ten sposób neuron RNN posiada dwa wejścia  $x(t)$  oraz  $y(t-1)$ . Możemy również zaprezentować sieć RNN w postaci odwiniętej w czasie (*ang. unrolled through time*).



**Rysunek 1.8.** Rekurencyjny neuron (po lewej) odwinięty w czasie (po prawej)

Gdyby rozważyć całą warstwę neuronów tego typu, wtedy warstwa przyjmowała by dwie macierze wag  $W_x$  oraz  $W_y$ . Dane wyjściowe całej warstwy zostaną obliczone wtedy zgodnie ze wzorem


$$y(t) = AF(W_x^\top x(t) + W_y^\top y(t-1) + b)$$

Aby wytrenować sieć neuronową stosuje się propagację wsteczną w czasie (*ang. backpropagation through time; BPTT*). Polega ona na odwinięciu sieci RNN, a następnie zastosowania zwykłej metody wstecznej propagacji[3].

#### 1.5.4. LSTM

Komórki LSTM (*ang. long-short term memory*) są rozszerzeniem neuronów sieci rekurencyjnych. Pozwalają wykrywać zależności w danych w długim okresie. Posiadają dwa wektory opisujące stan neuronu. Wektor  $h(t)$  określa stan krótkookresowy i wektor  $c(t)$  określa stan długookresowy.

Główny pomysł na funkcjonowanie komórek LSTM był taki, aby sieć sama mogła się nauczyć jakie informacje są istotne i je przechować, a które informacje można pominąć, zapomnieć. Schemat komórki LSTM przedstawiono na rysunku 1.9. Aby to osiągnąć powstała idea bramek (*ang. gates*), oraz kontrolerów bramek (*ang. gate controllers*). W komórce LSTM wyróżniamy trzy bramki. Bramkę zapomnienia (*ang. forget gate*) sterowaną przez  $f(t)$ , bramkę



Rysunek 1.9. Komórka LSTM

wejściową (*ang. input gate*) sterowaną przez  $i_{(t)}$ , oraz bramkę wyjściową (*ang. output gate*), sterowaną przez  $o_{(t)}$ . Przepływ danych w komórce LSTM zaczyna w miejscu gdzie wektor wejściowy  $x_{(t)}$  i poprzedni krótkoterminowy stan  $h_{(t-1)}$  trafiają do czterech warstw. Główną warstwą jest ta zwracająca  $g_{(t)}$ . W podstawowej komórce RNN jest tylko ta warstwa. Pozostałe trzy warstwy po przejściu przez funkcje logistyczne trafiają do bramek. Bramka zapomnienia kontroluje, które informacje z długookresowego stanu  $c_{(t-1)}$  powinny zostać wykasowane. Bramka wejściowa kontroluje jakie informacje z  $g_{(t)}$  powinny zostać przekazane dalej i dodane do następnego stanu długookresowego  $c_{(t)}$ . Bramka wyjściowa odpowiada za wybranie odpowiednich elementów z stanu długookresowego i przekazanie ich następnemu kroku. Wynik komórki zostaje przekazany do wyjścia komórki  $y_{(t)}$  oraz jako następny stan krótkoterminowy  $h_{(t)}$ .

Kolejne etapy komórki LSTM obliczane są zgodnie z poniższymi wzorami:

$$\begin{aligned}
 i_{(t)} &= \sigma(W_{xi}^\top x_{(t)} + W_{hi}^\top h_{(t-1)} + b_i) \\
 f_{(t)} &= \sigma(W_{xf}^\top x_{(t)} + W_{hf}^\top h_{(t-1)} + b_f) \\
 o_{(t)} &= \sigma(W_{xo}^\top x_{(t)} + W_{ho}^\top h_{(t-1)} + b_o) \\
 g_{(t)} &= \tanh(W_{xg}^\top x_{(t)} + W_{hg}^\top h_{(t-1)} + b_g)
 \end{aligned}$$



$$c_{(t)} = f_{(t)} \otimes c_{(t-1)} + i_{(t)} \otimes g_{(t)}$$


$$y_{(t)} = h_{(t)} = o_{(t)} \otimes \tanh(c_{(t)}),$$

gdzie  $W_{xi}, W_{xf}, W_{xo}, W_{xg}$  są to macierze wag dla każdej w czterech warstwach połączonych z wektorem wejściowym  $x_{(t)}$ ,  $W_{hi}, W_{hf}, W_{ho}, W_{hg}$  są to macierze wag dla każdej w czterech warstwach połączonych z poprzednim krótkookresowym stanem  $h_{(t-1)}$ , a  $b_i, b_f, b_o, b_g$  to biasy dla każdej z tych warstw [3].

Funckja  $\tanh$  to tangens hiperboliczny, jedna z funkcji sigmoidalnych. Wykres funkcji  $\tanh$  został przedstawiony na rysunku 1.10

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

To co różni funkcję  $\tanh$  od  $\sigma$  to zakres przyjmowanych wartości. Tangens hiperboliczny przyjmuje wartości z przedziału  $(-1, 1)$ .



