MIR

Systemy rozpoznawania muzyki

Multimedialne bazy danych

MBD (ang. *Multimedia Database*):

- przechowują dane o zawartości multimedialnej (np. o nagraniach muzycznych)
- umożliwiają wyszukiwanie wg. kryteriów nietekstowych (np. fragment nagrania)

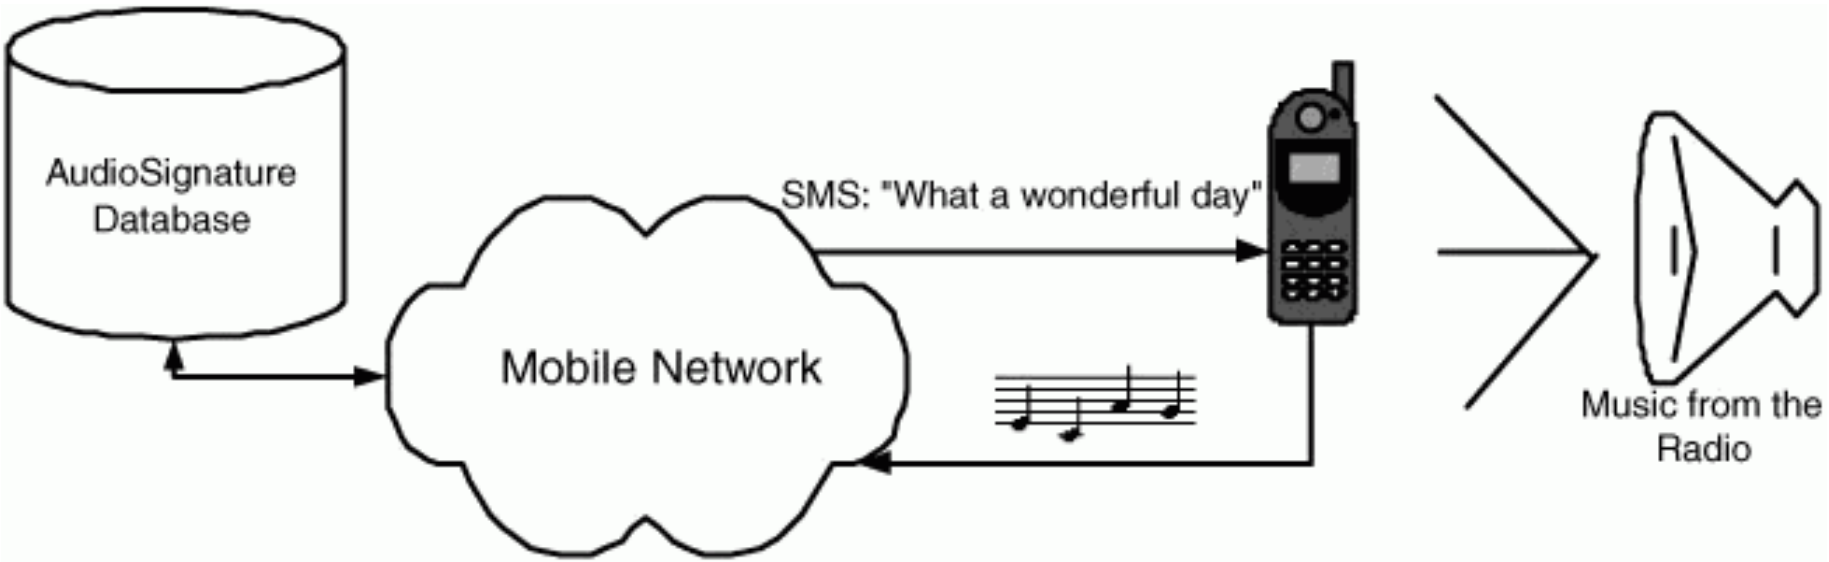

Systemy rozproszonych MBD

Klient łączy się z serwerem systemu
za pośrednictwem”chmury”

