

Politechnika Warszawska

WYDZIAŁ ELEKTRONIKI
I TECHNIK INFORMACYJNYCH



Instytut Automatyki i Informatyki Stosowanej

Praca dyplomowa magisterska

na kierunku Informatyka
w specjalności Systemy Informacyjno-Decyzyjne

Grupowanie utworów muzycznych

Barbara Laskowska

Numer albumu 253102

promotor
dr inż. Mariusz Kamola

Warszawa 2019

Streszczenie

Praca opisuje podejście do porównywania utworów muzycznych pod względem zawartej w nich treści muzycznej. Metoda opiera się o sposób przetwarzania dokumentów tekstowych. Utwory grupowane są algorytmem aglomeracyjnym według występujących w nich motywów muzycznych odpowiadających słowom w tekstach, na podstawie zdefiniowanej miary podobieństwa. Praca zawiera również opis przeprowadzonych badań w celu potwierdzenia poprawności metody oraz dyskusję wyników na wybranych przykładach muzycznych.

Słowa kluczowe: *grupowanie aglomeracyjne, identyfikacja motywów muzycznych, komputerowa analiza muzyczna*

Grouping of musical compositions

The thesis describes an approach to comparing musical compositions in terms of the musical content. The method is based on the way text files are processed. The compositions are grouping with an agglomerative algorithm according to the musical patterns corresponding to the words in test files. The comparison is based on the defined degree of similarity. The work also contains a description of the tests carried out to confirm the correctness of the method and discussion of the results on selected musical examples.

Key words: *agglomerative algorithm, musical patterns identification, computer music analysis*

.....
miejsowość i data

.....
imię i nazwisko studenta

.....
numer albumu

.....
kierunek studiów

OŚWIADCZENIE

Świadomy/-a odpowiedzialności karnej za składanie fałszywych zeznań oświadczam, że niniejsza praca dyplomowa została napisana przeze mnie samodzielnie, pod opieką kierującego pracą dyplomową.

Jednocześnie oświadczam, że:

- niniejsza praca dyplomowa nie narusza praw autorskich w rozumieniu ustawy z dnia 4 lutego 1994 roku o prawie autorskim i prawach pokrewnych (Dz.U. z 2006 r. Nr 90, poz. 631 z późn. zm.) oraz dóbr osobistych chronionych prawem cywilnym,
- niniejsza praca dyplomowa nie zawiera danych i informacji, które uzyskałem/-am w sposób niedozwolony,
- niniejsza praca dyplomowa nie była wcześniej podstawą żadnej innej urzędowej procedury związanej z nadawaniem dyplomów lub tytułów zawodowych,
- wszystkie informacje umieszczone w niniejszej pracy, uzyskane ze źródeł pisanych i elektronicznych, zostały udokumentowane w wykazie literatury odpowiednimi odnośnikami,
- znam regulacje prawne Politechniki Warszawskiej w sprawie zarządzania prawami autorskimi i prawami pokrewnymi, prawami własności przemysłowej oraz zasadami komercjalizacji.

Oświadczam, że treść pracy dyplomowej w wersji drukowanej, treść pracy dyplomowej zawartej na nośniku elektronicznym (płycie kompaktowej) oraz treść pracy dyplomowej w module APD systemu USOS są identyczne.

.....
czytelny podpis studenta

Spis treści

1	Wprowadzenie	9
1.1	Cel pracy	9
1.2	Układ pracy	10
2	Wstęp teoretyczny	11
2.1	Analiza dokumentów tekstowych	11
2.1.1	Algorytm TF-IDF	11
2.1.2	Odległość kosinusowa	12
2.2	Analiza muzyczna	13
2.2.1	Elementy dzieła muzycznego	13
2.2.2	Analiza formalna	14
2.2.3	Analiza harmoniczna, melodyczna i rytmiczna	15
3	Przegląd literatury	17
3.1	Komputerowa analiza muzyczna	17
3.1.1	Zapis i odczyt nut	18
3.1.2	Analiza muzyczna	18
3.2	Identyfikacja motywów	19
3.3	Grupowanie utworów muzycznych	21
4	Koncepcja rozwiązania	23
4.1	Porównanie analizy dokumentów tekstowych i analizy muzycznej	23
4.2	Problemy w identyfikacji motywów	24
4.3	System punktacji i próg odcięcia	25
4.4	Reprezentacja motywu i utworu	30
4.5	Podobieństwo motywów i utworów	33
4.6	Grupowanie utworów	34
5	Wyniki	36
5.1	Zbiór danych	36
5.2	Dobór parametrów metody	36
5.2.1	Wartość progowa β kwalifikacji motywów	36
5.2.2	Metoda grupowania	38
5.2.3	Miara odległości	39
5.3	Grupowanie wg kompozytorów	40
5.4	Wnioski z wykrytych anomalii	43
5.4.1	Bach i włoscy kompozytorzy XIV w.	43

5.4.2	Grupy 6 i 7 w grupowaniu metodą <i>complete</i>	44
5.4.3	Metoda <i>single</i>	45
6	Podsumowanie	46
7	Bibliografia.....	48
	Spis rysunków	49
	Spis tabel	51
	Dodatek.....	52

1 Wprowadzenie

Już w starożytności Arystoteles podzielił świat na 10 kategorii. Metody grupowania i klasyfikowania elementów świata stały się tematem rozważań wielu filozofów i naukowców również w późniejszym czasie. Obecnie jest to znacząca część prawdopodobnie każdej dziedziny życia. Powodem, dla którego podział różnych elementów ma tak duże znaczenie, jest sposób postrzegania świata przez człowieka.

Dziecko w wieku około 8 miesięcy zaczyna zauważać podobieństwa między różnymi przedmiotami i w ten sposób łączy je w pewne kategorie: świecące przedmioty, grające, pachnące czy jadalne. Podział elementów na grupy jest więc dla nas naturalny. Pomaga lepiej zrozumieć świat i dobrze w nim funkcjonować.

W nauce podział na grupy pozwala na przeprowadzenie szerokich badań, opis wspólnych cech elementów oraz poznawanie nowych. Komputerowe metody grupowania umożliwiły szybsze wykonywanie podziału, towarzyszą procesom badawczym wielu dziedzin naukowych. Grupowanie utworów muzycznych ma za zadanie wspierać badania muzykologiczne.

Utwory muzyczne w postaci zapisu nutowego przypominają pewne dokumenty tekstowe tylko napisane przy użyciu języka muzycznego. Grupowanie dokumentów tekstowych jest często wykorzystywanym algorytmem eksploracji tekstu. Wykorzystuje się je przy klasyfikacji dokumentów, wyszukiwaniu tekstów o podobnej tematyce, zawierające pewne słowa kluczowe itp. Pliki z utworami muzycznymi mogą również podlegać przetwarzaniu dokumentów tekstowych, ale jedynie poprzez zawarte w nich słowa i słowny opis utworu. Większe możliwości analizy utworów muzycznych można osiągnąć poprzez analizę jego treści muzycznych czyli zawartych w nich nut, motywów, fraz muzycznych, współbrzmień, dynamiki czy agogiki.

Porównanie języka muzycznego z językiem naturalnym umożliwi zastosowanie podobnych algorytmów grupowania jak do dokumentów tekstowych. Konieczne jest znalezienie analogii dla poszczególnych elementów tych języków oraz zdefiniowanie sposobu wyznaczania podobieństwa dwóch utworów.

1.1 Cel pracy

Muzyka i rozwój technologiczny coraz częściej idą w parze. Jednak nadal spora część muzyków nie widzi potencjału w narzędziach komputerowych poza wspomaganie zapisu nut. Komputer nigdy nie zastąpi w pełni muzyki na żywo i rzeczywistego kontaktu z muzykami, którzy poprzez wykonywanie lub komponowanie utworów próbują przekazać swoje emocje. Jest to jednym w powodów, dla których muzycy i muzykolodzy rzadko próbują włączyć do swojej pracy metody komputerowe.

Pomimo jednak artystycznej strony muzyki, jest ona dość silnie sformalizowana. System tonacji dur-moll oparty o koło kwintowe, budowa trójdźwięków i czterodźwięków, triada harmoniczna, modulacje to tylko niektóre elementy, które w swojej naturze posiadają bardzo dużo matematyki. Z tego względu uważam, że muzyka, a szczególnie prace muzykologiczne powinny korzystać z możliwości jakie daje współczesna informatyka.

Oprócz studiów technicznych ukończyłam I i II stopień szkoły muzycznej. Podczas swojej edukacji zauważyłam, że muzyka i przedmioty ściśle mają ze sobą dużo wspólnego. Doświadczenie muzyczne połączone z wykształceniem w dziedzinie informatyki pomogło mi

w realizacji tego tematu pracy magisterskiej. Całą koncepcję rozwiązania i większość decyzji projektowych opierałam na swojej wiedzy muzycznej.

Celem mojej pracy magisterskiej było opracowanie metody przetwarzania utworów muzycznych, w sposób zbliżony do podejścia muzykologicznego. Wybór metody grupowania i przeprowadzenie testów, które zweryfikują otrzymane wyniki. Odpowiednio dostrojony mechanizm może nie tylko wspierać pracę muzykologów, ale znaleźć zastosowanie również w systemach rekomendacji muzyki lub systemach antyplagiatowych.

1.2 Układ pracy

Pracę podzieliłam na 6 rozdziałów. Po krótkim wprowadzeniu w rozdziale 1 omówiłam podstawowe informacje na temat analizy muzyki i analizy dokumentów tekstowych (rozdział 2). W rozdziale 3 opisałam najważniejsze artykuły, które pomogły mi w opracowaniu metody. Cała koncepcja rozwiązania opisana jest w rozdziale 4. W dalszej części (rozdział 5) przedstawiłam testy i wyniki jakie udało mi się osiągnąć. Rozdział 6 to podsumowanie całości pracy i zebrane pomysły na dalszą pracę nad tematem komputerowej analizy muzycznej. Na końcu znajduje się bibliografia oraz spis rysunków i tabel. W dodatku umieściłam pełne wyniki kilku najważniejszych z przeprowadzonych testów.

2 Wstęp teoretyczny

Porównanie ze sobą dwóch światów: muzycznego i lingwistycznego wymaga znajomości metod używanych niezależnie w każdym z nich. W tym rozdziale omówię dwa sposoby przetwarzania dokumentów tekstowych oraz podstawy z dziedziny muzyki dotyczące analizy utworów muzycznych.

2.1 Analiza dokumentów tekstowych

Dokumenty tekstowe są jedną z najpopularniejszych form reprezentacji danych, jednocześnie najbardziej naturalną dla człowieka posługującego się na co dzień mową i pismem. Do ich analizy służą metody eksploracji tekstu. Najczęściej wykorzystywanymi zastosowaniami eksploracji tekstu są wyszukiwanie dokumentów zawierających słowa kluczowe, wyszukiwanie dokumentów podobnych do zadanego, grupowanie i klasyfikacja dokumentów tekstowych czy też analiza sieci cytowań.

Problemem jest taka reprezentacja, która będzie zawierała maksymalnie dużo znaczących informacji o dokumencie oraz zapewni efektywne wyszukiwanie poprzez obliczanie podobieństwa między dokumentami. Omówię dwa najpopularniejsze sposoby wyszukiwania informacji w tekście: algorytm TF-IDF oraz odległość kosinusową.

2.1.1 Algorytm TF-IDF

Jedną z podstawowych technik wyszukiwania dokumentów ze zbioru wg zadanego zapytania jest algorytm TF-IDF. Skrót pochodzi od angielskiego sformułowania *term frequency - inverse document frequency* (Russel). Algorytm polega na obliczeniu znormalizowanej wartości reprezentującej wagę występowania pewnego słowa w zależności od częstotliwości jego występowania w dokumencie w stosunku do występowania w całym zbiorze dokumentów.

Współczynnik TF-IDF wyraża się wzorem:

$$tf_{idf} = tf * idf \quad (1)$$

tf – waga słowa w konkretnym dokumencie

idf - waga słowa w zależności od całego zbioru dokumentów

Czynnik *tf* może być prosto reprezentowany poprzez liczbę wystąpień słowa. Zazwyczaj jednak wyraża się go jako częstotliwość występowania danego słowa w tekście czyli iloraz liczby wystąpień przez sumę wszystkich słów w dokumencie. Wg takiego podejścia przewagę w wyszukiwaniu dokumentów mogą mieć krótsze teksty.

W przypadku zapytań zawierających kilka słów algorytm wylicza wartość współczynnika oddzielnie dla każdego słowa i sumuje wartości. Nie uwzględnia ich kolejności ani współwystępowania. Algorytm traktuje dokumenty jako nieuporządkowany zbiór słów. W niektórych przypadkach może również prowadzić do błędnych wyszukiwań. Narzędzia oparte o przetwarzanie języka naturalnego wprowadzają listy wyrazów nieznaczących, które należy ignorować w tego typu problemach. W języku polskim są to słowa takie jak spójniki lub zaimki.

Czynnik *idf* pozwala zmniejszyć znaczenie słów używanych powszechnie. Jest to ogólna miara dla całego zbioru dokumentów. Zliczane są wystąpienia słów biorąc pod uwagę

wszystkie dokumenty w których wyszukiwane słowa się pojawiły. Wyższa wartość przypisywana jest słowom dość rzadko spotykanym wśród dokumentów w całym zbiorze w porównaniu do słów używanych w większości tekstów. Takie rozwiązanie pozwala poradzić sobie z problemem mało znaczących słów.


2.1.2 Odległość kosinusowa

Kolejnym częstym przypadkiem użycia algorytmów eksploracji tekstu jest znajdowanie dokumentów poprzez ich podobieństwo do zadanego tekstu źródłowego. Podstawową techniką porównywania ze sobą dwóch dokumentów jest odległość kosinusowa. W tej metodzie dokumenty przedstawiane są przy pomocy wielowymiarowych wektorów. Podobieństwo dokumentów wyznacza odległość pomiędzy dwoma wektorami w danej przestrzeni wektorowej. W ten sposób można również wyszukać dokumenty dla zadanego zapytania, przedstawiając je również w formie takiego wektora.

Wymiary przestrzeni reprezentują słowa. Wartości wektorów mogą być liczbą wystąpień danego słowa w dokumencie jak również mogą przyjmować wyniki algorytmu TF-IDF. Chociaż trudno sobie to wyobrazić, przestrzenie wektorowe dla zadanego problemu mogą posiadać tysiące wymiarów. Liczba wymiarów zależy od wielkości rozpatrywanego słownika słów znaczących.