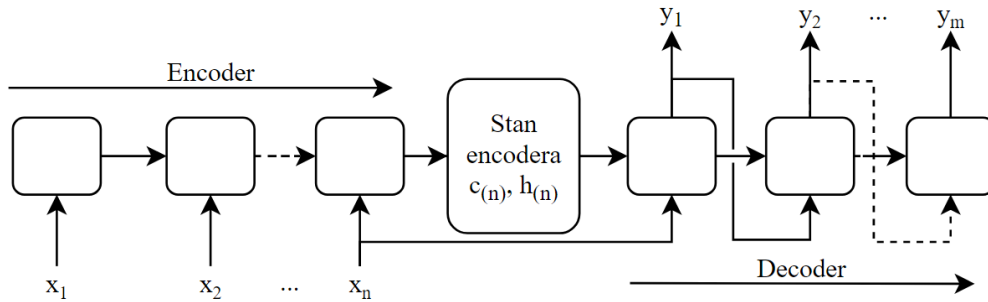
Rysunek 1.10. Tangens hiperboliczny

### 1.5.5. Sequence-to-sequence

Model w architekturze Sequence-to-sequence (*ang. seq2seq*) został wynaleziony z myślą o tłumaczeniu maszynowym języków, ale zastosowanie dla niego

znaleziono również w rozpoznawaniu mowy, opisywaniu wideo, czy tworzeniu chatbotów. Jego główną zaletą jest przetwarzanie sekwencji elementów o różnych długościach. Jest to naturalne, ponieważ tłumacząc z języka na język często tą samą sentencję można wyrazić różną liczbę słów. Dla przykładu zdanie po Polsku "Co dzisiaj robisz?" zawiera trzy słowa, natomiast przetłumaczone na Angielski "What are you doing today?" zawiera pięć słów. Nie można tego osiągnąć zwykłą siecią LSTM, dlatego model seq2seq został zaprojektowany, aby móc go zastosować do tego typu problemów [5].

Model sequence-to-sequence ma dwie części, encoder i decoder. Obie części są w zasadzie dwiema zupełnie osobnymi modelami, połączonymi ze sobą w jedną sieć. Zadaniem encodera, podobnie jak zostało to opisane w rozdziale 1.5.2 o autoencoderze, jest wydobywanie z wektora wejściowego najistotniejszych informacji i skompresowanie ich. Następnie wektor stanu encodera jest przekazywany do decodera, który na jego podstawie rekonstruuje sekwencję.



**Rysunek 1.11.** Architektura modelu sequence-to-sequence

Więcej szczegółów technicznych dotyczących modelu sequence-to-sequence przedstawię w dalszych rozdziałach pracy.

# Wprowadzenie do teorii muzyki

---

---

W tym rozdziale przedstawię podstawowe koncepcje muzyczne, sposoby reprezentacji muzyki.

## 2.1. Podstawowe koncepcje

### 2.1.1. Dźwięk muzyczny

Drgania powietrza z otoczenia człowieka są przetwarzane w mózgu i rozumiane jako dźwięki. Takie drgania nazywamy falą dźwiękową. Dźwięk muzyczny jest to fala dźwiękowa, którą wytwarza instrument muzyczny. Dźwięk muzyczny charakteryzuje się trzema podstawowymi parametrami:


- wysokością (*ang. pitch*) - jest to częstotliwość drgań wyrażona w hercach. Im większa częstotliwość tym dźwięk jest rozumiany jako wyższy, Zakres słyszalny dla człowieka wynosi od 20Hz do 20kHz.
- głośność (*ang. velocity*) - jest to amplituda drgań fali dźwiękowej. Im większa amplituda, tym dźwięk jest odczuwany jako głośniejszy,
- długość (*ang. duration*) - jest to czas z jakim dźwięk wybrzmiewa, np. 2 sekundy.

### 2.1.2. Sygnał dźwiękowy

W rzeczywistości utwór muzyczny jest zazwyczaj kombinacją wielu fal dźwiękowych, o różnych charakterystykach i nazywany jest sygnałem dźwiękowym. Wizualizację sygnału dźwiękowego przedstawiono na Rysunku 2.2

### 2.1.3. Zapis nutowy

Reprezentacja muzyki jako sygnału dźwiękowego przechowuje informacje o dokładnym brzmieniu danego utworu tzn. jakie drgania należy wytworzyć, aby móc odtwożyć muzykę. Taki zapis nie informuje nas bezpośrednio jakie instrumenty zostały użyte, jakie wysokości i długości dźwięków zostały wykorzystane. Dlatego ludzkość na przestrzeni wieków opracowała abstrakcyjne objekty, które reprezentują utwór w czytelny dla człowieka sposób.



Rysunek 2.1. Przykład przebiegu fali dźwiękowej

### Tempo


W muzyce symbolicznej tempo informuje nas o prędkości utworu. W muzyce klasycznej stosowało się opisowy sposób dostosowywania tempa np. Allegro - Szybko lub Adagio - wolno. Jak można szybko stwierdzić są to zwroty subiektywne i nie wyznaczają tempa jednoznacznie. Obecnie wyraża się tempo w liczbie uderzeń na minutę (*ang. beats per minute; BPM*). I tak Allegro jest to od 120 do 168 BPM a Adagio od 66 do 76 BPM [8].