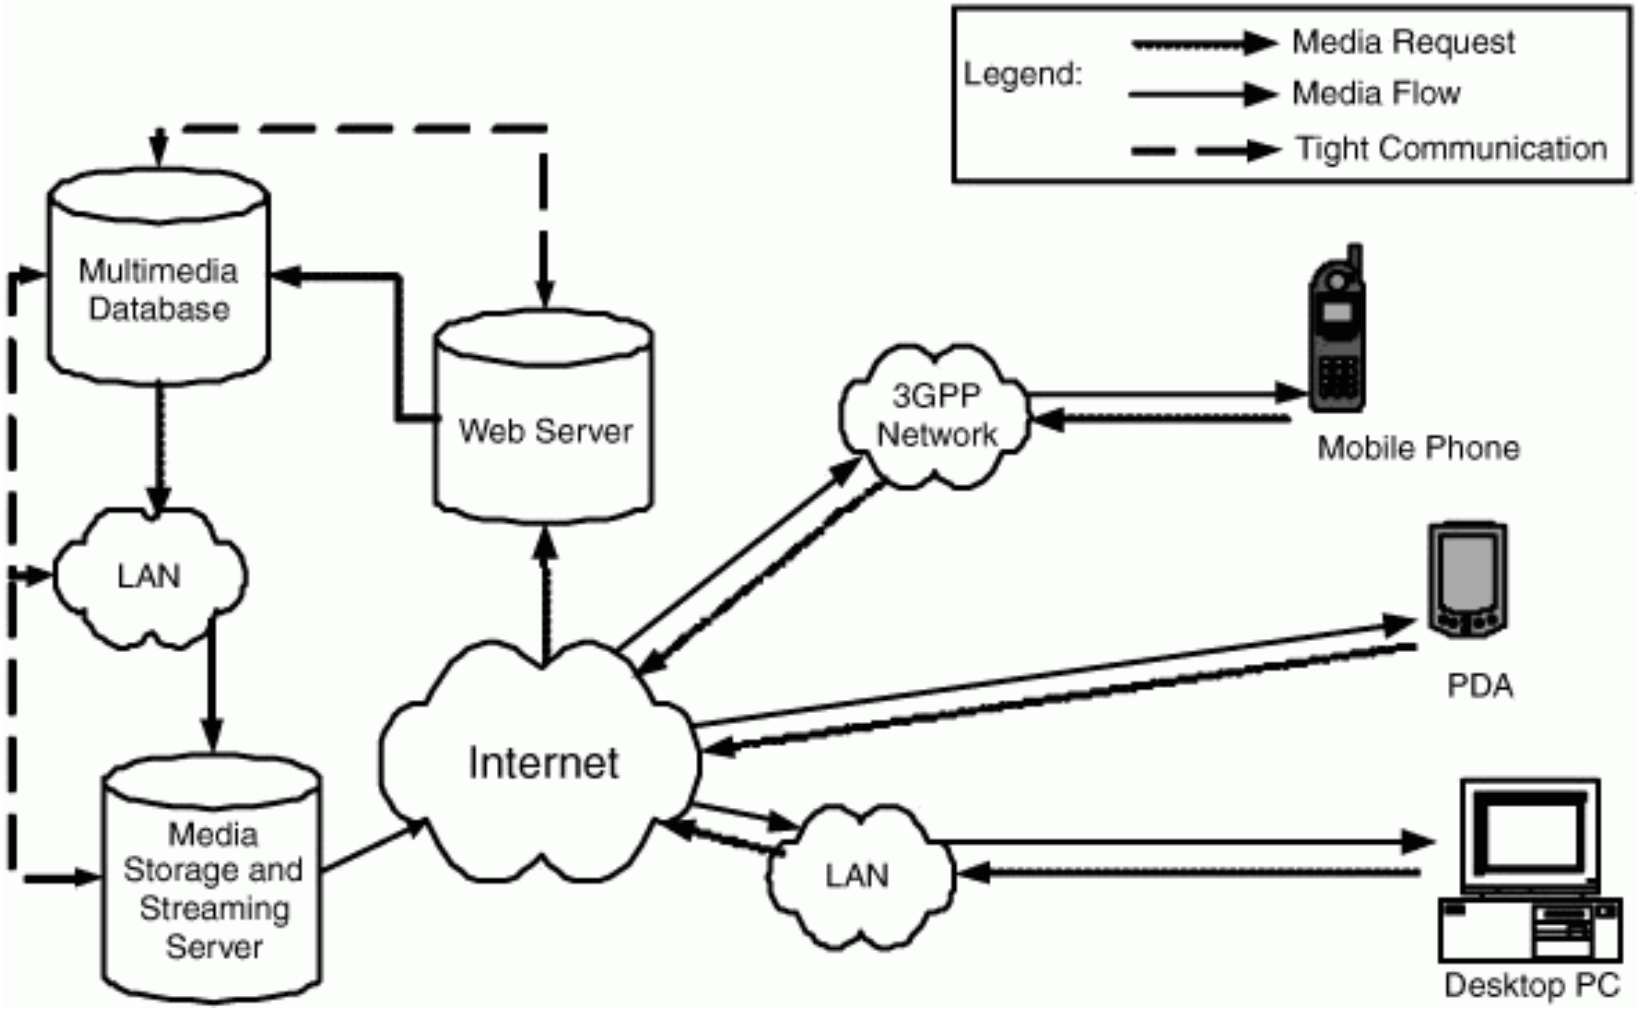

Systemy wyszukiwania muzyki

MIR – ang. *Music Information Retrieval*

Systemy umożliwiające wyszukiwanie muzyki wg kryteriów multimedialnych.