Rozpatrując problem w trójwymiarowej przestrzeni możemy wyobrazić sobie wektory reprezentujące dokumenty na podstawie zawartości w nim trzech słów. Podobieństwo wyznaczone jest jako kosinus kąta pomiędzy tymi wektorami. Jeśli więc porównujemy ze sobą ten sam dokument to kąt pomiędzy wektorami jest równy 0, a kosinus 1 oznacza maksymalne podobieństwo. Jeśli dokumenty są zupełnie różne, czyli zawierają inne słowa kluczowe (np. $\vec{v} = (1,0,1)$, $\vec{u} = (0,1,0)$) to kąt pomiędzy wektorami wynosi 90, a kosinus 0.

$$\text{Similarity}(\vec{v}, \vec{u}) = \cos \theta \quad (2)$$



Rys. 1 Wektory \vec{v} i \vec{u} w przestrzeni trzech słów (T1,T2,T3)

2.2 Analiza muzyczna

Analiza muzyczna ma za zadanie zrozumienie treści muzycznych przekazywanych przez kompozytora i dobre odczytanie jego intencji. Umożliwia to później zarówno odpowiednią interpretację utworu podczas jego wykonywania jak również świadome słuchanie muzyki. Analiza opiera się o wszystkie elementy dzieła muzycznego i dzieli się na analizę formalną, harmoniczną, melodyczną i rytmiczną. W tym rozdziale opiszemy elementy dzieła muzycznego oraz podstawy poszczególnych rodzajów analiz.



2.2.1 Elementy dzieła muzycznego

Elementy dzieła muzycznego porządkują materiał dźwiękowy. W wyniku ich współdziałania utwór muzyczny otrzymuje określony charakter i kształt. Trzy podstawowe elementy to: rytmika, melodyka i harmonika, cztery dodatkowe, które w dużym stopniu zależą od wykonawcy to: dynamika, agogika, kolorystyka i artykulacja (Wójcik, 2001).

Rytmika – porządkuje materiał dźwiękowy w czasie. Oznaczenia nut decydują o czasie ich trwania. Są to np. półnuty, ćwierćnuty, ósemki itp. Analogicznie do nut występują również pauzy czyli przerwy w muzyce o odpowiednim czasie trwania. Z tym elementem wiąże się pojęcie metrum, które wyznacza miary czasu i ustala regularne akcenty poprzez podział na takty.

Melodyka – określa następstwo dźwięków o różnej wysokości i różnym czasie trwania. Jest nieodłącznie związana z rytmiką. Główny podział melodyki dotyczy aparatu wykonawczego: melodyka wokalna i instrumentalna. Melodyka diatoniczna wykorzystuje dźwięki skali, natomiast melodyka chromatyczna wykorzystuje znaki chromatyczne, przy pomocy których powstają dźwięki obce dla danej skali.

Harmonika – element dotyczący współbrzmienia dźwięków. Historyczny rozwój muzyki dał nam trzy rodzaje harmoniki: modalną, funkcyjną i sonorystyczną. Harmonika modalna popularna do XVI w. opiera się na 8 kościelnych skalach modalnych. Od wieku XVII zaczęto stosować system dur-moll co dało początek harmonice funkcyjnej opartej na dwóch skalach: durowej i molowej. Na wszystkich stopniach tych gam budowane są akordy, które pełnią różne funkcje – trzy podstawowe to tonika, subdominanta i dominanta. Relacje między akordami pozwalają na budowanie i rozładowywanie napięć muzycznych. Harmonika sonorystyczna powstała w XX w. i charakteryzuje się równymi prawami dla wszystkich współbrzmień, które traktowane są jak plamy dźwiękowe.

Dynamika – element regulujący natężenie dźwięku. Do oznaczeń dynamicznych stosowane są słowa w języku włoskim, np. *piano* – cicho, *forte* – głośno. Stopniowe zmiany dynamiczne można określać słownie lub graficznie: *crescendo* (cresc. ) – pogłaśniając, *decrescendo/diminuendo* (decresc./dim. ) – ścisząc.

Agogika – określający tempo w jakim wykonywany ma być utwór. Stosuje się trzy rodzaje oznaczeń: włoskie słowa (*andante*, *moderato*, *allegro*), liczbowe oznaczenia dotyczące wskazań metronomu (♩ = 120), określenie minutowe dla długości całego utworu (ca = 10).

Kolorystyka – związana jest z barwą dźwięku, a więc zależy od instrumentu który wykonuje utwór. Ten sam utwór może mieć różne brzmienie gdy zostanie wykonany wokalnie, na fortepianie lub przez orkiestrę symfoniczną.

Artykulacja – element określający sposób wydobywania dźwięków oznaczany graficznie lub przy użyciu nazw włoskich. Trzy podstawowe sposoby to *legato* – łącząc dźwięki, *staccato* – odrywając i *portato* – przenosząc. Istnieją również określenia charakterystyczne dla

poszczególnych instrumentów lub grup instrumentów (*arco*, *pizzicato* – smyczkowe, *con sordino* – dęte blaszane, *glissando* – skrzypce, fortepian, puzon)

2.2.2 Analiza formalna

Analiza formalna dzieła muzycznego polega na analizie utworu pod kątem jego budowy.

Definicja formy muzycznej wg J. M. Chomińskiego:

Forma muzyczna jest wypadkową współdziałania elementów muzycznych, jako środek służący do realizacji pozamuzycznej treści dzieła, to twór realizowany za pomocą zasobu środków techniki kompozytorskiej, nierozzerwalnie związany z danym środkiem wykonawczym i typową dla niego fakturą.

W wyniku analizy możemy ocenić w jaki sposób kompozytor przekazał treści pozamuzyczne oraz je zinterpretować. Takie treści w utworach wokalnych zrozumiale realizowane są przy pomocy tekstu, natomiast w utworach instrumentalnych interpretacja jest dużo bardziej subiektywna i opiera się o emocjonalny ładunek utworu. Poprzez ocenę budowy formalnej utworu można dokładniej przeanalizować środki wykonawcze wykorzystane w akcie twórczym kompozytora.

Podstawowymi współczynnikami tworzącymi formę muzyczną są: motywy, frazy i zdania. Motywy zbudowane są z kilku lub nawet kilkunastu nut, frazy to kilka motywów, a zdania zbudowane są z dwóch lub większej liczby fraz. Są to określenia niekonkretne, ponieważ w różnych utworach możemy zauważyć bardzo różne sposoby komponowania tworzące całą formę utworu.

Motywy muzyczne można podzielić wg kilku kryteriów. Ze względu na rozmieszczenie akcentu motywy mogą być rozpoczynane zarówno od części akcentowanej jak i nieakcentowanej. Ze względu na kierunek linii melodycznej mamy motywy wznoszące, opadające, faliste, łukowe i oparte na powtarzaniu dźwięku. Ze względu na harmonikę możemy wyróżnić motywy oparte na jednym lub na kilku akordach.

Frazy rozróżniamy na jednorodne, czyli oparte o ten sam materiał motywiczny, powtarzany w sposób dokładny, sekwencyjny lub ze zmianą kierunku melodii, i różnorodne, które zawierają różne motywy. Zdania muzyczne dzielimy analogicznie w zależności od charakterystyki fraz muzycznych, z których jest zbudowane.

Motywy, frazy i zdania często zawarte są w ramach taktów. Nie jest to jednak regułą. Występują przedtakty, w których materiał muzyczny rozpoczyna się jedną lub kilka miar rytmicznych przed rozpoczęciem kolejnego taktu. Rozmiary fraz i zdań często zależą od czasu. Tak więc zdania zazwyczaj będą posiadały więcej taktów jeśli tempo utworu jest szybsze. Na rysunkach 2-6 pokazane są przykładowe motywy, frazy i zdanie muzyczne.



Rys. 2 F. Chopin Sonata h-moll op.58 cz I – przykład motywów opadających



Rys. 3 P. Czajkowski VI Symfonia op. 74 – motywy z następstwem akcentów: część nieakcentowana – akcentowana – nieakcentowana (> nad nutą oznacza akcent)



Rys. 4 M. Karłowicz Odwieczne Pieśni I – motywy z następstwem akcentów: część akcentowana - nieakcentowana



Rys. 5 R. Schumann Album dla młodzieży, Biedna sierotka – fraza jednorodna ze zmianą kierunku linii melodycznej



Rys. 6 F. Chopin, Mazurek fis-moll op. 6 nr 1 – Zdanie muzyczne jednorodne, powtórzenie sekwencyjne

Opisane powyżej elementarne czynniki formy muzycznej są stosunkowo łatwe do zauważenia przez człowieka jednak mają bardzo niekonkretne reguły. Wynika to z charakteru utworów muzycznych, które są dziełem artystycznym, a sztuka nie jest dziedziną ścisłą. Jest tworzona przez różnych ludzi mających indywidualne spojrzenie na świat i odczuwających unikalne połączenia wielu emocji.

2.2.3 Analiza harmoniczna, melodyczna i rytmiczna

Analizę formalną utworu uzupełniają inne bardziej szczegółowe rodzaje analiz: harmoniczna, melodyczna i rytmiczna. Polegają one na odczytaniu w utworze treści

dotyczących trzech podstawowych elementów dzieła muzycznego (harmonii, melodii i rytmu) i ich zinterpretowaniu.

Na podstawie analizy harmonicznej możemy zauważyć gdzie pojawiają się napięcia muzyczne (funkcje dominanty, dysonanse) czy i gdzie są rozładowywane poprzez harmoniczne rozwiązania. Nowa myśl muzyczna może być wprowadzona na przykład poprzez modulację do innej tonacji. To również można zauważyć analizując na jakich akordach oparta jest treść muzyczna utworu.

Analiza melodyczna i rytmiczna najczęściej występują razem, ponieważ trudno rozpatrywać melodię bez jej rytmu (wyjątkiem są średniowieczne utwory, których notacja nie uwzględniała rytmu). Samodzielna analiza rytmiczna jest częściej spotykana, szczególnie w przypadku partii instrumentów niemelodycznych. Uwzględniane są przebiegi melodyczne i rytmiczne, stosowane grupy rytmiczne, repetycje melodyczne i rytmiczne, progresje czyli powtórzenie materiału od innego dźwięku i inne techniki kompozytorskie. Długie wartości rytmiczne charakteryzują melodię kantylenową, natomiast dużo krótkich melodię figuracyjną.

3 Przegląd literatury

Istnieje dużo narzędzi wspomagających pracę muzyka jednak niewiele jest przydatnych w analizie muzycznej. W tym rozdziale opisałam literaturę, która pomogła mi w opracowaniu metody grupowania utworów muzycznych. Były to materiały dotyczące trzech podstawowych zagadnień: komputerowym możliwościom wsparcia analizy muzycznej, identyfikacji motywów muzycznych w utworach oraz wypróbowanym już sposobom grupowania muzyki.

3.1 Komputerowa analiza muzyczna

Materiały na temat komputerowej analizy muzycznej możemy podzielić na dwa główne nurty. Jeden opiera się na analizie tekstu muzycznego, natomiast drugi to analiza akustyczna dźwięków. Andrew R. Brown w swoim artykule (Brown, 1999) przedstawia różne sposoby analizy muzycznej i możliwości jej komputerowej realizacji rozpoczynając od kodowania muzyki w formacie MIDI poprzez analizę audio aż po gramatyczny rozkład muzyki.

Brown opisuje dwa programy służące do analizy zakodowanych danych muzycznych: Humdrum i SARA. Humdrum został stworzony przez Davida Hurona w latach 80-tych. Jest to zestaw narzędzi linii poleceń niezależny od języka programowania, dzięki czemu był często wykorzystywany w większych skryptach innych języków takich jak Python czy C++. SARA bazuje na dopasowaniu zadanych wzorców do zakodowanych danych muzycznych.

Inny sposób zapisu muzyki opiera się o symboliczną reprezentację. Dźwięki, ich wysokość, barwa, natężenie wizualizują próbki na wykresie. Obraz rośnie i spada odwzorowując zmiany dźwięków w czasie. Symbole graficzne mogą reprezentować elementy niemożliwe do zapisania w konwencjonalnej formie. Jest to sposób zapisu muzyki konkretnej (kierunek muzyki współczesnej) lub elektronicznej. Tak zapisana muzyka, może być analizowana z użyciem algorytmów porównujących grafikę.

Analiza zapisu audio jest popularna w przypadku muzyki elektroakustycznej lub etnomuzykologii, ze względu na brak zapisu nutowego. Przebiegi zawierają informacje o amplitudzie, barwie i mogą służyć do odczytania informacji o czasie trwania dźwięku. Szczegółowe analizy są możliwe przy użyciu na przykład transformaty Fouriera, która pokazuje wszystkie składowe harmoniczne dźwięku. Wiele narzędzi muzycznych obsługuje analizę Fouriera, a wyniki wyświetlane są jako wykresy 2D lub 3D.

Na końcu artykułu Brown zauważa, że ciekawsze od analizy samych dźwięków jest przyjrzenie się strukturze w jakiej występują. Jest to możliwe poprzez posługiwanie się gramatyką muzyczną. Wskazuje dwie gramatyki: Schenkerowską i GTTM – generacyjna teoria muzyki tonalnej. David Cope stworzył program EMI (*Experiments in Musical Intelligence*) służący do analizy i rekonstrukcji utworów pod kątem stylów różnych kompozytorów.

W analizie muzycznej stosowane są również słowne opisy. Zawierają one zwykle określenia metaforyczne, reprezentujące raczej ładunek emocjonalny muzyki, rzadziej jej elementy funkcyjne.

Brown twierdzi, że komputer może wspomagać muzyczną analizę na wielu poziomach, a narzędzia analityczne pomagają w rozumieniu trudnego do uchwycenia znaczenia muzyki.

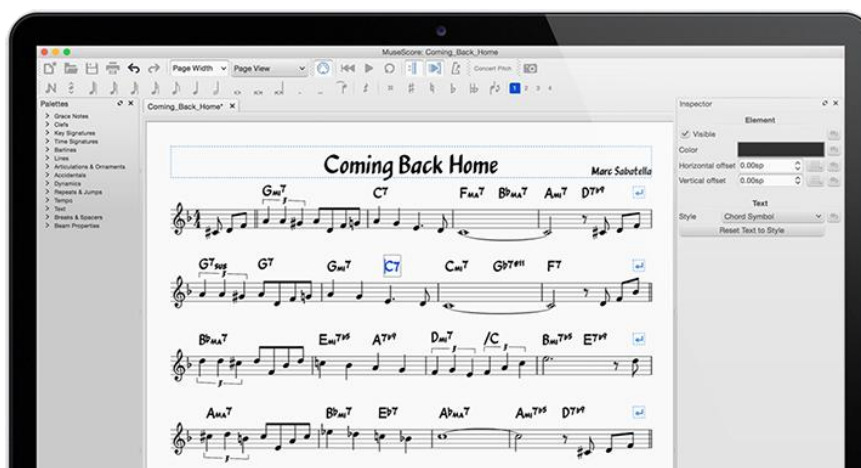
3.1.1 Zapis i odczyt nut

Najczęstszą wspieraną komputerowo potrzebą muzyków jest zapis nut, możliwość ich odtworzenia oraz wydrukowania. Narzędzia wspomagają kompozytorów i aranżerów poprzez uproszczone naśladowanie skomponowanych przez nich utworów, na przykład w formacie MIDI.