### Nuta

Nuta jest to graficzna reprezentacja dźwięku muzycznego. Informuje nas ona o dwóch parametrach dźwięku, wysokości oraz długości dźwięku. Długość dźwięku nazywa się jej wartością. Podstawową wartością nuty jest ćwierćnuta, odpowiada ona jednemu uderzeniu (*ang. beat*). Ta wartość pozwala nam zrozumieć jak długo należy wygrywać nutę relatywnie do pozostałych nut w utworze. Jeśli obok siebie ustawimy dwie nuty o wartościach ćwierćnuty i ósemki, wiemy że tę drugą nutę powinniśmy zagrać dwa razy krócej niż pierwszą. Aby wiedzieć dokładnie jak długo powinna wybrzmiewać nuta musimy odwołać się do tempa utworu. Dla przykładu w tempie 60 BPM w ciągu minuty zagramy dokładnie 60 ćwierć nut. Kolejne wartości tworzone poprzez sumowanie lub podział dłu-

gości ćwierćnuty. Półnuta trwa tyle co dwie ćwierćnuty, cała nuta tyle co dwie półnuty, ósemka trwa połowę czasu ćwierćnuty, a szesnastka połowę ósemki itd.

## PODZIAŁ REGULARNY WARTOŚCI NUT



Rysunek 2.2. Podział wartości nut<sup>1</sup>

Tak jak pisałem wcześniej, wysokość dźwięku jest to częstotliwość drgań fali dźwiękowej wyrażona w hercach. W muzyce symbolicznej dla uproszczenia wybrane częstotliwości zostały nazwane literami alfabetu C, D, E, F, G, A, H. Każdej literze przypisana jest częstotliwość zgodnie z Tabelą 2.1

Dźwięk	Čzęstotliwość
$C_4$	261,6
$D_4$	293,7
$E_4$	329,6
$F_4$	349,2
$G_4$	391,9
$A_4$	440,0
$H_4$	493,9

Tabela 2.1: Dźwięki symboliczne oraz ich częstotliwości

<sup>1</sup> źródło: <https://www.infomusic.pl/poradnik/46934,poradnik-teoria-muzyki-rytm>  
5 kwietnia 2020 12:46

W zapisie nutowym aby nucie nadać wysokość, umieszcza się ją w odpowiednim miejscu na pięciolonii. Przedstawione powyżej dźwięki zapisałibyśmy w taki sposób jak przedstawiono na Rysunku 2.3



**Rysunek 2.3.** źródło: <https://amplitudaschool.weebly.com/lekcja-11.html> 5 kwietnia 2020 13:24

## Interwały

### Oktawy

Oktawą nazywamy zestaw ośmiu nut od C do H. Podane w Tabeli 2.1 częstotliwości nut odpowiadają dźwiękom w oktawie czwartej. Dlatego w indeksie dolnym nuty widnieje liczba 4. Aby utworzyć dźwięk, np.  $A_5$  należy pomnożyć częstotliwość dźwięku  $A_4$  razy dwa, natomiast aby utworzyć dźwięk  $A_3$ , należy tę częstotliwość podzielić przez dwa.

$$A_5 = 440Hz * 2 = 880Hz$$

$$A_3 = 440Hz/2 = 220Hz$$

W ten sposób możemy utworzyć nieskończenie wiele oktaw, jednak w rzeczywistości używa się nut od C0 do C8.

### Akord

Gdy w jednym momencie zabrzmiały dwie lub więcej różnych nut, wtedy mówimy o akordzie. Akord potrafi dodać emocje do brzmienia całego utworu.

### Skala

Do opisu, czym jest skala. -i Skala jest to zestaw nut, które dobrze ze sobą brzmią. Skalę opisujemy dwoma parametrami. Tonację, oraz modem. Tonacja jest to nuta startowa, dla skali. Mod natomiast jest to zestaw interwałów liczony od pierwszej nuty. np. C-Dur, gdzie C jest wartością początkową, a Dur opisuje interwał, Możemu utworzyć inne skale, np G-Dur, używając tych samych interwałów, ale zaczynając od innej nuty.

## 2.2. Cyfrowa reprezentacja muzyki symbolicznej

### 2.2.1. Standard MIDI

Standard MIDI (ang. Musical Instrument Digital Interface) został stworzony w 1983 aby umożliwić synchronizację i wymianę informacji między elektronicznymi urządzeniami muzycznymi takimi jak syntezatory, keyboardy czy sekwencery. W późniejszych latach został on zaadaptowany do środowiska komputerowego jako cyfrowa reprezentacja muzyki symbolicznej.

```
note_on channel=0 note=48 velocity=100 time=0
note_on channel=0 note=53 velocity=100 time=0
note_on channel=0 note=60 velocity=100 time=0
note_on channel=0 note=48 velocity=0 time=220
note_on channel=0 note=48 velocity=100 time=0
note_on channel=0 note=53 velocity=0 time=0
note_on channel=0 note=55 velocity=100 time=0
note_on channel=0 note=60 velocity=0 time=0
```

Rysunek 2.4. Fragment protokołu MIDI

### Wiadomości

Plik MIDI zawiera zestaw wiadomości przesyłanych w czasie rzeczywistym o każdej nucie w utworze. Dwie wiadomości, które są dla nas szczególnie istotne to:

- `note_on`, który sygnalizuje aby rozpocząć grać nutę,
- `note_off`, który sygnalizuje aby zakończyć grać nutę.