Metody przesyłania zapytań:

- zanucenie lub zagwizdanie melodii
- zapytanie przez przykład – parametryzacja fragmentu nagrania
- bezpośrednie podanie np. zapisu nutowego (rzadko stosowane)

Zastosowanie systemów MIR

Możliwe zastosowania systemów rozpoznawania muzyki:

- wyszukiwanie danych o nagraniu (użytkownik przesyła nagranie lub nuci melodię, chce poznać wykonawcę i tytuł)
- ochrona praw autorskich – porównywanie nagrań, wyszukiwanie plagiatów
- monitorowanie programu radiowego – automatyczne tworzenie listy emitowanych nagrań
- systemy rekomendacji muzyki

Przesłanie zapytania

- Podejście intuicyjne do wyszukiwania:
  - przesyłamy do serwera nagranie (plik)
  - serwer parametryzuje nagranie i dokonuje wyszukiwania
- Wada:duże obciążenie łącza.
- Lepsze rozwiązanie:
  - oprogramowanie po stronie klienta (np. aplikacja mobilna) dokonuje parametryzacji
  - do serwera przesyłane są tylko parametry
  - serwer dokonuje tylko wyszukiwania i zwrócenia wyników

Systemy QBH

QBH – *Query-by-Humming* („zapytanie przez zanucenie melodii”)

- użytkownik nuci lub gwiżdże do mikrofonu melodię,
- algorytm śledzenia wysokości dźwięku (*pitch tracking*) zamienia melodię np. na kontur melodyczny,
- moduł wyszukujący porównuje kontur melodyczny uzyskany z zapytania z konturami zapisanymi w bazie, znajduje najbardziej podobne obiekty.