Format MIDI umożliwia usłyszenie komputerowo wygenerowanych dźwięków. Szerokie możliwości formatu MIDI pozwalają na rozróżnianie brzmienia różnych instrumentów oraz łączenie równolegle kilku partii. Dzięki temu można odtwarzać utwory nawet orkiestry symfonicznej bez ani jednego muzyka. Niestety format MIDI ma również sporo wad. Podstawowym problemem są małe możliwości realizacji dynamiki i artykulacji. Taka muzyka pozbawiona jest wyrazu emocjonalnego i służy głównie do sprawdzenia poprawności zapisanej muzyki, a nie do artystycznego odbioru treści muzycznych.

MusicXML to format notacji graficznej nut, który uwzględnia większość zapisów muzycznych. Opiera się na wzorcach dokumentowych DTD, dzięki czemu sprawnie można w nim wyszukiwać informacje, jest łatwy do zrozumienia oraz skonstruowania. MusicXML bazuje na dwóch akademickich formatach danych MuseData i HumDrum.

Przykładem narzędzia pozwalającego na zapis nut, wizualizację i odtwarzanie jest MuseScore. Obsługuje formaty MIDI i MusicXML. Jest to darmowa alternatywa na licencji GNU GPL dla drogich, profesjonalnych programów do edycji nut takich jak Sibelius czy Finale.



Rys. 7 Program MuseScore 3.0.1 (**MUSESCORE**)

3.1.2 Analiza muzyczna

Artykuł Iwony Lindstedt (Lindstedt, 2011) podsumowuje możliwości komputerowego wsparcia analizy muzycznej. Wymienia programy do analizy formalnej utworu takie jak Variations Audio Timeline lub AnaVis, które pozwalają na rozpisanie budowy utworu w sposób graficzny. Do obsługi plików audio ASAnnotation, Acousmographie i Sonic Visualiser. Te narzędzia pozwalają na pracę nad widmem sygnału. Dają możliwość nanoszenia informacji na spektrogram, który generują lub też wykorzystują narzędzia wyspecjalizowane do cyfrowego przetwarzania sygnałów. Analizy danych audio można dokonać również przy pomocy zbioru funkcji programu MATLAB – MIRTtoolbox.

Autorka artykułu zwraca szczególną uwagę na system analityczny Humdrum Toolkit, który umożliwia analizę materiału muzycznego poprzez porównywanie różnych form reprezentacji

danych muzycznych. Współczesną alternatywą dla pochodzącego z lat dziewięćdziesiątych Humdruma jest pakiet Music21 służący do komputerowo wspieranej analizy muzycznej. Pakiet oparty na języku programowania Python umożliwia szereg operacji takich jak wczytanie pliku audio lub zapisu nutowego, wizualizacja nut, stworzenie prostej melodii. Pakiet posiada również obiekty takie jak Pitches, Intervals, Chords, TimeSignatures, które pozwalają na bardziej szczegółową analizę. Pakiet posiada również komponenty graficzne dzięki którym można dostrzec korelacje pomiędzy różnymi parametrami muzycznymi. Pakiet Music21 jest przeznaczony do pracy nad zapisem nutowym, dlatego postanowiłam wykorzystać go w swojej pracy.

3.2 Identyfikacja motywów

Motyw to najmniejsza struktura formotwórcza utworu złożona z kilku lub kilkunastu dźwięków. Stanowi część frazy muzycznej, do której melodia wielokrotnie powraca w toku utworu. Określenia te nie są bardzo formalne, dlatego trudno jest określić najlepszy sposób wyznaczania motywów przy użyciu narzędzi komputerowych.

Identyfikacja motywów może być zrealizowana poprzez analizę plików audio i widma dźwięku. Wykorzystywane są do tego transformaty Fouriera (Gerhard, 2002) lub falkowe (Velarde, Meredith, & Weyde, 2016). Takie podejście może być ciekawe z tego względu, że analizowany jest faktyczny dźwięk, który słyszymy. Muzykologiczne badania opierają się jednak o zapis nutowy dlatego w swojej pracy skupię się na analizie zapisu nutowego w formacie MusicXML. Odtwarzanie utworu jest również pomocne dla człowieka podczas analizy, więc może kolejnym krokiem byłoby połączenie tych dwóch podejść.

Olivier Lartillot zaproponował wielowymiarowe podejście do rozpoznawania motywów (Lartillot, 2005), które moim zdaniem bardzo dobrze odpowiada intuicyjnemu podejściu człowieka do wyznaczania motywów w utworze. Na podstawie zapisu nutowego określa różne parametry muzyczne dotyczące dźwięków takie jak wysokość, nazwa dźwięku, stopień gamy, długość trwania dźwięku i miara taktu, na którą przypada nuta, oraz parametry dotyczące zmian między kolejnymi nutami: interwał diatoniczny, interwał chromatyczny i kontur, który zawiera informacje o tym czy melodia idzie w górę czy opada. Rys. 8. przedstawia przykładowe fragmenty muzyczne reprezentujące pewien motyw wraz z odpowiadającymi wartościami parametrów. Sekwencje zaznaczone prostokątami wskazują powtarzające się ciągi wartości, dzięki którym możemy zidentyfikować motyw.

theoretical pitch	C# DC# E E B C# B D D
absolute scale degree	2 3 2 4 4 1 2 1 3 3
local scale degree	0 1 0 2 2 0 1 0 2 2
diatonic interval (diat)	+1 -1 +2 0 -3 +1 -1 +2 0
MIDI pitch	61 62 61 64 64 59 61 59 62 62
chromatic interval (chro)	+1 -1 +3 0 -5 +2 -2 +3 0
contour (cont)	+ - + 0 - + - + 0
6/8 pulsation	1 2.5 3 4 6 1 2.5 3 4 6
3/8 pulsation	1 2.5 3 1 3 1 2.5 3 1 3
rhythm per 16th note	3 1 2 4 2 3 1 2 4 2
rhythm per 8th note (rhyt)	3/2 1/2 1 2 1 3/2 1/2 1 2 1
rhythm per dotted quarter note	1/2 1/6 1/3 2/3 1/3 1/2 1/6 1/3 2/3 1/3

Rys. 8 Parametry dźwięków wg O. Lartillota (Lartillot, 2005)

O. Lartillot wybrał cztery parametry, które uznał za kluczowe do rozpoznania motywów i tylko te wzięt pod uwagę w tej pracy. Te właściwości to: interwał diatoniczny, interwał chromatyczny, kontur i rytm. Parametry te są oznaczone na Rys. 8 grubszą czcionką.


Ponieważ powtórzenia motywów bardzo rzadko są identyczne Lartillot proponuje połączenie dwóch metod rozpoznawania różnych realizacji motywów. Pierwszy sposób identyfikuje motyw jeśli niespójność nie przekroczyła zadanego liczbowego marginesu błędu. Ten margines musi być wyznaczany arbitralnie przez użytkownika w zależności od potrzeb. Druga metoda zakłada, że motywy mogą być rozpoznawane poprzez dokładne odwzorowanie według wielu różnych kryteriów. Dwa podejścia zobrazowane są na Rys. 9. Widzimy tu kilka realizacji motywów, które różnią się wysokością ostatniej nuty. Nad pięcioliniami wskazane jest jaki margines błędu dla interwałów uwzględni kolejne wystąpienia motywu. Poniżej nut widzimy, które parametry są identyczne dla różnych sekwencji nut.

	$chro = (0, 0, -2 \pm 3)$
	$chro = (0, 0, -2 \pm 2)$
	$chro = (0, 0, -2 \pm 1)$
	$chro = (0, 0, -2)$
	$chro = (0, 0, -2)$
	$diat = (0, 0, -1)$
	$cont = (0, 0, -)$
	$rhyt = (0.5, 0.5, 1)$

Rys. 9 Dwa sposoby klasyfikacji motywów. (Lartillot, 2005)

Sposób rozpoznawania motywów w melodiach ludowych zaproponował Zoltán Juhász (Juhász, 2009). Metoda polega na porównywaniu „monotoniczności” melodii niezależnie od rytmu. Nuty zostają przetłumaczone na wektory wartości określających wysokość, a następnie linie melodyczne są ze sobą porównywane w macierzy. Macierz ta zawiera

odchylenia pomiędzy nutami dwóch linii melodycznych jak na Rys. 10. Zidentyfikowane w ten sposób motywy zostały użyte jako dane wejściowe dla samoorganizującej się mapy, która następnie poszukuje takich wzorców w innych utworach ludowych pochodzących z różnych stron świata. To podejście dobrze pasuje do melodii ludowych, które przekazywane ustnie przez lata pozmieniały swoje początkowe brzmienia w zależności od ludu, który je powtarzał. Dzięki takiemu systemowi można odnaleźć powiązania etnologiczne pomiędzy populacjami różnych państw.



Rys. 10 Macierz odchyłeń, ścieżka złożona z wartości 0 wskazuje związek pomiędzy odpowiednimi fragmentami melodii, źródło: (Juhász, 2009)

3.3 Grupowanie utworów muzycznych

Metody grupowania utworów muzycznych wykorzystywane są w serwisach umożliwiających odtwarzanie muzyki. Opierają się one w głównej mierze na preferencjach użytkowników takich serwisów i analizie dużych zbiorów danych o tym jakich utworów słuchają jeden po drugim, które wyłączają po kilku taktach, a których słuchają kilkakrotnie. Jeśli jeden użytkownik po wysłuchaniu utworu A wyszukuje i odtwarza utwór B to najprawdopodobniej utwór B spodoba się również innemu użytkownikowi, który słuchał utworu A. Takie informacje mogą dobrze grupować utwory i być bardzo trafnym systemem rekomendacji, jednak ich działanie ma pewne wady. Zależy od liczby użytkowników serwisu, a także nie mówi nic o cechach utworów.

W swojej pracy chciałam skupić się na budowie utworu i jego zawartości muzycznej w porównywaniu utworów. Takie podejście umożliwia wskazanie konkretnych cech, fragmentów muzycznych, które kwalifikują utwór do pewnej grupy. W książce *Computational Music Analysis* (Meredith, 2016) podjęto próbę klasyfikacji utworów na podstawie analizy treści muzycznych.

W rozdziale *Composer Classification Models for Music – Theory Building* (Herremans, Martens, & Sorensen, 2016) przedstawione są wyniki komputerowej klasyfikacji utworów trzech kompozytorów: Bacha, Haydna i Beethovena opartej na analizie danych muzycznych. Autorzy zaimplementowali 5 metod klasyfikacji: drzewo decyzyjne C4.5, zestaw reguł RIPPER, regresja logistyczna, naiwny klasyfikator bayesowski i maszyna wektorów nośnych. Poprawność jaką osiągnęli to wyniki od 80% do 86% prawidłowej klasyfikacji.

Na rysunku Rys. 11 zawarte są parametry, które zostały użyte do strojenia klasyfikatorów w tym badaniu. Te wartości wynikają ze zliczania wystąpień poszczególnych dźwięków lub interwałów. Z punktu widzenia muzykologicznego nie są to dobre wskaźniki, gdyż nie są

podstawą do określania stylu kompozytorów. O ile w przypadku analizy konkretnego utworu możemy dodać to jako dodatkową informację, jak np. „Linia melodyczna opiera się o skoki interwałowe kwinty” lub „Akompaniament tworzą oktawy w diatonicznych pochodach” nie są to jednak parametry, które określane są w analizie każdego utworu.

Variable	Feature description
x_1	Chromatic Motion Frequency - Fraction of chromatic intervals
x_2	Melodic Fifth Frequency
x_3	Melodic Octaves Frequency
x_4	Melodic Thirds Frequency
x_5	Most Common Melodic Interval Prevalence
x_6	Most Common Pitch Prevalence ^a
x_7	Most Common Pitch Class Prevalence ^b
x_8	Relative Strength of Most Common Intervals - fraction of intervals belonging to the second most common / most common melodic intervals
x_9	Relative Strength of Top Pitch Classes ^c
x_{10}	Relative Strength of Top Pitches ^c
x_{11}	Repeated Notes - fraction of notes that are repeated melodically
x_{12}	Stepwise Motion Frequency

^a Pitch refers to MIDI pitch number.

^b Pitch class refers to MIDI pitch number mod 12.

^c Top pitch or top pitch class refers to the most common pitch or pitch class in the piece.

Rys. 11 Cechy wyodrębnione w celu klasyfikacji utworów trzech kompozytorów, źródło: (Herremans, Martens, & Sorensen, 2016)

4 Koncepcja rozwiązania

Pomysłem na przeprowadzenie grupowania utworów muzycznych jest zastosowanie podobnych algorytmów jak w przypadku dokumentów tekstowych. W tym rozdziale wskażę w jakim zakresie można traktować utwory muzyczne jak dokumenty tekstowe. W podrozdziale 4.2 pokazałam trudności w komputerowej analizie słów muzycznych, które doprowadziły do zdefiniowania słowa-motywu poprzez zbiór jego realizacji. Następnie przedstawiłam w jaki sposób wykrywam w utworze takie motywy muzyczne. Na końcu rozdziału opisałam miarę podobieństwa dwóch utworów.

4.1 Porównanie analizy dokumentów tekstowych i analizy muzycznej

Jak już wspomniałam w rozdziale 0 utwory muzyczne przypominają dokumenty tekstowe napisane w języku muzycznym. Czytane są od lewej strony do prawej, z góry na dół. Posiadają jednak dużo więcej oznaczeń. Zamiast linii zawierających poszczególne słowa mamy pięciolinie, często występujące wielokrotnie, połączone równoległe w systemy. Tab. 1 przedstawia prostą analogię pomiędzy językiem naturalnym a językiem muzycznym jaką przyjął w swojej pracy.

Język naturalny		Język muzyczny	
Ala ma kota, a kot ma Alę.	zdanie złożone	zdanie muzyczne	
Ala ma kota	zdanie proste	fraza muzyczna	
kot	słowo	motyw	
k	litera	nuta	

Tab. 1 Analogia elementów języka naturalnego i muzycznego

Utwór muzyczny dodatkowo posiada oznaczenia dynamiczne i artykulacyjne które można by porównać do znaków interpunkcyjnych w tekście. Kolorystyka, agogika i harmonika to elementy, które moim zdaniem nie mają swojego odwzorowania w dokumentach tekstowych. W swoich rozważaniach pominęłam jednak te elementy. W prostych algorytmach tekstowych znaki interpunkcyjne nie są uwzględniane, dlatego też dynamika i artykulacja zostały przeze mnie pominięte w dalszej pracy. Kolorystyka i agogika mają znaczenie w empirycznym odbiorze muzyki, ale mniejsze w statycznej analizie treści muzycznych. Natomiast harmonika została pominięta ze względu na zbyt dużą złożoność zadania. W przyszłości uwzględnienie harmonii mogłoby poprawić działanie algorytmu.