Dla przykładu wiadomość:

```
note_on channel 0 note 48 velocity 100 time 0
```

oznacza aby na kanele 0 zagrać dźwięk nr 48 z głośnością 100 w momencie 0 utworu. Nie informuje nas on jednak o długości trwania dźwięku. Aby zakończyć dźwięk, należy wysłać wiadomość:

```
note_off, channel 0, note 48, velocity 100, time 24.
```

Zwróćmy uwagę że aby ustalić wartość nuty, potrzebujemy odebrać dwie wiadomości. Różnica między parametrami `time`, informuje nas o długości nuty. W tym przypadku jest to 24. Co oznacza ćwierćnutę.

## Rozdzielczość

Czas w MIDI jest reprezentowany jako liczba naturalna i jest on zależny od ustalonego tempa utworu. Standardowa rozdzielczość pliku MIDI to 24. Oznacza to, że jedna jednostka czasu odpowiada jednej dwudziesteczwartej jednego udeżenia.

## Kanały

Plik MIDI posiada 16 kanałów numerowanych od 0 do 15. Każdy kanał odpowiada instrumentowi lub ścieżce. Kanał 9 jest kanałem zarezerwowanym na instrumenty perkusyjne.

## Nuty

Nuty w formacie MIDI opisane są kolejnymi cyframi naturalnymi w przedziale od 0 do 127. Odpowiada to dźwiękom od  $C_0$  do  $C_8$ . Dla przykładu nuta 69 odpowiada  $A_4$ , a nuta 47 odpowiada  $B_2$ .

Wyjątkiem są nuty z kanału dziewiątego, gdzie istnieją tylko nuty z zakresu od 35 do 81 i każda nuta odpowiada innemu elementowi perkusyjnemu np. 35 to stopa (*kick*), a 37 to werbel *snare*.

## Głośność

Za głośność dźwięku odpowiada parametr *velocity*, który jest liczbą z przedziału od 0 do 127. Im większa jest wartość tym głośniej wybrzmi dźwięk.

## Program

Program w kontekście standardu MIDI oznacza instrument który ma zagrać nuty. W standardzie GM (ang. General MIDI), jest 16 grup instrumentów a w każdej z nich znajduje się po 8 instrumentów. Są to pianina, chromatyczne perkusje, organy, gitary, basy, instrumenty smyczkowe, zestawy instrumentów, instrumenty dmuchane blaszane, instrumenty dmuchane drewniane, flety, syntezatory prowadzące, syntezatory uzupełniające, efekty syntetyczne, instrumenty etniczne, perkusjonalia i efekty dźwiękowe.

## Ścieżka

Ścieżka (ang. Track) grupuje nuty aby podzielić utwór muzyczny na różne instrumenty lub partie. Protokół MIDI pozwala aby grać wiele ścieżek dźwiękowych jednocześnie, wtedy mówimy o muzyce polifonicznej lub multiinstrumentalnej.



# Projekt

---

---

W tym rozdziale opiszę w jaki sposób zbudowałem swój własny generator muzyki, jak przechodził proces uczenia, jakie próbki udało mi się wygenerować. Opis kodu który napisałem.

### 3.1. Koncepcja

Celem tej pracy, było wykonanie modelu, który przy użyciu głębokiego uczenia będzie w stanie generować krótkie klipy multiinstrumentalne. Zainspirował mnie sposób w jaki tworzy się muzykę w zespole. W przeciwieństwie do muzyki tworzonej przez jednego kompozytora, w zespole każda partia tworzona jest przez muzyka grającego na danym instrumencie. Przykładowy sposób tworzenia utworu w zespole, np. rockowym wygląda jak następuje. Jedna osoba tworzy (generuje) pierwszą partię muzyczną, np partię na gitary. Ta partia została stworzona bez odniesienia do innych członków zespołu. Następnie taka partia zostaje przedstawiona zespołowi. Każdy z członków zespołu musi teraz stworzyć swoje partie w taki sposób, aby pasowały one muzycznie do pierwszej partii. W ten sposób powstają nam zależności między partiami, tworzącymi cały utwór.

Na podstawie tej idei postanowiłem opracować model składający się z wielu sieci neuronowych, każda z nich odpowiadać będzie jednej partii w utworze, muzykowi w zespole. Jedną z tych sieci będzie generatorem. Ta sieć powinna być skonstruowana w taki sposób aby zainicjować partię muzyczną. Pozostałe będą dopasowywać swoje partie w taki sposób aby pasowały pod partię wygenerowaną. Te sieci nawywać będą modelami akompaniującymi. Dzięki temu jesteśmy w stanie stworzyć model wielu sieci, w którym następna sieć, będzie produkować swoje partie na podstawie tego co wygenerowała poprzednia.