Schemat systemu QBH

Ghias *et al.*, 1995

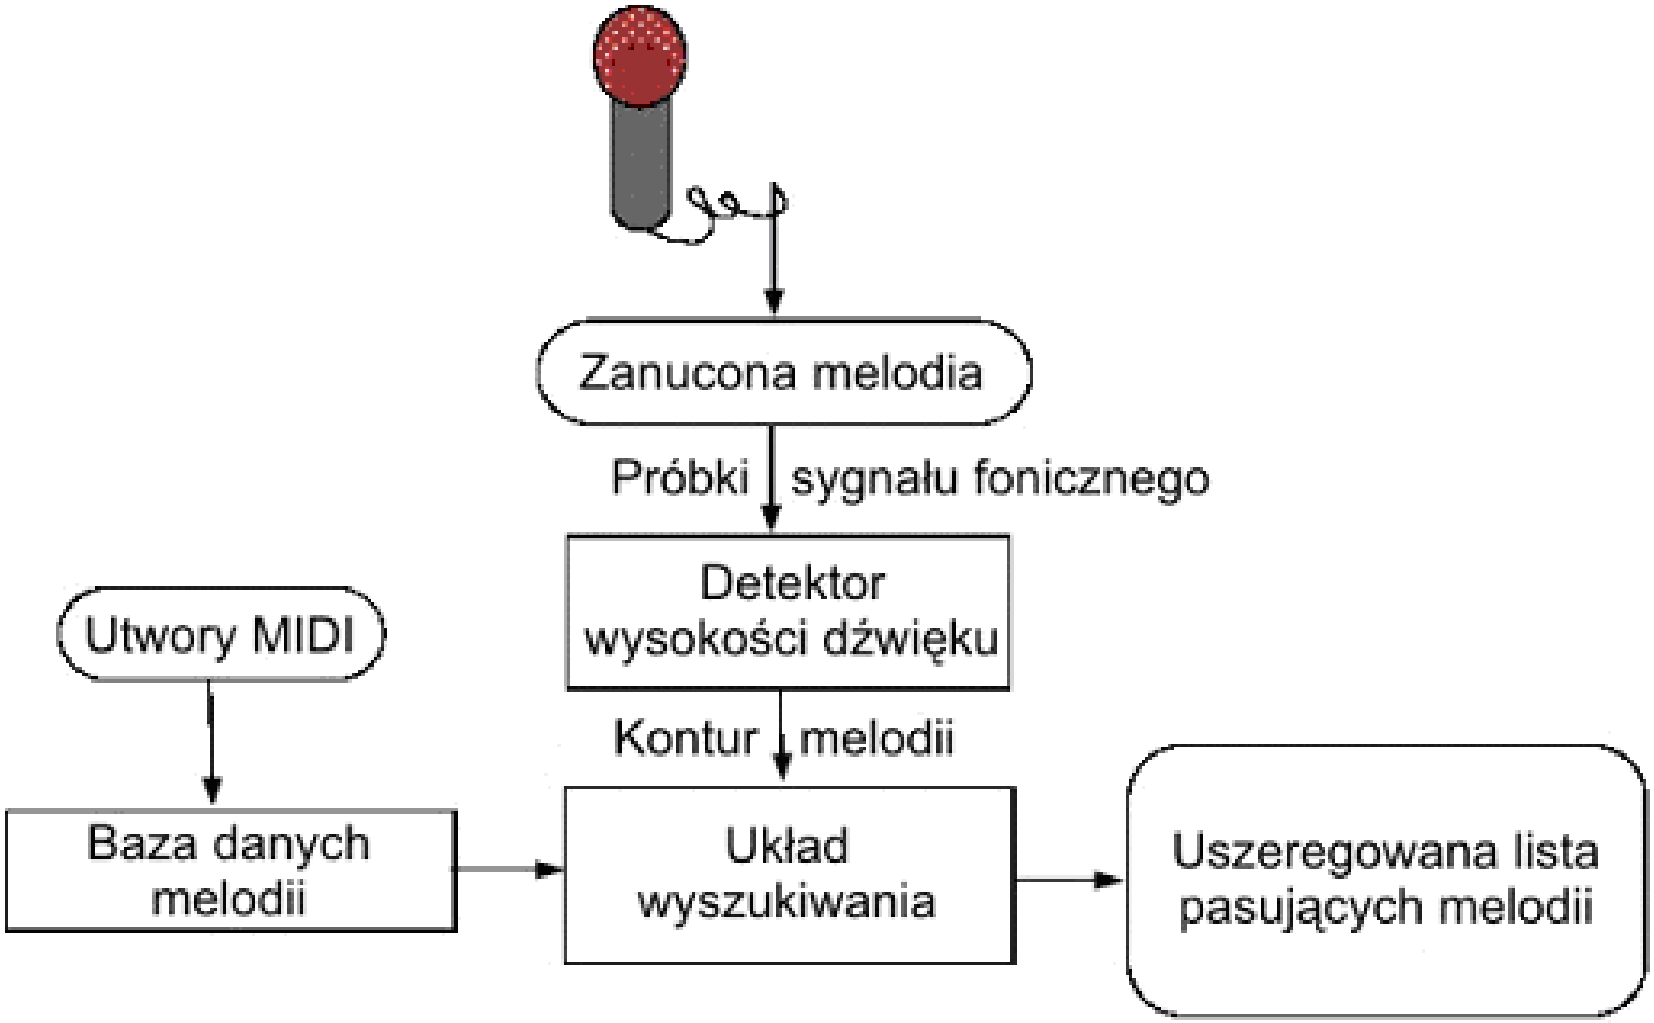

Kontur melodyczny

Najprostszy opis: kontur melodyczny jest zapisywany przy pomocy kodu Parsonsa.

Zapisywana jest tylko informacja o wysokości każdej nuty względem poprzedniej:

U – wyższa, D – niższa, R (lub S) – taka sama.

Przykładowy kod: *UURRDUDDDDDRUDUD

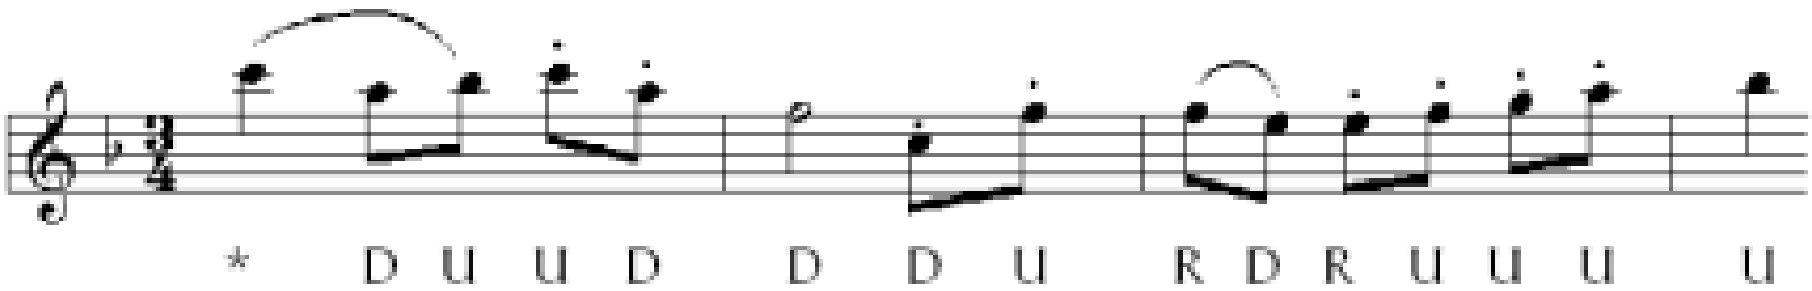

Kontur melodyczny

Zakłada się, że kod Parsonsa dla danej melodii jest unikalny. Kod jest nieczuły na:

- drobne zafałszowania przy nuceniu melodii,
- błędy rytmiczne (czasy trwania nut).