Metody analizy dokumentów tekstowych w większości opierają się o słowa. Wg Tab. 1 w muzyce słowu odpowiada motyw. Jak pisałam w rozdziale 2.2.2 motyw muzyczny

to podstawowa struktura składająca się z kilku lub kilkunastu dźwięków. Człowiek, słuchając muzyki, jest w stanie rozpoznać, a nawet zapamiętać poszczególne motywy. Są one również dość łatwe do zauważenia w zapisie nutowym. Dużo trudniej natomiast uchwycić ten element poprzez komputerowy algorytm (Wilder; Lartillot, 2005) Swój pomysł na rozwiązanie tego problemu przedstawię w dalszej części pracy.

4.2 Problemy w identyfikacji motywów

Ze względu na trudność w sformalizowaniu pojęcia motywu musiałam rozważyć możliwe jego formy, aby jak najlepiej służył realizacji postawionego przede mną zadania. Poniższa analiza umożliwiła zdefiniowanie pojęcia tego pojęcia na potrzeby mojego algorytmu.

Motyw staje się charakterystyczny dla danego utworu jeśli jego materiał muzyczny jest kilkakrotnie wykorzystywany. Aby zidentyfikować znaczące motywy analizuję materiał muzyczny w przesuwającym oknie zawierającym zadaną liczbę nut. Znalezione na przestrzeni całego utworu powtórzenia sekwencji parametrów będą traktować jako podstawę do wyznaczenia motywów.

Powtórzenia motywów nie muszą być dosłowne. Melodia może podlegać inwersji, augmentacji lub dyminucji (wartości rytmiczne są odpowiednio wydłużane lub skracane) czy też innym technikom wariacyjnym. Oznacza to, że jeden motyw może mieć różne realizacje w całym utworze. Algorytm musi zauważyć te odchylenia i rozpoznać w innym materiale konkretny motyw.


Realizacje motywu rozpoznaję dzięki porównaniu ich reprezentacji, które są zbiorem czterech cech (Lartillot, 2005). Dokładne obliczenia jakie stosuję przedstawiłam w dalszej części pracy, natomiast poniżej zestawiałam kilka fragmentów kantaty J.S.Bacha o numerze katalogowym BWV 295, jako przykłady wystąpień motywów.



<i>Diatonic interval</i>	[1,2,1,2,1]	[1,2,2,2,2]
<i>Chromatic interval</i>	[0,1,1,1,0]	[0,2,2,1,2]
<i>Contour</i>	[0,-,-,0]	[0,-,-,-]
<i>Rythm</i>	[2,1,1,1,2]	[2,1,1,1,2]

Tab. 2 Wartości czterech podstawowych cech dla powyższych motywów.


W Tab. 2 możemy zauważyć, że powyższe fragmenty różnią się w pewnych wartościach interwałów (wartości diatonic interval i chromatic interval). Dużo lepsze wartości uzyskujemy dla dwóch pozostałych kryteriów contour i rythm co może wskazywać, że została znaleziona inna realizacja tego samego motywu.



<i>Diatonic interval</i>	[2,1,2,1]	[4,1,2,1]
<i>Chromatic interval</i>	[2,0,2,0]	[5,0,2,0]
<i>Contour</i>	[+,0,-,0]	[+,0,-,0]
<i>Rythm</i>	[1,2,1,1,2]	[1,1,1,1,2]

Tab. 3 Wartości czterech podstawowych cech dla powyższych motywów.

Tab. 3 przedstawia wartości cech dla kolejnych dwóch fragmentów. W tym przypadku zmianie uległ tylko pierwszy interwał i wartość rytmiczna drugiej nuty. Pozostałe wartości są takie same, dzięki czemu możemy uznać te dwa fragmenty za ten sam motyw.



<i>Diatonic interval</i>	[2,2,3]	[2,2,7]
<i>Chromatic interval</i>	[2,1,5]	[2,1,9]
<i>Contour</i>	[-,-,-]	[+,+,-]
<i>Rythm</i>	[1,1,2,2]	[1,1,2,2]

Tab. 4 Wartości czterech podstawowych cech dla powyższych motywów.

Powyższy przykład i jego parametry w tab. 4 pokazuje powtórzenie motywu z użyciem inwersji. Trzy pierwsze nuty to dokładne powtórzenie interwałów, jednak za pierwszym razem kierunek melodii jest opadający, za drugim wznoszący. Fragmenty wyróżnia ostatni interwał, który jest wynikiem prowadzonej melodii na końcu kolejnych taktów. Algorytm powinien rozpoznać te dwa fragmenty jako jeden motyw.

Umieszczone tutaj przykłady posłużyły mi do ustalenia sposobu punktacji powtórzeń wartości parametrów w różnych sekwencjach nut.

4.3 System punktacji i próg odcięcia

Parametry używane do opisu sekwencji nut służą do ich porównywania i identyfikacji powtórzeń, które wskazują na wystąpienie pewnego znaczącego motywu muzycznego. Te parametry nie są równoważne, dlatego opracowałam specjalny system punktacji, który pozwoli komputerowo ocenić podobieństwo fragmentów muzycznych.

Pomimo że parametry są 4 to zdecydowałam o przyznawaniu sekwencjom dźwięków maksymalnie 2 punktów. Wynika to z natury parametrów gdzie 3 z nich odnoszą się do melodii (*diatonic interval*, *chromatic interval* i *contour*), a tylko jeden do rytmu (*rythm*). Rytm i melodia to dwa z trzech głównych elementów muzyki. Przy identyfikacji motywów uznałam więc powtórzenia rytmiczne za równie ważne jak powtórzenia melodyczne i dostosowałam w ten sposób punktację. W przypadku rozszerzania algorytmu o element harmonii punktacja powinna zostać poszerzona o kolejny punkt za podobieństwo na poziomie harmonicznym.

Wśród parametrów nie ma wysokości dźwięku co uniezależnia motywy od tonacji utworu. Dzięki temu można zidentyfikować motyw, który pojawia się w utworze poprzez progresję czyli przesunięcie melodii w górę lub w dół (Rys. 12). Progresja może występować jako dokładne powtórzenie interwałów i wtedy wszystkie parametry będą jednakowe, lub diatonicznie co może spowodować różnicę w interwałach chromatycznych, natomiast interwały diatoniczne pozostaną takie same. Z tego powodu podjęłam decyzję o jednakowej punktacji gdy sekwencje mają takie same wartości dla interwałów diatonicznych lub chromatycznych.

Stanisław Prószyński, *Tre pezzi in modo d'una sonata per pianoforte*, cz. III *Toccata*, t. 118–125

163 **Presto, veloce** (Szybko, lotnie)

Rys. 12 Progresja w utworze S. Prószyńskiego, *Tre pezzi in modo d'una sonata* (Wacholc)

Kolejnym często stosowanym zabiegiem muzycznym jest inwersja. Polega na zachowaniu interwałów przy zmianie kierunku melodii jak na Rys. 13a-b. Taki motyw ma identyczne wartości *interval* (*diatonic* lub *chromatic*) jednak różni się wartością *contour*. Dlatego punktacja za interwały powinna być przyznawana niezależnie od punktacji za kierunek melodii. Przy braku zgodności wartości *contour* przyznają połowę maksymalnej liczby punktów.

Jeśli jedynie *contour* jest zgodny, nie wskazuje nam to wystarczająco kolejnej realizacji motywu. Zdarza się jednak, że ostatni interwał w kilkunitowym motywie jest różny z zachowaniem kierunku melodii. Warto wtedy nagrodzić taką zgodność, aby na pewno rozpoznać motyw. Z tego względu punktuję również samodzielne wystąpienie jednakowej wartości konturu, ale maksymalna liczba punktów do zdobycia za ten element jest podzielona przez 3.

Augmentacja i dyminucja to zabiegi kompozytorskie polegające na zmianie długości trwania dźwięków. Są to odpowiednio proporcjonalne wydłużenie lub skrócenie wartości rytmicznej nuty. Zamiast porównywać pojedyncze wartości rytmiczne, porównuję proporcje dwóch kolejnych nut, aby algorytm zauważał takie zależności jak na Rys. 13c-d.

Rys. 13 Motyw muzyczny a) poddany zabiegom kompozytorskim: b) inwersji, c) augmentacji, d) dyminucji

Praca motywiczna polega również na wariacyjnym przetwarzaniu motywów co skutkuje zmianami poszczególnych interwałów. Drobne zmiany interwałów są więc dopuszczalne w różnych realizacjach motywów. Przy zachowaniu innych parametrów takich jak kontur czy rytm możemy pozwolić na różnice niektórych interwałów tak jak na rys.13. Motyw szesnastkowy w inwencji J. S. Bacha ma w pierwszym takcie budowę interwałów [4,4,3] lub [5,5,3]. Aby system punktacji uwzględnił tego typu zmiany musi rozważać niezależnie kolejne wartości sekwencji parametrów *interval*, *contour* i *rhythm*.

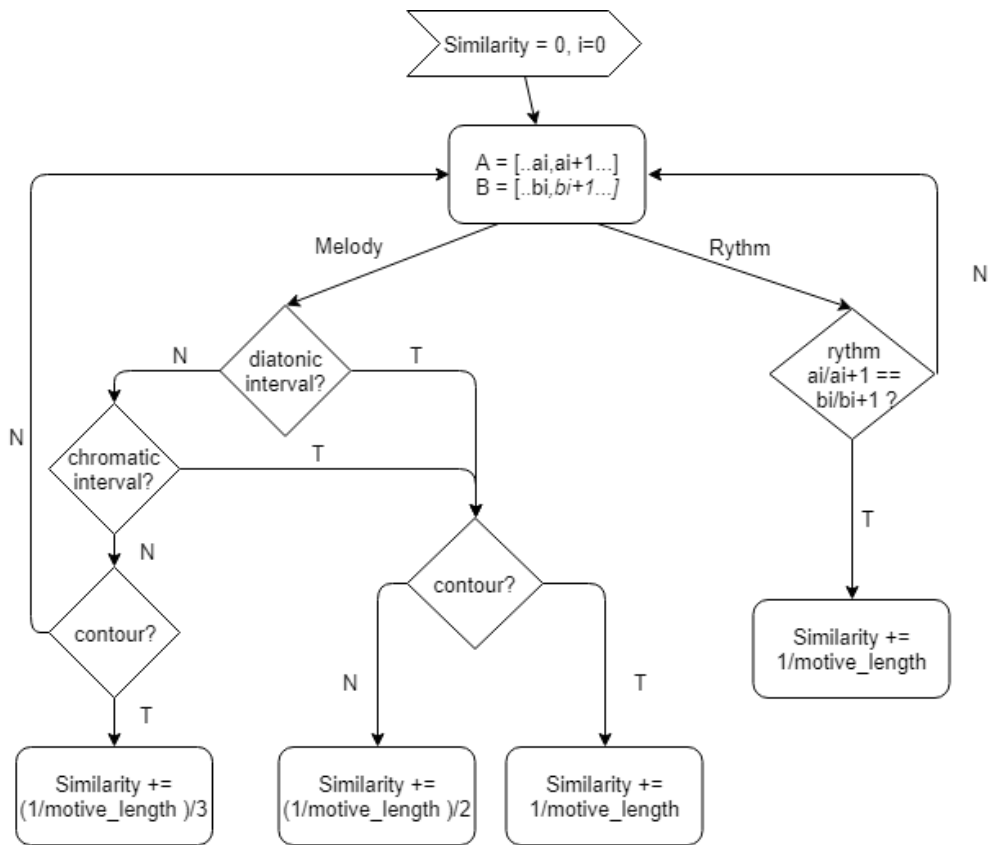


Rys. 14 Johann Sebastian Bach, Inwencja nr 13, takt 1. Motyw szesnastkowy ze zmianami interwałów

Aby motywy różnej długości były tak samo punktowane, kolejne wartości parametrów otrzymują punkty znormalizowane do długości motywu. Rys. 15 przedstawia schemat punktacji. Punkty przyznawane są gdy odpowiednie wartości dwóch sekwencji parametrów są identyczne. Wykonywane są niezależnie dwie ścieżki: melodyczna i rytmiczna. W rytmicznej porównane są proporcje kolejnych wartości rytmicznych. Ścieżka melodyczna rozważa trzy przypadki: gdy identyczna jest jedynie wartość parametru *contour* przyznawana jest 1/3 możliwych punktów, gdy identyczny jest tylko interwał (diatoniczny lub chromatyczny) przyznawana jest połowa możliwych punktów, natomiast gdy którykolwiek interwał i jednocześnie kontur są identyczne przyznawany jest cały punkt. Punkty są znormalizowane do długości wektora, ponieważ są one przyznawane dla kolejnych par wartości (a_i, b_i) , a nie dla par całych sekwencji parametrów. Wartość punktacji dla dwóch fragmentów utworu jest z przedziału $(0,2)$.

Wartość podobieństwa jest obliczana dla wszystkich par sekwencji dźwięków o zadanej długości. Ta wartość posłuży później do wybrania, które realizacje powinny odpowiadać temu samemu motywowi.

Na podstawie osiągniętych wyników podobieństw sekwencji dźwięków, wyznaczyłam wartość progową dla kwalifikacji fragmentów jako realizacje jednego motywu. Wszystkie sekwencje tworzą graf pełny, w którym wierzchołkami są potencjalne realizacje motywów, a wagi krawędzi reprezentują wartość podobieństwa dwóch motywów na podstawie czterech parametrów. Po usunięciu z grafu krawędzi o wartościach wyższych niż wyznaczony próg β pozostałe składowe spójne posłużą do utworzenia motywów. Wierzchołki jednej składowej tworzą zbiór realizacji jednego motywu. Rys. 16 przedstawia wynik dla utworu Bacha (BWV295) gdy wartość progowa podobieństwa realizacji wynosi 1.7. Na kolejnych pięcioliniach przedstawione są grupy realizacji stanowiące znaczące motywy w tym utworze.



Rys. 15 Schemat punktacji wartości parametrów dla pary (A,B) sekwencji dźwięków

The image displays a musical score for the chorale 'Des heili'gen Geistes reiche Gnad' (BWV 295). The score is presented on 12 staves, organized into four systems of three staves each. The notation includes various musical symbols such as clefs, time signatures, notes, rests, and accidentals. The first system (staves 1-3) shows the initial motifs. The second system (staves 4-6) continues the motifs. The third system (staves 7-9) shows more complex rhythmic patterns and some chromaticism. The fourth system (staves 10-12) concludes the motifs with dense chordal textures and rhythmic patterns. The overall style is characteristic of 17th-century Lutheran chorales.