Kluczowe było zauważenie podobieństwa między językiem naturalnym oraz muzyką. Zarówno zdanie, jak i partia muzyczna składa się z sekwencji elementów rozmieszczonych w czasie. Elementy te są zależne od długoterminowego kontekstu, oraz od tego jaki element był ustawiony wcześniej. Dla języka naturalnego są to słowa, na muzyki są to nuty i akordy. Dodatkowo pomyślałem, że różne instrumenty można porównać do różnych języków świata. Wtedy, aby

stworzyć melodię np. basu tak aby pasowała pod partę gitary, należy "przetłumaczyć" język gitary na język basu. Do tłumaczeń języka naturalnego wykorzystuje się modele sequence-to-sequence, dlatego postanowiłem w modelu generowania muzyki wykorzystać właśnie tę architekturę. Dodatkowo modele sequence-to-sequence mają tę cechę, że liczba elementów sekwencji wejściowej, może być inna niż liczba elementów sekwencji wyjściowej. Idealnie sprawdzi się w przypadku muzyki, ponieważ o długości trwania ścieżki muzycznej nie świadczy liczba nut, tylko suma ich wartości.

## 3.2. Wstępne przygotowanie danych do treningu

Aby móc przedstawić sieci neuronowej muzykę, aby mogła być ona przez niego zrozumiana należy zamienić ją na liczby, wektory i macierze. Istnieje wiele technik umożliwiających osiągnięcie tego celu. W mojej pracy wykorzystałem technikę o nazwie one-hot encoding. Enkodowanie One-Hot jest wykorzystywane w uczeniu maszynowym aby nadać liczbową wartość danych kategorycznych. Polega ona na stworzeniu słownika, w którym każde słowo otrzyma swój unikatowy identyfikator, następnie zostanie utworzony wektor o wymiarze słów w słowniku, gdzie na pozycji odpowiadającej indeksowi słowa będzie wartość 1 a na pozostałych będzie wartość zero [2].

### 3.2.1. Przykład działania One-Hot Encoding

Weźmy sekwencję liter w słowie MATEMATYKA. Znajdźmy unikatowe elementy tej sekwencji, oraz nadajmy im unikatowy identyfikator. Kolejność nie ma znaczenia.

M - 0, A - 1, T - 2, E - 3, Y - 4, K - 5.

Kodując słowo MATEMATYKA, otrzymalibyśmy macierz

$$\begin{bmatrix} 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}$$

### 3.2.2. Muzyczne "słowo"

Na potrzeby dostosowania danych muzycznych do koncepcji słów w zdaniu, zakodowałem pojedyncze słowo muzyczne jako

((*zbirwysokoci*), *dugo*)

W ten sposób byłem w stanie zakodować podedyjczne nuty oraz akordy.

Akord C-dur składający się z dźwięków C, E i G o długości ósemki, zapisalibyśmy w następujący sposób.

((60, 64, 67), 0.5)

W ten sposób jesteśmy w stanie kodować melodię w sekwencji słów muzycznych. Tak skonstruowane dane, mają niestety swoje negatywne aspekty. Nie da się w ten sposób zapisać partii, w której zostaje grana nowa nuta gdy poprzednia jeszcze powinna brzmieć. Nasz zapis zakłada, że melodia, jest grana element po elemencie, i nowy element wymusza zakończenie poprzedniego. Nie przechowujemy również informacji o dynamice melodii (głośności). Rozszerzenie tego zapisu o informacje o głośności nie jest trudne i nie będzie wymagać przebudowania modelu, natomiast zwiększy liczbę możliwych "słów muzycznych" w słowniku i zwiększy złożoność obliczeniową. Zdecydowałem się na niewykorzystanie tych danych w generowaniu muzyki.

### 3.2.3. Konwersja MIDI na sekwencje słów muzycznych

Powręczny sposób przechowywania muzyki symbolicznej w formie cyfrowej to pliki \*.mid lub \*.midi które przechowują informację o potoku wiadomości protokołu MIDI. Aby odczytać wiadomości plików MIDI, wykorzystałem bibliotekę `pretty_midi`, która zawiera wiele funkcji pozwalających na edycję plików MIDI.

Aby otworzyć pliki midi za pomocą biblioteki `pretty_midi` należy skorzystać z poniższej składni.

```
>>> import pretty_midi as pm
>>> midi_path = 'example.mid'
>>> midi = pm.PrettyMIDI(midi_path)
>>> melody = midi.instruments[0]
>>> melody.notes

[Note(start=18.873909, end=19.186408, pitch=71, velocity=110),
 Note(start=19.132529, end=19.471968, pitch=76, velocity=114),
 Note(start=19.396538, end=19.768304, pitch=80, velocity=111),
 Note(start=19.655158, end=19.951494, pitch=81, velocity=105),
 Note(start=19.913779, end=20.226278, pitch=80, velocity=99),
 Note(start=20.172399, end=20.452571, pitch=76, velocity=119),
 Note(start=20.431020, end=20.624985, pitch=71, velocity=115),
 Note(start=20.689640, end=20.975200, pitch=69, velocity=114),
 ...]
```