Mogą jednak wystąpić błędy, które należy brać pod uwagę podczas wyszukiwania:

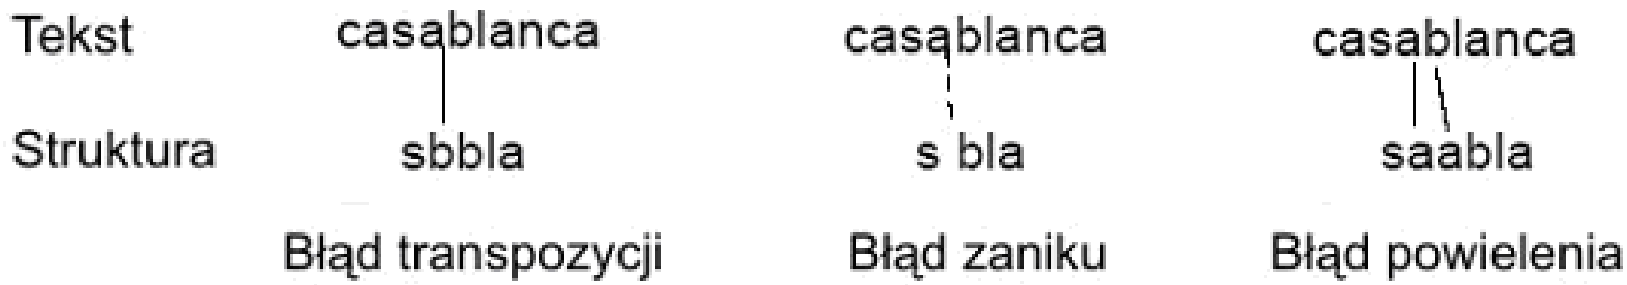

Rozszerzenia systemu QBH

Bardziej zaawansowane systemy QBH używają do wyszukiwania informacji o:

- bezwzględnych wysokościach nut
- czasie trwania poszczególnych nut

Detekcja wysokości nut może wykorzystywać różne algorytmy (autokorelacja, liczenie przejść przez zero, FFT, itp.).

Detekcja wysokości nut (przykład)

- Sygnał jest przetwarzany przez filtr dolnoprzepustowy – ogr. pasma do 1 kHz.
- Detektor wyznacza w przetworzonym sygnale powtarzający się okres podstawowy
- Analiza w ramkach o dł. ok. 20 ms.

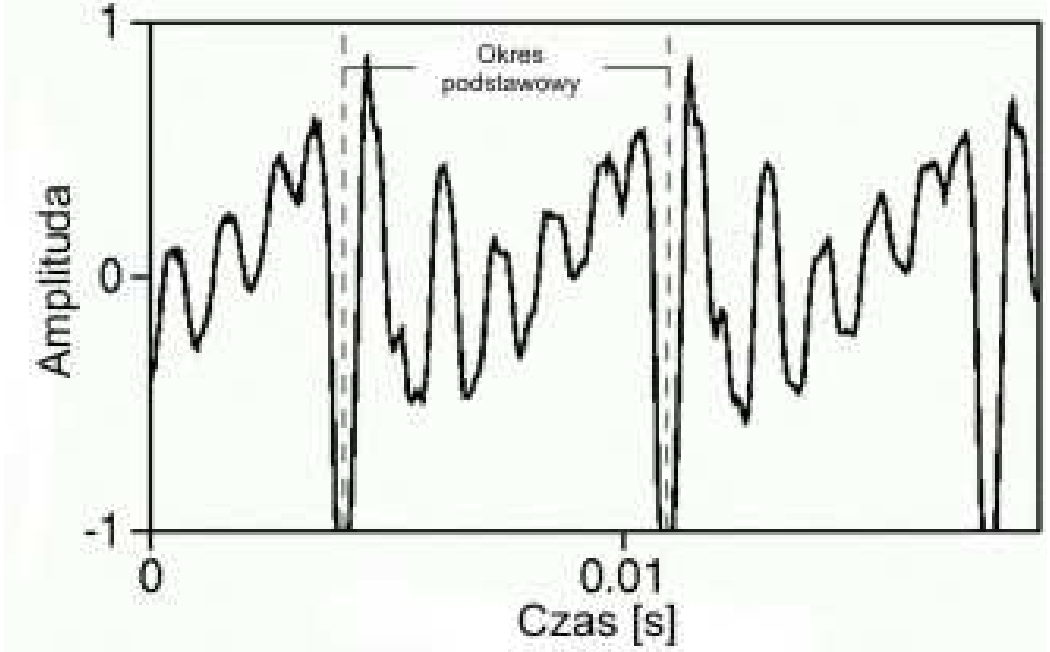

Detekcja czasu trwania nut (przykład)