Rys. 16 Motywy w chorale Des heili'gen Geistes reiche Gnad' (BWV 295)

4.4 Reprezentacja motywu i utworu

Utwór zazwyczaj zbudowany jest z większej liczby znaczących motywów. Każdy z tych motywów może być realizowany na różne sposoby. Do porównywania utworów potrzebujemy rozwiązać problem takiej reprezentacji motywów, aby nie tracić przy tym ważnych muzycznie informacji.

Rozważmy zatem utwór jako zbiór znaczących motywów. Motyw jest znaczący wtedy gdy sekwencja interwałów i wartości rytmicznych powtarza się w toku trwania utworu. Uwzględniając jednak informacje zawarte w poprzednich rozdziałach 4.2 i 3.2 motyw może być powtórzony w odmienny sposób. Aby skutecznie porównywać te motywy w różnych utworach powinniśmy zachowywać wszystkie informacje na temat różnych realizacji motywu.

Zauważmy, że poprzez cztery parametry: interwał diatoniczny, chromatyczny, kontur i rytm, umożliwiamy już porównywanie fragmentów o różnych wysokościach nut. Interesują nas takie same sekwencje interwałów, dzięki temu reprezentacja jest niezależna od tonacji utworu.


Jednym ze sposobów zapisu motywu jest zapis wektorów parametrów, w których pojawiać się będą białe znaki (X) oznaczające dowolność na danej pozycji wektora. Zapis motywu poprzez taki wzorzec pozostawia z jednej strony dość dużą swobodę w dopasowaniu fragmentów innych utworów, a z drugiej spore ograniczenie. Jeśli różnych realizacji mamy mało w utworze białych znaków będzie niewiele. Jeśli porównując dwa utwory będziemy poszukiwać identycznych wzorców niewielka modyfikacja motywu w innym utworze może skutkować nierozpoznanie podobieństwa (Rys. 19) Jednocześnie gdy motyw będzie posiadał więcej różnorodnych realizacji (różniących się w ogólności na większości pozycji wektorów parametrów) taki zapis może spowodować zbyt duże dopasowanie motywów z innych utworów (rRys. 18). Rozwiązaniem dla pierwszej sytuacji byłaby elastyczna miara podobieństwa utworów, natomiast przy wystąpieniu drugiego scenariusza miara podobieństwa musiałaby być bardzo dokładna. Ta sprzeczność eliminuje sposób reprezentacji motywu jako wektory parametrów z białymi znakami.




Rys. 17 Fragmenty Chorału Johanna Sbeastiana Bacha BWV 295

<i>Diatonic interval</i>	[1,2,X,2,X]
<i>Chromatic interval</i>	[0,X,X,1,X]
<i>Contour</i>	[0,-,-,X]
<i>Rythm</i>	[2,1,1,1,1,2]

Tab. 5 Uogólnione parametry motywu na Rys. 17.



Rys. 18 Motyw spełniający warunki tab. 5




Rys. 19 Motyw niespełniający warunków zawartych w Tab. 5 przez niezgodność czwartej wartości *chromatic interval* (tab.6)

<i>Diatonic interval</i>	[1,2,2,2,1]
<i>Chromatic interval</i>	[0,1,2, 2 ,0]
<i>Contour</i>	[0,-,-,-,0]
<i>Rythm</i>	[2,1,1,1,1,2]


Tab. 6 Parametry motywu na rys. 17

Drugim sposobem zapisu jest ustalenie przedziału w jakim mogą zachodzić zmiany. Przykładowo wektor interwałów $[1,1\pm 1,2,2\pm 1]$ uwzględnia wszystkie kolejne wektory: $[1,2,2,2]$, $[1,1,2,2]$, $[1,1,2,3]$, $[1,2,2,3]$ występujące w przykładzie na Rys. 20, a także wektory $[1,2,2,1]$ i $[1,1,2,1]$, które w tym fragmencie nie występują. Pytanie, na które trudno jest odpowiedzieć, dotyczy wielkości marginesu błędu. Jaki margines może uwzględnić wszystkie sensowne realizacje motywu jednocześnie nie dopuszczając zbyt wielu możliwości?

a)



b)



Rys. 20 Przykładowe melodie dla reprezentacji motywów jako wektory z marginesem błędu. Motyw melodii 17a) można zapisać jako $[1,1\pm 1,2,2\pm 1]$; Motyw melodii 14b) ma zapis $[1\pm 1,2\pm 1,2\pm 1,2\pm 1]$

Dla uproszczenia rozważania zawężymy do wartości wektora tylko jednego parametru – interwału diatonicznego. Drobne modyfikacje melodii z Rys. 20 doprowadziły do powstania melodii z rys. 14b. Tutaj wektor interwałów diatonicznych ma postać $[1\pm 1,2\pm 1,2\pm 2,2\pm 1]$.

Wartości wektora na ostatniej pozycji pokrywają się, natomiast na drugiej pozycji mogłyby być zbieżne gdybyśmy określili je tylko w jedną stronę (1+1 i 2-1, ponieważ w rzeczywistości tylko takie występują). Na pozostałych pozycjach w jednym utworze mamy stałe te same wartości, a w drugim również dopuszczamy zmiany. Widząc nuty możemy stwierdzić, że utwory są do siebie bardzo podobne. Natomiast wektory motywów są od siebie dość różne $[1,1\pm 1,2,2\pm 1]$; $[1\pm 1,2\pm 1,2\pm 1,2\pm 1]$. W tym przypadku można określić miarę podobieństwa na podstawie zawierania się przedziałów. Jednak czy miara ta będzie odpowiednia jeśli w motywie wymiennie będą pojawiać się interwały 3 i 7 jak w przykładzie motywów opisanych w Tab. 4? Margines ± 4 obejmie w ten sposób całą oktawę dźwięków. Jeśli jednocześnie uwzględnimy margines błędu na kilku pozycjach wektorów kilku parametrów, możemy zauważyć, że taka reprezentacja prowadzi do zbyt dużego dopasowania motywów między utworami. Te rozważania doprowadziły mnie do zdefiniowania kilku pojęć na potrzeby mojej metody.

Motyw jako abstrakcyjne pojęcie jest realizowany w utworze poprzez pewne wystąpienia sekwencji czterech parametrów (3). Warto zwrócić uwagę, że dla sekwencji nut o długości k sekwencje trzech parametrów mają długość $k-1$. Dzieje się tak ze względu na fakt, że parametry melodyczne nie dotyczą jednej nuty, ale różnicy między dwoma kolejnymi. Natomiast parametr *rhythm*, który jest związany z każdą nutą, ma długość k . Jeśli sekwencje są do siebie wystarczająco podobne możemy zakwalifikować te wystąpienia jako realizacje $R_i^{(k)}$ jednego motywu. Zbiór powiązanych ze sobą realizacji tworzy motyw $M^{(k)}$ (4). W ten sposób motyw nie jest uniwersalny, ale odpowiada pewnemu utworowi i zawiera wszystkie realizacje jakie wystąpiły w danym utworze C (5). Na podstawie tych wystąpień możemy dalej wyciągać wnioski poprzez odpowiednie określenie miary podobieństwa dwóch motywów – zbiorów realizacji a następnie utworów, czyli zbiorów motywów. Sposób wyznaczanie tych miar przedstawiłam w rozdziale 4.5. Rys. 21 przedstawia przykładowe motywy w postaci kilku realizacji (dla uproszczenia jednego parametru).

$$R_i^{(k)} = \begin{bmatrix} a_{11} & \dots & a_{1,k-1} \\ a_{21} & \dots & a_{2,k-1} \\ a_{31} & \dots & a_{3,k-1} \\ a_{41} & \dots & \dots & a_{4k} \end{bmatrix} \quad a_{ij} \in \{N, +, -, *, \emptyset\} \quad (3)$$

$$M^{(k)} = \{R_i^{(k)} : R_i^{(k)} \in M^{(k)} \Leftrightarrow \exists R_j^{(k)} \in M^{(k)} \wedge Sim(R_i^{(k)}, R_j^{(k)}) \geq \beta\} \quad (4)$$

$$C = \{M_1^{(2)}, \dots, M_n^{(2)}, M_1^{(3)}, \dots, M_i^{(k)} \dots\} \quad (5)$$

Motyw utworu A	Motyw utworu B
[1,2,2,2]	[2,2,3,3]
[1,1,2,2]	[2,2,4,3]
[1,1,2,3]	[1,2,3,2]
[1,2,2,3]	[1,2,1,3]
	[1,1,2,3]
	[1,2,2,3]

Rys. 21 Motywy melodii z rys 17a i 17b jako zbiory realizacji sekwencji parametrów – uproszczenie do jednego parametru

4.5 Podobieństwo motywów i utworów

Wyznaczone motywy reprezentujące utwór posłużą do wyznaczenia wartości podobieństwa między utworami. Podobieństwo dokumentów tekstowych obliczane jest na podstawie zawierania tych samych słów. Utwory można porównać pod względem zawierania takich samych motywów. Ale motywy reprezentowane są poprzez różne realizacje jak opisałam w poprzednim podrozdziale. W związku z tym w innym utworze ten sam motyw może się pojawiać trochę inaczej.

Podobieństwo dwóch motywów – zbiorów realizacji obliczam przy pomocy indeksu Jaccarda:

$$Sim(M_i, M_j) = J(M_i, M_j) = \frac{|M_i \cap M_j|}{|M_i \cup M_j|} \quad (6)$$

M_i, M_j - zbiory realizacji motywów o długości k

Aby obliczyć podobieństwo utworów należy uwzględnić podobieństwa wszystkich motywów. Całkowita wartość podobieństwa utworów może być reprezentowana poprzez znormalizowaną sumę ważoną podobieństw poszczególnych motywów jak we wzorze (7).

$$Similarity(C_x, C_y) = \frac{\sum_i^N \sum_j^M w_{ij} \cdot Sim(M_i, M_j)}{\sum_i^N \sum_j^M w_{ij}} \quad (7)$$

M_i - i-ty motyw utworu C_x

M_j - j-ty motyw utworu C_y

Dla przykładu założmy, że mamy dwa utwory C_x i C_y . Utwór C_x składa się z 3 charakterystycznych motywów: M_{x1}, M_{x2} i M_{x3} , natomiast utwór C_y ma 2 charakterystyczne motywy: M_{y1} i M_{y2} . Podobieństwa poszczególnych par motywów przedstawia Tab. 7.

Motyw	M_{y1}	M_{y2}
M_{x1}	0,5	0,2
M_{x2}	0	0,7
M_{x3}	0,1	0

Tab. 7 Wartości podobieństw motywów dla przykładowych utworów X i Y

Zakładając wszystkie wagi równe 1 podobieństwo utworów C_x i C_y wynosi $Similarity(C_x, C_y) = \frac{0,5+0+0,1+0,2+0,7+0}{6} = 0,25$. Ta wartość wydaje się jednak dość mała jeśli zauważymy, że utwory C_x i C_y mają dwa bardzo podobne motywy $Sim(M_{x1}, M_{y1}) = 0,5$ i $Sim(M_{x2}, M_{y2}) = 0,7$. Wynika z tego, że utwory mają dwa motywy znaczące wspólne, a utwór C_x ma jeszcze jeden dodatkowy charakterystyczny motyw. Intuicyjnie można stwierdzić, że podobieństwo tych utworów powinno być większe.

Rozwiązaniem tego problemu jest wybranie par motywów jako pokrycie motywiczne utworów C_x i C_y oraz obliczenie wartości uwzględniając jedynie te pary. Takie pokrycie

bardziej odpowiada sensowi podobieństwa utworów na podstawie zawartych w nich motywów. Jeśli znajdziemy w utworach bardzo podobne motywy to nie ma znaczenia, że właśnie te motywy nie są podobne do innych fragmentów utworów. A wręcz powinny się od nich różnić ze względu na sposób wyznaczania motywów. Gdyby były podobne to powinny odpowiadać kolejnym realizacjom tego samego motywu.

To ograniczenie możemy zrealizować poprzez konstrukcję dodatkowych warunków dla binarnej wartości v_{ij} (9) i (10).

Wagi w_{ij} , odpowiadają ważności motywu. Dłuższe motywy są traktowane jako bardziej znaczące dla formy utworu dlatego ich wartość powinna być większa. Przy tak zdefiniowanej mierze podobieństwo utworów C_x i C_y wynosi $Similarity(C_x, C_y) = \frac{0,5+0,7}{2} = 0,6$ co bardziej odpowiada intuicyjnemu podobieństwu tych utworów.

$$Similarity(C_x, C_y) = \frac{\sum_i^N \sum_j^M v_{ij} \cdot w_{ij} \cdot Sim(M_i, M_j)}{\sum_i^N \sum_j^M v_{ij} \cdot w_{ij}} \quad (8)$$

$$\sum_i^N v_{ij} \leq 1 \quad v_{ij} \in \{0,1\} \quad (9)$$

$$\sum_j^M v_{ij} \leq 1 \quad v_{ij} \in \{0,1\} \quad (10)$$

4.6 Grupowanie utworów

Wybór metody grupowania zależy od sposobu reprezentacji utworów, czyli również od reprezentacji motywu. Opisane przez mnie w rozdziale 2.1 metody charakterystyczne dla grupowania dokumentów tekstowych nie nadają się w przypadku utworów muzycznych opisanych przy pomocy motywów jako zbiorów realizacji. Słowa używane w dokumentach tekstowych należą do pewnego słownika i w wielu dokumentach występują w tej samej formie. Motywy muzyczne są wyznaczane na podstawie tekstu muzycznego. Oznacza to, że nie istnieją odgórne wzorce, które odnajdujemy w przykładach, a na podstawie przykładów możemy określić pewne wzorce.

Gdybyśmy próbowali stworzyć na podstawie takich motywów przestrzeń wielowymiarową posiadałaby ona tyle wymiarów ile motywów znajdziemy w całym korpusie utworów. Motywy zapisane jako zbiory realizacji prawdopodobnie w ogóle by się nie powtarzały w utworach, a więc analizowane przykłady nie utworzyłyby w przestrzeni większych skupisk. Aby było to możliwe należałoby ograniczyć powstały słownik motywów i ocenić które obiekty z analizowanych utworów mogą reprezentować ten sam motyw – słowo. Jednak na to rozwiązanie się nie zdecydowałam ze względu na charakter muzyki i muzyczne znaczenie motywu, który właśnie poprzez swoje odmiany pozwala nam z jednej strony rozróżniać utwory, a z drugiej porównywać kompozycje pochodzące z innych epok lub odnajdywać powiązania pomiędzy twórczościami różnych kompozytorów.