Dzięki bibliotece `pretty_midi`, plik `midi` został odczytany i przechwany w obiekcie `PrettyMIDI`. Ten obiekt posiada atrybut `instruments`, który jest listą ścieżek pliku MIDI. Obiekt ścieżki posiada atrybut `notes`, który jest listą nut tej ścieżki. Możemy zobaczyć, że biblioteka `pretty_midi` zamieniła potok sygnałów protokołu MIDI na konkretne nuty posiadające parametry `start`, `end`, `pitch` oraz `velocity`. Aby otrzymać sekwencję danych w takiej formie w jakim potrzebujemy możemy zastosować na obiekcie `Instrument` poniższą funkcję.

```
def parse_pretty_midi_instrument(instrument, resolution,
    time_to_tick, key_offset):
    ''' arguments: a prettyMidi instrument object
        return: a custom SingleTrack object
    '''

    first_tick = None
    prev_tick = 0
    prev_note_lenth = 0
    max_rest_len = 4.0

    notes = defaultdict(lambda:[set(), set()])
    for note in instrument.notes:
        if first_tick == None:
            first_tick = 0

        tick = round_to_sixteenth_note(
            time_to_tick(note.start)/resolution)
        if prev_tick != None:
            act_tick = prev_tick + prev_note_lenth
            if act_tick < tick:
                rest_lenth = tick - act_tick
                while rest_lenth > max_rest_len:
                    notes[act_tick] = [{-1},{max_rest_len}]
                    act_tick += max_rest_len
                    rest_lenth -= max_rest_len
                notes[act_tick] = [{-1},{rest_lenth}]

        note_lenth = round_to_sixteenth_note(
            time_to_tick(note.end-note.start)/resolution)

        if -1 in notes[tick][0]:
            notes[tick] = [set(), set()]

        if instrument.is_drum:
            notes[tick][0].add(note.pitch)
        else:
            notes[tick][0].add(note.pitch+key_offset)

        notes[tick][1].add(note_lenth)
```

```

        prev_tick = tick
        prev_note_lenth = note_lenth

    notes = [(tuple(e[0]), max(e[1])) for e in notes.values()]

    if instrument.is_drum:
        name = 'Drums'
    else :
        pm.program_to_instrument_class(instrument.program)

    return SingleTrack(name,
                       instrument.program,
                       instrument.is_drum,
                       Stream(first_tick, notes))

```

Powyzsza funkcja w zamienia wartosci absolutne czasu, na wartosci wzgledne o ustalonej rozdzielczosci przez plik MIDI. Dodatkowo zmniejsza szczegolowosc, i zaokrągla czas zagrania nuty po szesnastki. Gdy w tym samym momencie, czyli jesli kilka nut posiada ta sama wartosc start, zostaja dodane do jednego slowa muzycznego aby utworzyc akord. Pauzy sa kodowane jako -1. Dodatkowo jesli pauza trwa dluzej niz takt wtedy zostaje podzielona na mniejsze czesci o dlugosci `max_rest_len`. Funkcja zwraca obiekt `SingleTrack`, ktory jest obiektem stworzonym aby poza nutami, przechowywac inne istotne informacje na temat sciezki, ktora beda istotne w nastepnych czesciach przetwarzania danych. Ostatecznie sekwencje slow muzycznych przechowane sa w `notes`.

```

>>> resolution = midi.resolution
>>> time_to_tick = midi.time_to_tick
>>> instrument = melody

>>> single_track = parse_pretty_midi_instrument(instrument,
resolution, time_to_tick, key_offset=0)
>>> single_track.stream.notes

[((-1,), 4.0),
 ((-1,), 0.5),
 ((71,), 0.5),
 ((76,), 0.75),
 ((80,), 0.75),
 ((81,), 0.5),
 ((80,), 0.5),
 ((76,), 0.5),
 ((71,), 0.5),
 ((69,), 0.5),
 ((68,), 0.5),
 ((69,), 0.25),

```

...]

### 3.2.4. Inne aspekty przygotowania danych

Po odczytaniu danych i konwersji je do pożądanego formatu dane należy oczyścić. W mojej pracy zastawowałem kilka operacji, w celu zwiększenia muzycznego sensu danych.

#### Unormowanie skali

W muzyce istnieje pojęcie skali. Skala jest to zestaw nut, które dobrze ze sobą współgrają. Zostało to szerzej opisane w podrozdziale 2.1.3. W uczeniu maszynowym powoduje to realny problem, ponieważ piosenki wykorzystują różne skale, a sieć neuronowa będzie preferować wybranie skali częściej używanej. Dodatkowo zmiana skali, nie zmienia drastycznie kontentu muzycznego utworu. Zmiana wysokości przyskich nut, bez zmiany ich względnych interwałów nazywana jest transpozycją. Aby rozwiązać ten problem zaleca się agmentację danych, do wszystkich możliwych skal. W mojej pracy wykorzystałem jednak inne rozwiązanie. Zamiast rozszerzać zbiór danych, sprowadziłem wszystkie ścieżki muzyczne do jednej skali C. Dzięki temu model przyłoży większą uwagę na rozumienie wzajemnych relacji, zamiast uczyć się pojęcia tonacji skali [1].