- Użytkownik nucąc melodię wyraźnie rozdziela każdą nutę („na na na na…”).
- Gwałtowny wzrost, a następnie spadek amplitudy sygnału (trwający ok. 60 ms).
- Wartości progowe amplitudy pozwalają wyznaczyć początek i koniec każdej nuty.

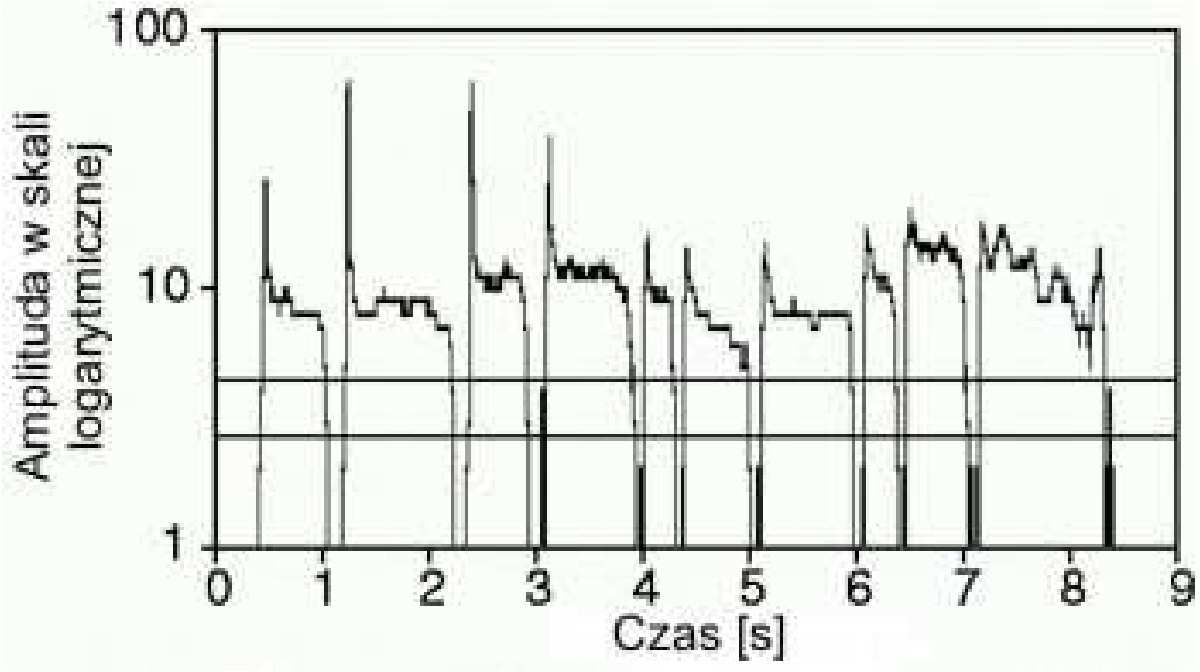

QBH a QBW

Czasami rozróżnia się dwa typy QBH:

- właściwe QBH – zapytanie przez „zanucenie”
- *Query by whistling* – zapytanie przez zagwizdanie melodii

Oba typy wykorzystują te same algorytmy.

QBW w porównaniu do QBH:

- znacznie prostsza analiza (gwizdanie produkuje wielotony łatwe do analizy)
- trudniej jest podać melodię bez zafałszowań

Query by rhythm

- QBR (*Query by Rhythm*) to metoda, w której podaje się kontur rytmiczny, np. przez wystukanie rytmu na klawiaturze komputerowej.
- Jest mało dokładna, rytm rzadko identyfikuje jednoznacznie utwór, trudno dokładnie podać rytm utworu.
- Metoda raczej pomocnicza, stosowana wraz z innymi metodami.

Wyszukiwanie danych

Zadanie dla algorytmu wyszukującego:

- wyszukać wystąpienia wzorca
  P = p1 p2 p3 … pm
- w ciągach tekstowych T = t1 t2 t3 … tn
- przy założeniu maksimum *k* różnic

Baza zwraca listę znalezionych utworów uszeregowanych wg podobieństwa do zapytania.