Aby móc pogrupować utwory w sposób najbardziej zbliżony do podejścia muzykologów opracowałam miarę podobieństwa opisaną w rozdziale 4.5, przy pomocy której można dokonać grupowania aglomeracyjnego utworów. Poniżej przedstawiłam algorytm aglomeracyjny w postaci pseudokodu.

Algorytm aglomeracyjny

Wejście: C - zbiór utworów c ,

$\text{Similarity}(c_i, c_j)$ - miara odległości pomiędzy utworami c_i i c_j

$S(G_i, G_j)$ - funkcja do mierzenia podobieństwa pomiędzy dwoma skupieniami G_i i G_j

Wyjście: dendrogram skupień

if liczba_skupień > 1:

 znajdź G_i, G_j które maksymalizują funkcję $S(G_i, G_j)$

$G_i = G_i \cup G_j$

 Usuń skupienie G_j

end

Funkcja do mierzenia odległości pomiędzy skupieniami musi opierać się o miarę podobieństwa *Similarity*. Na początku algorytmu skupieniem jest każdy utwór samodzielnie. Wtedy wystarczy użyć wprost tej miary. W kolejnych krokach algorytmu dołączamy do skupienia złożonego z dwóch utworów trzeci (lub skupienie dwóch innych). W tym przypadku możemy postępować w różny sposób. Możemy obliczyć średnią podobieństw utworów z dwóch grup, wybrać maksymalną wartość podobieństwa, minimalną lub zastosować bardziej skomplikowane podejście. Zrealizowałam trzy podstawowe metody a wyniki z poszczególnych prób przedstawione są w kolejnym rozdziale 5.2.2.

5 Wyniki

W tym rozdziale przedstawię wyniki, które osiągnęłam po zaimplementowaniu opisanej wcześniej metody do porównywania utworów. Ocenę tych wyników podzieliłam na 3 części.

Pierwsza część przeprowadzonych testów posłużyła mi do dobrania odpowiednich parametrów metody takich jak wartość progowa kwalifikująca realizacje jako jeden motyw i metoda grupowania. Następnie przeprowadziłam grupowanie dla całego korpusu utworów, a grupowanie oceniłam pod kątem wspólnej klasyfikacji utworów tego samego kompozytora. W ostatnim podrozdziale umieściłam moją ocenę kilku nieoczywistych klasyfikacji, które mogą świadczyć o niepoprawności metody lub ciekawym powiązaniu pomiędzy utworami różnych kompozytorów.

5.1 Zbiór danych

Analizowałam pliki MusicXML dostępne w korpusie biblioteki music21. Ze względu na wymagania algorytmu, który analizuje następstwo interwałów melodycznych nie uwzględniając harmonii, musiałam ograniczyć zbiór danych do utworów, które nie zawierają akordów. Najliczniejsze zbiory to utwory, które możemy zakwalifikować w trzech kategoriach: utwory Jana Sebastiana Bacha, utwory Claudio Monteverdiego oraz muzyka włoska czternastego wieku. Liczności zbiorów przedstawia Tab. 8.

Bach	398
Monteverdi	46
Muzyka włoska XIV w.	100

Tab. 8 Liczności zbiorów danych


5.2 Dobór parametrów metody

W pierwszej kolejności przeprowadziłam testy pozwalające na dopracowanie parametrów metody. Wykonałam je na małej liczbie danych, aby łatwiej było interpretować wyniki. Spośród każdej podgrupy utworów wylosowałam po kilka przykładów, przeprowadziłam grupowanie w zależności od różnych parametrów i wykreśliłam dendrogramy. Poniżej przedstawię kilka najważniejszych wyników. Całość testów zamieszczona jest w dodatku.


5.2.1 Wartość progowa β kwalifikacji motywów

Wyznaczając motywy jako zbiory realizacji, jak opisałam w rozdziale 4.3, analizowany jest graf pełny, w którym krawędzie reprezentują podobieństwo dwóch sekwencji nut. Z grafu zostają usunięte krawędzie o wartościach niższych niż pewna wartość progowa β . W zależności od doboru tej wartości, zbiory realizacji motywów mają różne rozmiary. Im wyższa wartość tym zbiory mają mniej elementów, ale jest ich więcej. Co oznacza, że wyznaczone motywy są określone bardziej dokładnie – z mniejszą tolerancją błędów.


Wartość podobieństwa sekwencji nut jest z zakresu $[0;2]$. Sprawdziłam, że dla wartości poniżej 1,5 powstałe zbiory zawierają zbyt odległe realizacje, w mojej ocenie nie tworzące tego samego motywu. Z tego powodu testy przeprowadziłam dla trzech wartości: 1.5, 1.7 i 1.9. Pozwoliło to zweryfikować jakie znaczenie ma ten parametr, a w konsekwencji licznosc oraz wielkosc zbiorow realizacji (motywów) w danym utworze.




Rys. 22 Dendrogram dla parametru $\beta = 1.5$




Rys. 25 Dendrogram dla parametru $\beta = 1.5$




Rys. 23 Dendrogram dla parametru $\beta = 1.7$



Rys. 26 Dendrogram dla parametru $\beta = 1.7$



Rys. 24 Dendrogram dla parametru $\beta = 1.9$



Rys. 27 Dendrogram dla parametru $\beta = 1.9$


Powyższe rysunki przedstawiają wyniki dwóch testów w postaci dendrogramów dla 9 utworów. Na rysunkach 22-24 miarą odległości jest odwrotność podobieństwa, natomiast na rysunkach 25-27 wartość przeciwna. Łatwo zauważyć, że wraz ze wzrostem parametru β maleją odległości pomiędzy utworami czyli są one oceniane jako bardziej podobne. Przy małym parametrze β powstają duże zbiory realizacji reprezentujące motyw, a wartość

podobieństwa motywów w dwóch utworach jest odwrotnie proporcjonalna do sumy licznosci tych zbiorów. Stąd maleje podobieństwo pomiędzy utworami. W przypadku wysokiego parametru β w utworze mamy więcej oddzielnych, dokładniej sprecyzowanych motywów. Mogłoby to również wpływać na mniejsze podobieństwo utworów ze względu na trudniejsze dopasowanie motywów pomiędzy utworami. Nie jest to jednak tak znaczące, ponieważ do całkowitej oceny wliczamy tylko podobieństwa najlepszych par motywów. Nie potrzebujemy więc uwzględniać, że motyw z utworu A jest niepodobny do kilkunastu motywów z utworu B jeśli jest mocno podobny do jednego z nich.

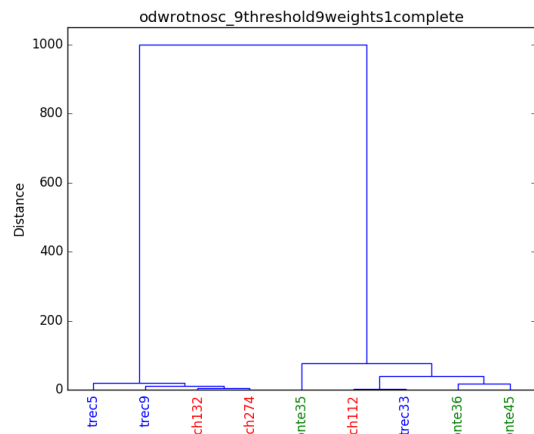
5.2.2 Metoda grupowania

Przetestowałam trzy podstawowe metody grupowania: *single*, *complete* i *average*. Metoda *single* polega na łączeniu grup na podstawie najmniejszej minimalnej wartości podobieństwa spośród wszystkich par elementów. *Complete* to przeciwieństwo czyli dołączane są utwory o najmniejszej maksymalnej wartości podobieństwa spośród elementów już powstałych grup. Natomiast metoda *average* wylicza średnią podobieństw dla wszystkich par i te wartości porównuje wybierając najbardziej podobny utwór lub grupę i łącząc w większe skupienie utworów. Poniżej przedstawiłam wyniki dwóch testów dla małych zestawów danych. Oba testy wykonane były dla motywów wyznaczanych z parametrem $\beta = 1.9$.


Metody *average* i *complete* dały w tych testach podobne grupy (rys. 28-29 i rys. 30-31). Metoda *single* bardziej odbiega od pozostałych. O ile na rys. 30 możemy zauważyć dwie charakterystyczne grupy utworów, tak w kolejnym teście na rys. 33 mamy właściwie jedną grupę. Obniżając próg odcięcia możemy jedynie otrzymać jedną grupę złożoną z kilku utworów i kilka kompozycji które samodzielnie tworzą grupy.




Rys. 28 Dendrogram dla metody grupowania *average*, miara odległości $distance_2$




Rys. 29 Dendrogram dla metody grupowania *complete*, miara odległości $distance_2$




Rys. 30 Dendrogram dla metody grupowania *single*, miara odległości $distance_2$



Rys. 32 Dendrogram dla metody grupowania *complete*, miara odległości $distance_1$



Rys. 31 dendrogram dla metody grupowania *average*, miara odległości $distance_1$



Rys. 33 Dendrogram dla metody grupowania *single*, miara odległości $distance_1$

5.2.3 Miara odległości


Testy przeprowadziłam stosując dwie miary odległości wyznaczone na podstawie podobieństwa obliczanego wg metody opisanej w rozdziale 4.5. Pierwsza miara to przeciwieństwo podobieństwa (8) jednak powiększona o 1, ponieważ miara podobieństwa jest z zakresu $\langle 0,1 \rangle$. Druga miara to odwrotność podobieństwa (9). Mianownik został powiększony o $\varepsilon = 0,0001$, ponieważ podobieństwo może przyjmować wartość 0.

$$distance_1(A,B) = 1 - Similarity(A,B) \quad (11)$$


$$distance_2(A,B) = \frac{1}{Similarity(A,B) + \varepsilon} \quad (12)$$

Otrzymane grupy nie różnią się znacząco jak możemy zobaczyć na rysunkach 34-37, natomiast na podstawie dendrogramów dla miary $distance_2$ łatwiej jest rozróżnić utworzone

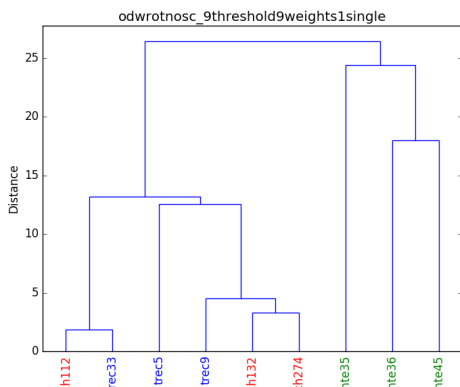
grupy utworów ze względu na większe różnice w wynikach. Odpowiedni dobór zamiany miary podobieństwa na odległość może wpłynąć na wygląd dendrogramu jednocześnie nie zmieniając porządku elementów zbioru danych.



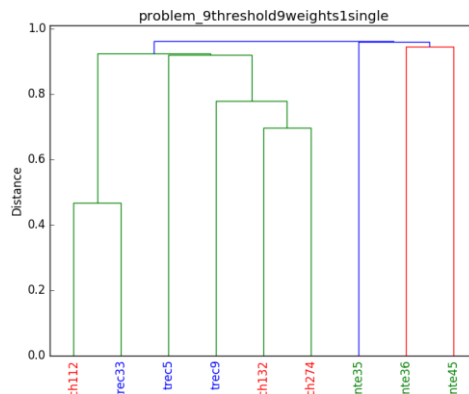
Rys. 34 Dendrogram dla miary distance2, grupowanie average



Rys. 36 Dendrogram dla miary distance1, grupowanie average



Rys. 35 Dendrogram dla miary distance2, grupowanie single



Rys. 37 Dendrogram dla miary distance1, grupowanie single


5.3 Grupowanie wg kompozytorów

Aby ocenić czy zaproponowane przeze mnie podejście do grupowania utworów muzycznych dobrze klasyfikuje kompozycje postanowiłam sprawdzić czy uzyskane grupy zawierają utwory tego samego kompozytora. Testy przeprowadziłam na większym zestawie danych niż opisane w poprzednim rozdziale. Wylosowałam 100 utworów równomiernie z 3 zestawów danych: 34 utwory Bacha, 33 utwory Monteverdiego oraz 33 utwory skomponowane w XIV w. przez włoskich kompozytorów. Na rysunkach przedstawione są wyniki tego grupowania.

Metoda grupowania *average* dała najbardziej obiecujący wynik. Dobierając odpowiednio wartość podziału uzyskałam 4 grupy, które dość dobrze odpowiadają oczekiwanym wynikom. Utwory Monteverdiego w większości zostały sklasyfikowane razem w grupie 3. Na Rys. 38 możemy zauważyć, że utwory te są do siebie dość podobne. Mniej liczna grupa 2 klasyfikuje w podobny sposób wyłącznie utwory z XIV w. Najliczniejsza jest natomiast grupa 4, w której znalazły się wszystkie 34 utwory Bacha, ale również 26 utworów z XIV w. oraz 7 kompozycji

Monteverdiego. Grupa ta w porównaniu do pozostałych posiada jednak mniej jednolitą strukturę. Można ją podzielić na 5-7 mniejszych ustawiając próg poniżej wartości 100. Taka modyfikacja jednak nie poprawi grup pod kątem klasyfikacji wg trzech grup źródłowych. Warto przyrzeć się konkretnym przykładom najbliżej zgrupowanych utworów w tej grupie. Taka klasyfikacja może wskazywać na inspiracje Bacha włoską muzyką średniowieczną. Analizę wybranych kompozycji wykonałam w kolejnej części pracy.

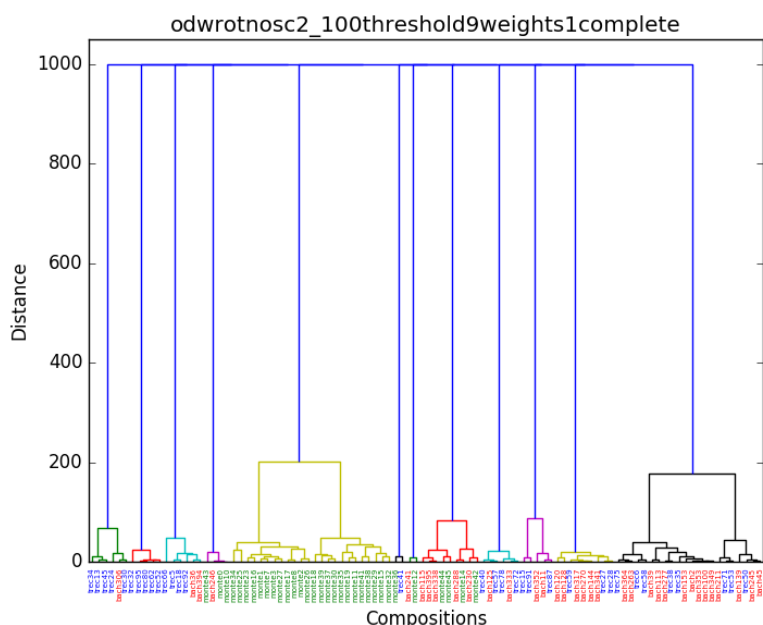
Ocena tej klasyfikacji pod kątem poprawnego grupowania wg kompozytorów wymaga przypisania grup do kompozytorów. Przykładowo możemy uznać, że grupa 4 to utwory Jana Sebastiana Bacha, grupa 3 Monteverdiego, a grupa 2 to muzyka włoska XIV w. Dokładność takiego grupowania wynosi 65%. Wynik można poprawić wybierając próg poniżej wartości 100 i odpowiednie zakwalifikowanie grup wchodzących w skład grupy 4, która jest najbardziej zróżnicowana.