#### Podział na takty

Długie listy muzycznych słów zostały podzielone na takty (*bars*), o odpowiedniej długości, domyślnie o długości 4, co odpowiada czterem ćwierćnutom. Dzięki temu utwór muzyczny zostanie podzielony na mniejsze sekwencje. Sekwencje te będą posiadały różną liczbę elementów, ale będą tak samo długie, w kontekście muzycznym. Głównym celem takiego zabiegu, jest zapewnienie muzycznego sensu sekwencjom. Takt jest naturalnym dla muzyki podziałem dłuższej partii na mniejsze.

### 3.2.5. Podział danych na dane wejściowe i wyjściowe

Na podstawie przetworzonych danych, należy przygotować dane wejściowe  $X$  i wyjściowe  $Y$  dla sieci neuronowych, aby przeprowadzić proces uczenia. W tym celu będziemy rozważać pary sekwencji  $(x, y)$ , gdzie  $x \in X$  i  $y \in Y$ . Każda sekwencja zawierać będzie omówione wcześniej słowa muzyczne. W przygotowanym przeze mnie modelu, występują dwa rodzaje sieci neuronowych, sieć generująca oraz sieć akompaniująca.

## Przygotowanie danych dla generatora

Model generatywny będzie tworzył partie muzyczne, na podstawie poprzednich sekwencji tego samego instrumentu. Weźmy parę muzyczną  $G$ , która jest uporządkowaną listą elementów  $g$  w czasie. Każdy element  $g$  jest taktem składających się ze słów muzycznych.

$$G = [g_1, g_2, g_n],$$

gdzie  $n$  jest liczbą taktów w partii muzycznej. Pary  $(x_t, y_t)$  tworzymy według poniżej reguły

$$\begin{aligned} x_t &= g_t \\ y_t &= g_{t+1}, \end{aligned}$$

dla  $t \in (1, n - 1)$ .

Dzięki takiemu zdefiniowaniu danych uczących generator będzie uczył się jak powinien wyglądać następny takt, na podstawie poprzedniego. W ten sposób będziemy w stanie wykorzystać model, do generowania muzyki bez danych wejściowych. Wątek zostanie rozwinięty w dalszej części pracy.

Implementacja w pythonie:

```
def get_data_seq2seq_melody(self, instrument_class,
                            x_seq_len=4):
    '''return a list of bars with content for every track
    with given instrument class for melody generaiton
    x_seq_len and y_seq_len

    x previous sentence, y next sentence of the same melody line
    '''

    instrument_tracks =
        self.tracks_by_instrument[instrument_class]

    for track_index in instrument_tracks:
        bars = self.tracks[track_index].stream_to_bars()
        bars_indexes_with_content =
            get_bar_indexes_with_content(bars)
        bars_with_content =
            [bars[i] for i in get_bar_indexes_with_content(bars)]

        x_seq = []
        y_seq = []
        for i in range(len(bars_with_content)-x_seq_len-1):
            _x_seq =
                [note for bar in bars_with_content[i:i+x_seq_len]
                 for note in bar]
            _y_bar = bars_with_content[i+x_seq_len]
```

```

x_seq.append(_x_seq)
y_seq.append(_y_bar)

return x_seq, y_seq

```

## Przygotowanie danych dla akomaniamentu

Model akompaniujący natomiast, będzie na podstawie partii jednego tworzyć partię na nowy instrument, dla tego samego kroku czasu. Niech  $G, B$  będą sekcjami muzycznymi różnych instrumentów tej samej długości oraz niech

$$G = [g_1, g_2, \dots, g_k]$$

$$B = [b_1, b_2, \dots, b_k],$$

wówczas pary dla zbioru uczącego tworzymy w następujący sposób

$$x_t = g_t$$

$$y_t = b_t,$$

dla  $t \in (1, k)$ . Istotne jest aby każdy element ze zbioru taktów partii  $B$  był rzeczywistą aranżacją tego instrumentu dla taktów partii  $G$  oraz aby między elementami  $g_t$  oraz  $b_t$  była muzyczna relacja.

Implementacja przedstawionej techniki w pythonie.

```

def get_data_seq2seq_arrangment(self, x_instrument,
    y_instrument, bars_in_seq=4):
    '''this method is returning a sequances of given lenth
    by rolling this lists of x and y for arrangemt generation
    x and y has the same bar lenth, and represent the
    same musical phrase played mb difrent instruments (tracks)
    '''
    x_seq = []
    y_seq = []
    x_bars, y_bars =
self.get_common_bars_for_every_possible_pair(
    x_instrument, y_instrument)

for i in range(len(x_bars) - bars_in_seq + 1):
    x_seq_to_add =
    [note for bar in
    x_bars[i:i+bars_in_seq] for note in bar ]
    y_seq_to_add =
    [note for bar in
    y_bars[i:i+bars_in_seq] for note in bar ]
    x_seq.append(x_seq_to_add)
    y_seq.append(y_seq_to_add)

```



```
return x_seq, y_seq
```

### 3.2.6. Inne aspekty przygotowania zbioru uczącego

#### Oczyszczenie danych

W przygotowaniu danych dla modelu, ważne jest aby dostarczone dane były jak najlepszej jakości. W tym celu zastosowałem jeszcze deduplikację par  $(x, y)$  oraz usunąłem takty które nie zawierały muzycznego kontentu.