Grupa	Bach	Monteverdi	Trecento
1	-	1	1
2	-	-	6
3	-	24	-
4	34	7	26

Tab. 9 Klasyfikacja utworów wg podgrup źródłowych do grup wynikowych na podstawie rys. 38

Rys. 38 Dendrogram 100 utworów, grupowanie *average*, $\beta = 1.9$



Rys. 39 Dendrogram 100 utworów, grupowanie *complete*, $\beta = 1.9$

Grupa	Bach	Monteverdi	Trecento
1	1	-	5
2	-	-	5
3	2	-	4
4	1	3	-
5	-	24	-
6	-	1	1
7	1	1	-
8	5	4	-
9	2	-	4
10	2	-	3
11	6	-	3
12	14	-	8


Tab. 10 Klasyfikacja utworów na podstawie rys. 39

Rys. 39 przedstawia dendrogram dla tej samej grupy utworów pogrupowanych metodą *complete*. W tym przypadku widzimy co najmniej 12 grup o różnej charakterystyce. Są grupy zawierające utwory z jednej kategorii źródłowej, np. grupa nr 5 zawiera jedynie utwory Monteverdiego, a grupa 2 wyłącznie utwory włoskich kompozytorów XIV w. Ciekawe są natomiast grupy 6 i 7, które składają się wyłącznie z dwóch bardzo podobnych do siebie utworów, które jednocześnie pochodzą z różnych grup źródłowych

Na podstawie tego wyniku oznaczymy poszczególne grupy wg dominującego kompozytora, aby utworzyć 3 grupy i porównać je z danymi wejściowymi. Grupy 6 i 7 odrzucamy jako błąd. Grupy Jana Sebastiana Bacha to numery: 8, 11 i 12, Claudio Monteverdi: 4 i 5, Trecento: 1, 2, 3, 9 oraz 10. Po zsumowaniu wyników otrzymamy grupy przedstawione w tabeli. Dokładność takiego grupowania wynosi 76%.

Grupy	Bach	Monteverdi	Trecento	Dokładność
Bach 8,11,12	25	4	11	62,5%
Monteverdi 4,5	1	27	0	96,5 %
Trecento 1,2,3,9,10	7	0	21	75%

Tab. 11 Grupy utworzone po połączeniu odpowiednich grup z Tab. 10



Rys. 40 Dendrogram 100 utworów, grupowanie *single*, $\beta = 1.9$

Metoda grupowania *single* dla 100 utworów nie dała dobrego rezultatu. Brak kilku niezależnych grup bez względu na wartość progu definiującego grupy.

Przetestowałam również metodę na całym korpusie danych – 544 utwory. Wyniki były porównywalne do testów na 100 utworach. Wyniki tego testu w postaci dendrogramów umieściłam w dodatku.

5.4 Wnioski z wykrytych anomalii

Po przeprowadzeniu grupowania wg ustalonych przeze mnie kryteriów dokonałam pewnej oceny wyników. Założenie uzyskania podziału pasującego do zbiorów wejściowych było pewnym punktem wyjścia. W tej części pracy opisałam niektóre wyniki odbiegające od tego założenia.

5.4.1 Bach i włoscy kompozytorzy XIV w.

W powstałych grupach często powtarzały się nieoczywiste połączenia utworów Bacha z kompozycjami czternastowiecznymi. Aby sprawdzić czy takie grupowanie ma sens odnalazłam kilka najlepiej połączonych ze sobą utworów i sprawdziłam dlaczego zostały do siebie dopasowane.

Już w pierwszych kilkunastu taktach Credo Cursor, włoskiego kompozytora de Teramo bez problemu odnalazłam kilka motywów powtarzanych w krótkim chorale Bacha. Fragmenty pokazane na Rys. 41 pozwalają zauważyć pewne podobieństwa. Widzimy dokładne lub zbliżone przebiegi ósemkowe, czasami występujące równoległe w kilku głosach. Utwór średniowieczny jest dużo dłuższy, a w dalszej części powtórzeń przebiegów melodycznych podobnych do oznaczonych na rysunku jest więcej.

Rys. 41 Chorał Bacha (BWV 248.23) oraz Credo Cursor sklasyfikowane jako bardzo podobne. Kolorami oznaczono kilka odpowiadających motywów.

Podobieństwo tych utworów, choć nie dotyczy czasu ani miejsca powstania dzieł, jest nie tylko widoczne, ale również słyszalne po odtworzeniu tych utworów. Niektóre z oznaczonych motywów wprawne ucho może wyłapać po ich wysłuchaniu. Jednak większa część z nich będzie niezauważalna. Utrudniać mogą zmiany rejestrów (kolor fioletowy), różna harmonia towarzysząca melodycznym motywom a także odmienne rozłożenie akcentów (kolor pomarańczowy). Te różnice nadają niepowtarzalny charakter utworom i przesuwają granicę pomiędzy inspiracją muzyczną a plagiatem.

5.4.2 Grupy 6 i 7 w grupowaniu metodą *complete*

Grupowanie metodą *complete*, którego wynik przedstawia Rys. 39, wskazało dwie ciekawe pary podobnych do siebie utworów (monte36 i trec41 oraz bach41 i monte12), które nie są podobne do żadnej innej grupy. Po połączeniu ich razem największa odległość jednego stała się zbyt duża aby móc połączyć tę grupę z jakimkolwiek innym skupieniem utworów, pozostałych w korpusie. Skłoniło mnie to do zbadania jak wyglądają te pary utworów i dlaczego zostały w ten sposób odseparowane.

Obie pary mają kilka wspólnych cech. Jeden utwór to ok. 90-cio taktowy madrygał Monteverdiego z pięcioma liniami melodycznymi, natomiast drugi jest sporo krótszy: dwie linie melodyczne 53-taktowego Benedicamus z XIV w. oraz 18-taktowy czterogłosowy chorał Bacha. Ma to swoje odzwierciedlenie w liczności motywów znalezionych w tych kompozycjach. Utwory składają się raczej z długich powtarzanych nut lub w pochodach gamowych, sekundowych.

Fragmenty utworów z grupy 6. przedstawia rys. 41. Oznaczone motywy wpłynęły na wynik ich podobieństwa. Większość motywów znalezionych w krótkim utworze Benedicamus zostały odnalezione również w dłuższym madrygale. Podobieństwo zależy od liczby motywów w utworze, który ma ich mniejszą liczbę, ponieważ założeniem jest odnalezienie powiązań niezależnie od długości utworu. Po połączeniu ze sobą tych utworów następnymi kandydaci do połączenia będą rozważani pod kątem mniejszego podobieństwa.

The image shows three musical score fragments labeled a), b), and c). Fragment a) is titled '21. Benedicamus' and is attributed to 'Anonymous I-IV 68'. It features a vocal line (C) and a bass line (B) with several motifs highlighted in green, yellow, and blue boxes. Fragment b) is titled 'madrigal.4.8.mxl' and is attributed to 'Monte:21'. It shows a vocal line (C) and a bass line (B) with motifs highlighted in blue boxes. Fragment c) is a continuation of the madrigal, showing a vocal line (C) and a bass line (B) with motifs highlighted in green and yellow boxes.

Rys. 42 Fragmenty utworów: (a) Benedicamus (XIV w.) oraz (b, c) Mardyał 4.8 (Monteverdi) zgrupowane razem metodą *complete*. kolorami oznaczone są wybrane odpowiadające motywy.

5.4.3 Metoda *single*

Dendrogram na rys. 40 jest bardzo nietypowy. Nie utworzyły się oddzielne grupy. Można jednak zauważyć ogólną tendencję. Mniejsze wartości odległości uzyskiwane są dla utworów Bacha, a następnie do tego zbioru dołączane są kolejne kompozycje Monteverdiego. Może to oznaczać, że duża część utworów Monteverdiego jest bardziej podobna do grupy utworów złożonej w większości z utworów Bacha i włoskich kompozytorów XIV w. niż do pozostałych niezgrupowanych jeszcze utworów tego samego kompozytora.

Jednak ta metoda przyjmuje jako kryterium grupowania najlepsze dopasowanie do któregoś z elementów grupy. Jeśli przyjrzymy się dokładnie wykresowi, zauważymy, że wśród dużej części kompozycji Bacha i licznych utworów czternastowiecznych znajdziemy kilka utworów Monteverdiego. Utwory te zawierają motywy podobne do pozostałych w tej grupie, natomiast kolejne kompozycje Monteverdiego, mogą łączyć się z tą grupą właśnie ze względu na te pojedyncze elementy albo utwory Bacha są na tyle różnorodne, że można wśród nich znaleźć motywy stosowane przez różnych kompozytorów.

Aby rozstrzygnąć tę kwestię porównałam konkretne przykłady na pozostałych wykresach. Pięć kompozycji Monteverdiego niezależnie od metody nie znalazło się w największej grupie przypisanej danemu kompozytorowi. W grupowaniu metodą *average utwory* te znalazły się w grupie 4, natomiast metoda *complete* przypisała je do małych grup 3, 7 i 8.

Taki wynik grupowania wynika z dwóch powodów. Przede wszystkim należy uwzględnić specyfikę zbioru danych. Utwory Bacha to krótkie utwory wokalne: kantaty i chorały. Motywy na których są zbudowane mogą często przeplatać się w dłuższych kompozycjach z pozostałą częścią zbioru. Drugim powodem jest charakterystyka samej twórczości Bacha. Będąc kantorem w kościele w Lipsku komponował oddzielną kantatę religijną na każdy tydzień. Każdy drobny utwór jest opracowany na oddzielnym pomysle melodyczno-rytmicznym, a ich liczność pozwala na dobre dopasowanie utworów innych kompozytorów.

6 Podsumowanie

Tematem mojej pracy było grupowanie utworów muzycznych. Początkowo chciałam porównywać materiał muzyczny analogicznie do dokumentów tekstowych. Zależało mi jednak na jak najlepszym odwzorowaniu muzykologicznego podejścia do kompozycji i zachowaniu sensu muzycznego. Z tych powodów nie mogłam dokładnie przełożyć algorytmów stosowanych do tekstów na muzykę.

Dokument tekstowy złożony jest ze słów, a utwór z motywów muzycznych. Chociaż intuicyjnie analogia między tymi elementami jest bardzo dokładna to w użyciu wygląda zupełnie inaczej. Słowa mają swoją podstawową wersję i ograniczoną liczbę odmian poprzez końcówki fleksyjne, natomiast muzyka opiera się na przetwarzaniu pewnego materiału muzycznego. Okazało się niemożliwym utworzenie słownika motywów wykorzystywanych w muzyce, który by dobrze porządkował utwory w wielowymiarowej przestrzeni wektorowej. Motywy muzyczne mogą być podobne, a jednak przetwarzane w odmienny sposób.

Wyzwaniem było zdefiniowanie czym jest motyw i jak go rozpoznawać przy użyciu metod komputerowych. Pomimo różnych prób (Lartillot, 2005), (Juhász, 2009), (Wilder), uważam, że żaden algorytm nie jest w stanie zidentyfikować znaczących motywów tak jednoznacznie jak specjalista w dziedzinie muzyki przy użyciu metod empirycznych. Wypracowany kompromis pomiędzy dokładnością dopasowania, a swobodą przetwarzania materiału motywicznego (4.4) jest wystarczająco dobrą reprezentacją dla przeprowadzonych przeze mnie badań.

Swoją pracę ograniczyłam do podejścia, które mogłabym opisać jako horyzontalne – analizy melodycznej i rytmicznej motywów. Natomiast to co odróżnia muzykę od słów są współbrzmienia akordów, instrumentów, które brzmiąc równocześnie tworzą unikalną harmonię. Aby to uwzględnić zapis nutowy należałoby analizować również wertykalnie. Klasyfikacje motywów można również poprawić poprzez definiowanie rozłożenia akcentów na poszczególnych nutach motywu. Aby algorytm mógł posłużyć w systemach antyplagiatowych musiałby uwzględniać również te parametry.

Zdefiniowałam motyw jako zbiór jego realizacji w danym utworze, a następnie opracowałam metodę porównywania motywów, która posłużyła do wyznaczenia miary podobieństwa i odległości dwóch utworów. Przy użyciu tej miary przeprowadziłam badania na zbiorze ponad 500 utworów, które pozwoliły mi na pewne zweryfikowanie poprawności działania mojego algorytmu.

Dane wejściowe pochodziły z trzech grup. Oczekiwałam uzyskania podobnych grup w wyniku zastosowania grupowania hierarchicznego. Dokładność takiego grupowania wyniosła 65% i 76% co nie jest tak dobrym wynikiem jakie zostały osiągnięte w badaniach nad metodami uczenia maszynowego bez nadzoru (Herremans, Martens, & Sorensen, 2016) gdzie dokładność w zależności od metody osiągała od 80% do 86%.

Moim założeniem było jednak nie tylko prawidłowe grupowanie utworów, ale również opracowanie narzędzia pomocnego w badaniach muzykologicznych, które oprócz oczywistych zależności, umożliwi znajdowanie nieznanymi a jednocześnie ciekawymi powiązań muzycznych pomiędzy różnymi utworami. Moim zdaniem metoda przedstawiona w tej pracy może posłużyć jako takie narzędzie.

W rozdziale 5.2 opisałam parametry metody, których zmiana pozwala na osiągnięcie wyników różnej dokładności. Parametr β wpływa na licznosc i wielkość zbiorów realizacji reprezentujących motywy. Im wyższa wartość tym zbiory mniejsze a motywy określone

bardziej dokładnie. Znalezione powiązania są więc bardziej dosłowne przy wyższej wartości tego parametru. Wybór sposobu samego grupowania oraz progu klasyfikacji wpływa na charakterystykę grup. Możemy uzyskać małe grupy, w których wszystkie utwory są ze sobą mocno powiązane lub większe grupy, o pojedynczych silnych powiązaniach. Myślę, że większość z tych charakterystyk znalazłaby zastosowanie w badaniach muzykologów.

Znaczący jest sposób zamiany miary podobieństwa na odległość. Odwrotność podobieństwa sprawia, że różnice wartości dla kolejnych poziomów grupowania są coraz większe. Przy odległości równej przeciwności podobieństwa utwory dość długo są do siebie niepodobne, a kolejne grupy łączą się na niewielkim przedziale wartości. Dendrogram dla takiego grupowania jest dużo mniej czytelny. Odrzuciłabym również metodę grupowania *single*, ponieważ nie tworzy dobrego podziału na równoliczne grupy.

Opracowana przeze mnie metoda jest dobrym punktem wyjścia do dalszych prac nad narzędziami do analizy muzyki. Chciałabym, aby w przyszłości powstał program oparty na przedstawionych tutaj założeniach, który będzie wykorzystywany w pracy muzykologów.

7 Bibliografia

- Brown, A. R. (1999). An Introduction to Music Analysis with Computer. *XArt Online Journal*.
- Collins, T., Arzt, A., Frostel, H., & Widmer, G. (2016). Using Geometric Symbolic Fingerprinting to Discover Distinctive Patterns in Polyphonic Music Corpora. W D. Meredith, *Computational Music Analysis* (strony 445-472). Springer.
- Gerhard, D. (2002). Computer Music Analysis.
- Herremans, D., Martens, D., & Sorensen, K. (2016). Composer Classification Models for Music - Theory Building. W D. Meredith, *Computational Music Analysis* (strony 369-392). Springer.
- Juhász, Z. (2009). Motive identification in 22 folksong corpora using dynamic time warping and self organizing maps. *10th International Society for Music Information Retrieval Conference*. ISMIR.
- Lartillot, O. (2005). Multi-Dimensional Motivic Pattern Extraction Founded on Adaptive Redundancy Filtering. *Journal of New Music Research*, 34 (4), 375-393.
- Lindstedt, I. (2011). Narzędzia komputerowe w badaniu muzyki. *Ruch Muzyczny*.
- Meredith, D. (2016). *Computational Music Analysis*. Springer.
- MuseScore. (brak daty). Pobrano 02 04, 2019 z lokalizacji <https://musescore.org/pl>
- Russel, M. A. *Mining the Social Web*.
- Velarde, G., Meredith, D., & Weyde, T. (2016). A Wavelet-Based Approach to Pattern Discovery in Melodies. W D. Meredith, *Computational Music Analysis* (strony 303-334). Springer.
- Wacholc, M. (brak daty). *Muzyka współczesna w Solfeżu elementarnym*. Pobrano 02 04, 2019 z lokalizacji Wydawnictwo muzyczne Triangel: <http://www.triangiel.com/pl/ksztalcenie-sluchu-na-materiale-muzyki-wspolczesnej.html>
- Wilder, G. (brak daty). Adaptive melodic segmentation and motivic identification.
- Wójcik, D. (1997). *ABC form muzycznych*.
- Wójcik, D. (2001). *Nauka o muzyce*.

Spis rysunków

Rys. 1 Wektory v i u w przestrzeni trzech słów (T1,T2,T3).....	12
Rys. 2 F. Chopin Sonata h-moll op.58 cz I – przykład motywów opadających.....	14
Rys. 3 P. Czajkowski VI Symfonia op. 74 – motywy z następstwem akcentów: część nieakcentowana – akcentowana – nieakcentowana (> nad nutą oznacza akcent)	15
Rys. 4 M. Karłowicz Odwieczne Pieśni I – motywy z następstwem akcentów: część akcentowana - nieakcentowana.....	15
Rys. 5 R. Schumann Album dla młodzieży, Biedna sierotka – fraza jednorodna ze zmianą kierunku linii melodycznej	15
Rys. 6 F. Chopin, Mazurek fis-moll op. 6 nr 1 – Zdanie muzyczne jednorodne, powtórzenie sekwencyjne	15
Rys. 7 Program MuseScore 3.0.1 (MuseScore)	18
Rys. 8 Parametry dźwięków wg O. Lartillota (Lartillot, 2005)	20
Rys. 9 Dwa sposoby klasyfikacji motywów. (Lartillot, 2005).....	20
Rys. 10 Macierz odchyień, ścieżka złożona z wartości 0 wskazuje związek pomiędzy odpowiednimi fragmentami melodii, źródło: (Juhász, 2009)	21
Rys. 11 Cechy wyodrębnione w celu klasyfikacji utworów trzech kompozytorów, źródło: (Herremans, Martens, & Sorensen, 2016).....	22
Rys. 12 Progresja w utworze S. Prószyńskiego, <i>Tre pezzi in modo d'una sonata</i> (Wacholc)	26
Rys. 13 Motyw muzyczny a) poddany zabiegom kompozytorskim: b) inwersji, c) augmentacji, d) dyminucji	26
Rys. 14 Johann Sebastian Bach, Inwencja nr 13, takt 1. Motyw szesnastkowy ze zmianami interwałów.....	27
Rys. 15 Schemat punktacji wartości parametrów dla pary (A,B) sekwencji dźwięków	28
Rys. 16 Motywy w chorale Des heil'gen Geistes reiche Gnad' (BWV 295)	29
Rys. 17 Fragmenty Chorału Johanna Sbeastiana Bacha BWV 295.....	30
Rys. 18 Motyw spełniający warunki tab. 5	30
Rys. 19 Motyw niespełniający warunków zawartych w Tab. 5 przez niezgodność czwartej wartości <i>chromatic interval</i> (tab.6).....	31
Rys. 20 Przykładowe melodie dla reprezentacji motywów jako wektory z marginesem błędu. Motyw melodii 17a) można zapisać jako $[1,1\pm 1,2,2\pm 1]$; Motyw melodii 14b) ma zapis $[1\pm 1,2\pm 1,2\pm 1,2\pm 1]$	31
Rys. 21 Motywy melodii z rys 17a i 17b jako zbiory realizacji sekwencji parametrów – uproszczenie do jednego parametru	32
Rys. 22 Dendrogram dla parametru $\beta = 1.5$	37
Rys. 23 Dendrogram dla parametru $\beta = 1.7$	37
Rys. 24 Dendrogram dla parametru $\beta = 1.9$	37
Rys. 25 Dendrogram dla parametru $\beta = 1.5$	37
Rys. 26 Dendrogram dla parametru $\beta = 1.7$	37
Rys. 27 Dendrogram dla parametru $\beta = 1.9$	37
Rys. 28 Dendrogram dla metody grupowania <i>average</i> , miara odległości $distance_2$	38
Rys. 29 Dendrogram dla metody grupowania <i>complete</i> , miara odległości $distance_2$	38
Rys. 30 Dendrogram dla metody grupowania <i>single</i> , miara odległości $distance_2$	39
Rys. 31 dendrogram dla metody grupowania <i>average</i> , miara odległości $distance_1$	39
Rys. 32 Dendrogram dla metody grupowania <i>complete</i> , miara odległości $distance_1$	39

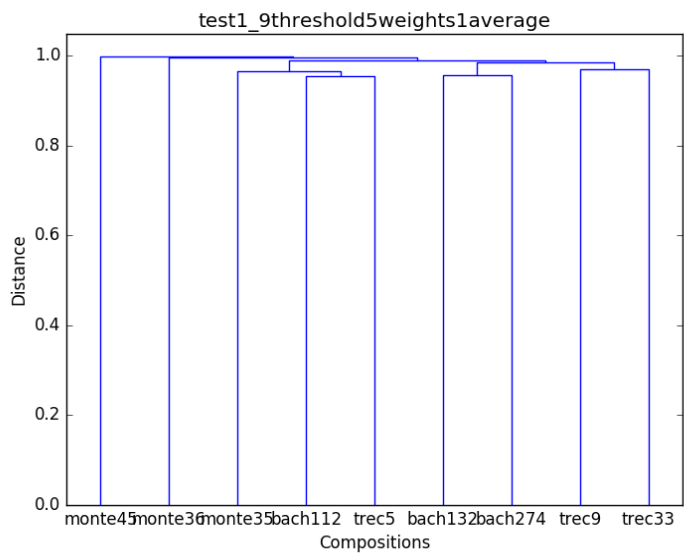
Rys. 33 Dendrogram dla metody grupowania <i>single</i> , miara odległości <i>distance</i> ₁	39
Rys. 34 Dendrogram dla miary <i>distance</i> ₂ , grupowanie <i>average</i>	40
Rys. 35 Dendrogram dla miary <i>distance</i> ₂ , grupowanie <i>single</i>	40
Rys. 36 Dendrogram dla miary <i>distance</i> ₁ , grupowanie <i>average</i>	40
Rys. 37 Dendrogram dla miary <i>distance</i> ₁ , grupowanie <i>single</i>	40
Rys. 38 Dendrogram 100 utworów, grupowanie <i>average</i> , $\beta = 1.9$	41
Rys. 39 Dendrogram 100 utworów, grupowanie <i>complete</i> , $\beta = 1.9$	42
Rys. 40 Dendrogram 100 utworów, grupowanie <i>single</i> , $\beta = 1.9$	43
Rys. 41 Chorał Bacha (BWV 248.23) oraz Credo Cursor sklasyfikowane jako bardzo podobne. Kolorami oznaczono kilka odpowiadających motywów.	44
Rys. 42 Fragmenty utworów: (a) <i>Benedicamus</i> (XIV w.) oraz (b, c) <i>Mardygał</i> 4.8 (Monteverdi) zgrupowane razem metodą <i>complete</i> . kolorami oznaczone są wybrane odpowiadające motywy.	45

Spis tabel


Tab. 1 Analogia elementów języka naturalnego i muzycznego	23
Tab. 2 Wartości czterech podstawowych cech dla powyższych motywów	24
Tab. 3 Wartości czterech podstawowych cech dla powyższych motywów	24
Tab. 4 Wartości czterech podstawowych cech dla powyższych motywów	25
Tab. 5 Uogólnione parametry motywu na Rys. 17.	30
Tab. 6 Parametry motywu na rys. 17	31
Tab. 7 Wartości podobieństw motywów dla przykładowych utworów X i Y	33
Tab. 8 Liczności zbiorów danych.....	36
Tab. 9 Klasyfikacja utworów wg podgrup źródłowych do grup wynikowych na podstawie rys. 38.....	41
Tab. 10 Klasyfikacja utworów na podstawie rys. 39.....	42
Tab. 11 Grupy utworzone po połączeniu odpowiednich grup z Tab. 10	42

Dodatek


Test 1	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.5




Test 1	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.7




Test 1	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.9




Test 1	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>complete</i>
Parametr β	1.5




Test 1	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>complete</i>
Parametr β	1.7




Test 1	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>complete</i>
Parametr β	1.9




Test 1	
Liczba utworów	9
Miara odległości	Przeciwiństwo podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.5




Test 1	
Liczba utworów	9
Miara odległości	Przeciwiństwo podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.7




Test 1	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.9




Test 2	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.5




Test 2	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.7




Test 2	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.9




Test 2	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>complete</i>
Parametr β	1.5




Test 2	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>complete</i>
Parametr β	1.7




Test 2	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>complete</i>
Parametr β	1.9




Test 2	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.5




Test 2	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.7




Test 2	
Liczba utworów	9
Miara odległości	Przeciwieństwo podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.9




Test 3	
Liczba utworów	9
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.5




Test 3	
Liczba utworów	9
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.7




Test 3	
Liczba utworów	9
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.9




Test 3	
Liczba utworów	9
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>complete</i>
Parametr β	1.5




Test 3	
Liczba utworów	9
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>complete</i>
Parametr β	1.7




Test 3	
Liczba utworów	9
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>complete</i>
Parametr β	1.9




Test 3	
Liczba utworów	9
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.5



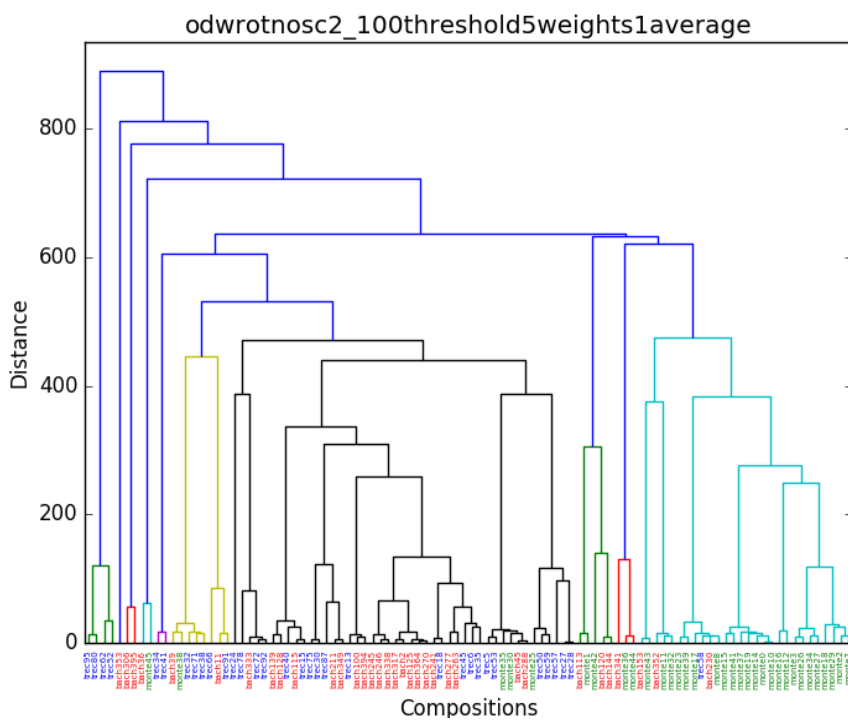
Test 3	
Liczba utworów	9
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.7




Test 3	
Liczba utworów	9
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.9




Test 4	
Liczba utworów	100
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.5




Test 4	
Liczba utworów	100
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.7




Test 4	
Liczba utworów	100
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.9




Test 4	
Liczba utworów	100
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>complete</i>
Parametr β	1.9




Test 4	
Liczba utworów	100
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.5




Test 4	
Liczba utworów	100
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.7



Test 4	
Liczba utworów	100
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.9




Test 5	
Liczba utworów	544
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.5




Test 5	
Liczba utworów	544
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>complete</i>
Parametr β	1.5



Test 5	
Liczba utworów	544
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.5




Test 5	
Liczba utworów	544
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.7




Test 5	
Liczba utworów	544
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>complete</i>
Parametr β	1.7




Test 5	
Liczba utworów	544
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.7



Test 5	
Liczba utworów	544
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>average</i>
Parametr β	1.9



Test 5	
Liczba utworów	544
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>complete</i>
Parametr β	1.9



Test 5	
Liczba utworów	544
Miara odległości	Odwrotność podobieństwa
Metoda grupowania	<i>single</i>
Parametr β	1.9