#### Wybór programu dla instrumentu

Podczas etapu ekstrakcji danych z plików MIDI poza informacjami o muzyce, zapamiętuję również informacje o programie partii muzycznej. Każda ścieżka MIDI przechowuje informacje o instrumencie (brzmieniu) danej partii. Istnieje 128 różnych programów, dla zmniejszenia szczegółowości na potrzeby modelu wyróżniam 16 instrumentów zgodnie z grupą do jakiej należą w podziale General MIDI. Dla każdej z grup, sprawdzam jaki program został najczęściej wykorzystywany i zapisuję go na przyszłość, aby móc wygenerowanej muzyce przy kompilacji do MIDI zdefiniować brzmienie instrumentu zgodnie z najczęściej wykorzystywanym w zbiorze MIDI, który został wykorzystany do stworzenia zbioru uczącego dla modelu.

#### Melodia

Dodatkowym elementem procesu ekstrakcji danych jest znalezienie ścieżek melodii przewodnich w plikach MIDI. Ścieżki tego typu zamiast być oznaczone nazwą grupy instrumentów do której należą oznaczone są nazwą Melody. Melodia jest kategorią ścieżek z podziału ze względu na rolę partii w utworze, zamiast na instrument. Istnieją też inne role instrumentów, jednak często rola jest w pewnym sensie definiowana przez instrument. Nie jest to zasada, bardziej prawidłowość w muzyce. Uznałem że wydobyć ten informacji na temat ścieżki nada więcej muzycznego sensu danym. Aby sprawdzić czy dana ścieżka jest melodią, zastosowałem poniższą funkcję:

```
def check_if_melody(self):  
    '''checks if Track object could be a melody  
  
    it checks if percentage of single notes in  
    Track.stream.notes is higher than treshold  
    of 90 and there is at least 2 notes in bar per average  
  
    '''  
    events = None  
    single_notes = None
```

```

content_lenth = None

for note in self.stream.notes:
    if self.name not in ['Bass', 'Drums']:
        events = 0
        content_lenth = 0
        single_notes = 0
        if note[0][0] != -1: # if note is not a rest
            events += 1
            content_lenth += note[1]
            if len(note[0]) == 1: # if note is a single note
                single_notes += 1

if events != None:
    if events == 0 or content_lenth == 0:
        return False
    else:
        single_notes_rate = single_notes/events
        density_rate = events/content_lenth
        if single_notes_rate >= 0.9 and density_rate < 2:
            self.name = 'Melody'
            return True
        else:
            return False
else:
    return False

```

Funkcja sprawdza liczbę pojedynczych nut i akordów w ścieżce, oraz zagęszczenie nut w takcie. Jeśli jest więcej niż 90 pojedynczych nut w ścieżce oraz jest średnio więcej nut w takcie niż dwie, wtedy uznaję że partia instrumentalna utworu jest melodią.

**3.3. Transformacja danych dla modelu**

**3.4. Definicja modelu**

**3.5. Uczenie modelu**

**3.6. Generowanie muzyki przy pomocy wytrenowanego modelu**

**3.7. Wyniki**

**3.8. Wnioski**



## Podsumowanie

---

---

Ostateczne wnioski, czy muzyka generowana komputerowa da się lubić? Czy to pozytywnie wpłynie na przemysł muzyczny? Tak i nie. Może złużyć jako inspiracja dla muzyków, proces wspierający. Z drugiej strony może obniżyć koszty produkowania muzyki pop, która i tak jest już bardzo powtarzalna. Czy sieci neuronowe nauczą się produkować Hity?



---

# Bibliografia

---

---

- [1] Briot, J.P., Hadjeres, G., Pachet, F.D. (2019): *Deep Learning Techniques for Music Generation - A Survey*. *arXiv:1709.01620v3*
- [2] DeepAI (2019): *One Hot Encoding*
- [3] Géron, A. (2019): *Hands-on machine learning with scikit-learn, keras and TensorFlow*. *O'Reilly*.
- [4] Goodfellow, I., Bengio, Y., Courville, A. (2016): *Deep Learning*. *MIT Press*.
- [5] Kostadinov, S. (2019): *Understanding Encoder-Decoder Sequence to Sequence Model*
- [6] Krysicki, W., Włodarski, L. (1999): *Analiza matematyczna w zadaniach*, PWN.
- [7] Sobczyk, M. (2006): *Statystyka*. *UMCS*.
- [8] Swinney, A. (2020): *What is a tempo marking?*
- [9] Zocca, V., Spacagna, G., Slater, D., Roelants, P. (2018): *Deep Learning. Uczenie głębokie z językiem Python*. *Helion*.