Algorytmy wyszukiwania:

- obliczanie odległości ciągów
- drzewa binarne i inne algorytmy

Optymalizacje wyszukiwania

Przyspieszenie wyszukiwania:

- wybieramy losowo z bazy *k* obiektów – punktów węzłowych, liczymy ich odległość od każdego obiektu w bazie
- każdy obiekt jest przypisany do najbliższego punktu węzłowego
- liczymy odległość szukanego ciągu od *k* punktów węzłowych
- wybieramy najbliższy punkt węzłowy i liczymy odległość tylko od jego punktów potomnych

Optymalizacje wyszukiwania

Przy dużych zbiorach danych można powtórzyć tą operację dla mniejszych grup ciągów.

Tworzy się w ten sposób struktura drzewiasta.

Na każdym poziomie drzewa – wybór potomka z najmniejszą odległością.

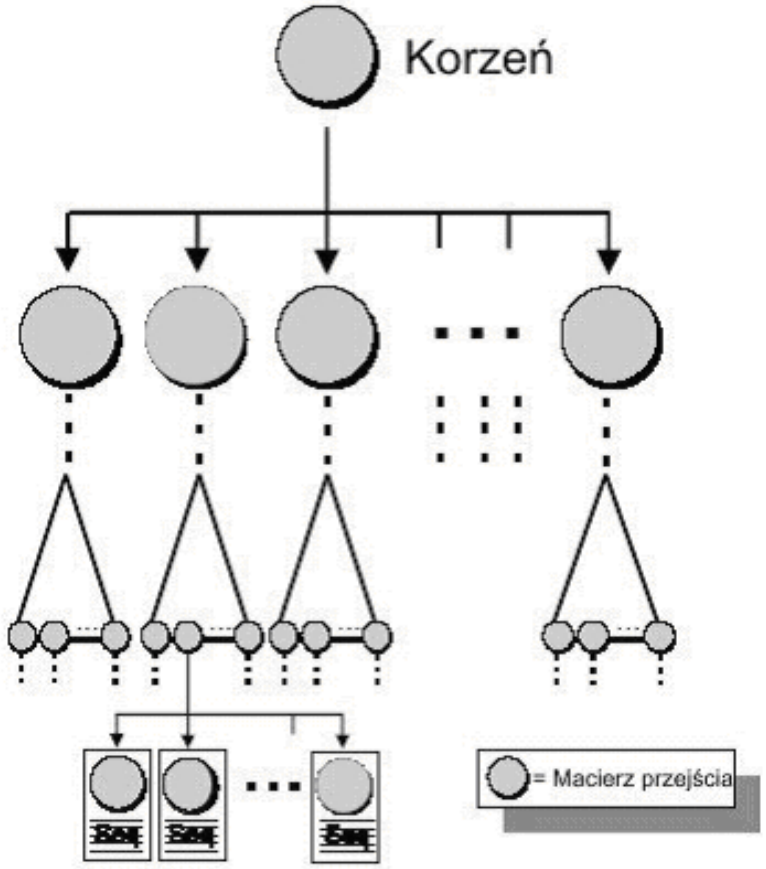

Przykład: system Musipedia

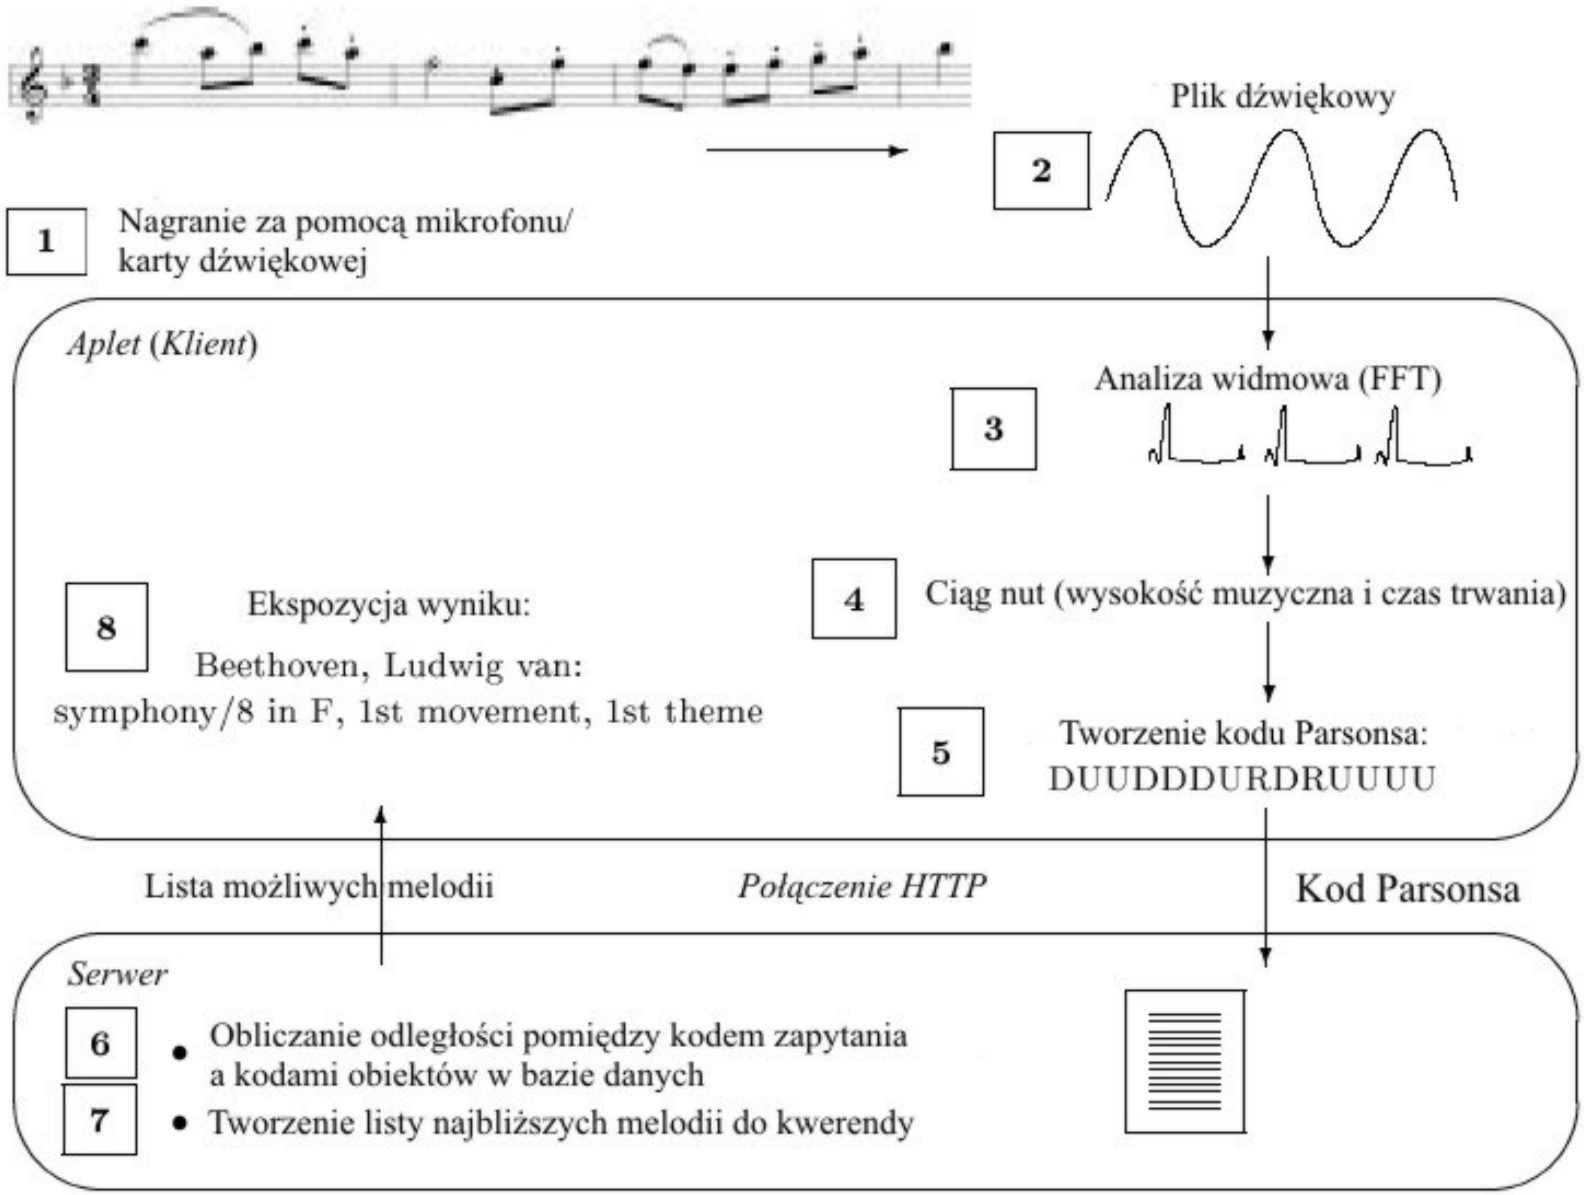

Przykład: system Musipedia

Panel do wprowadzenia zapytania

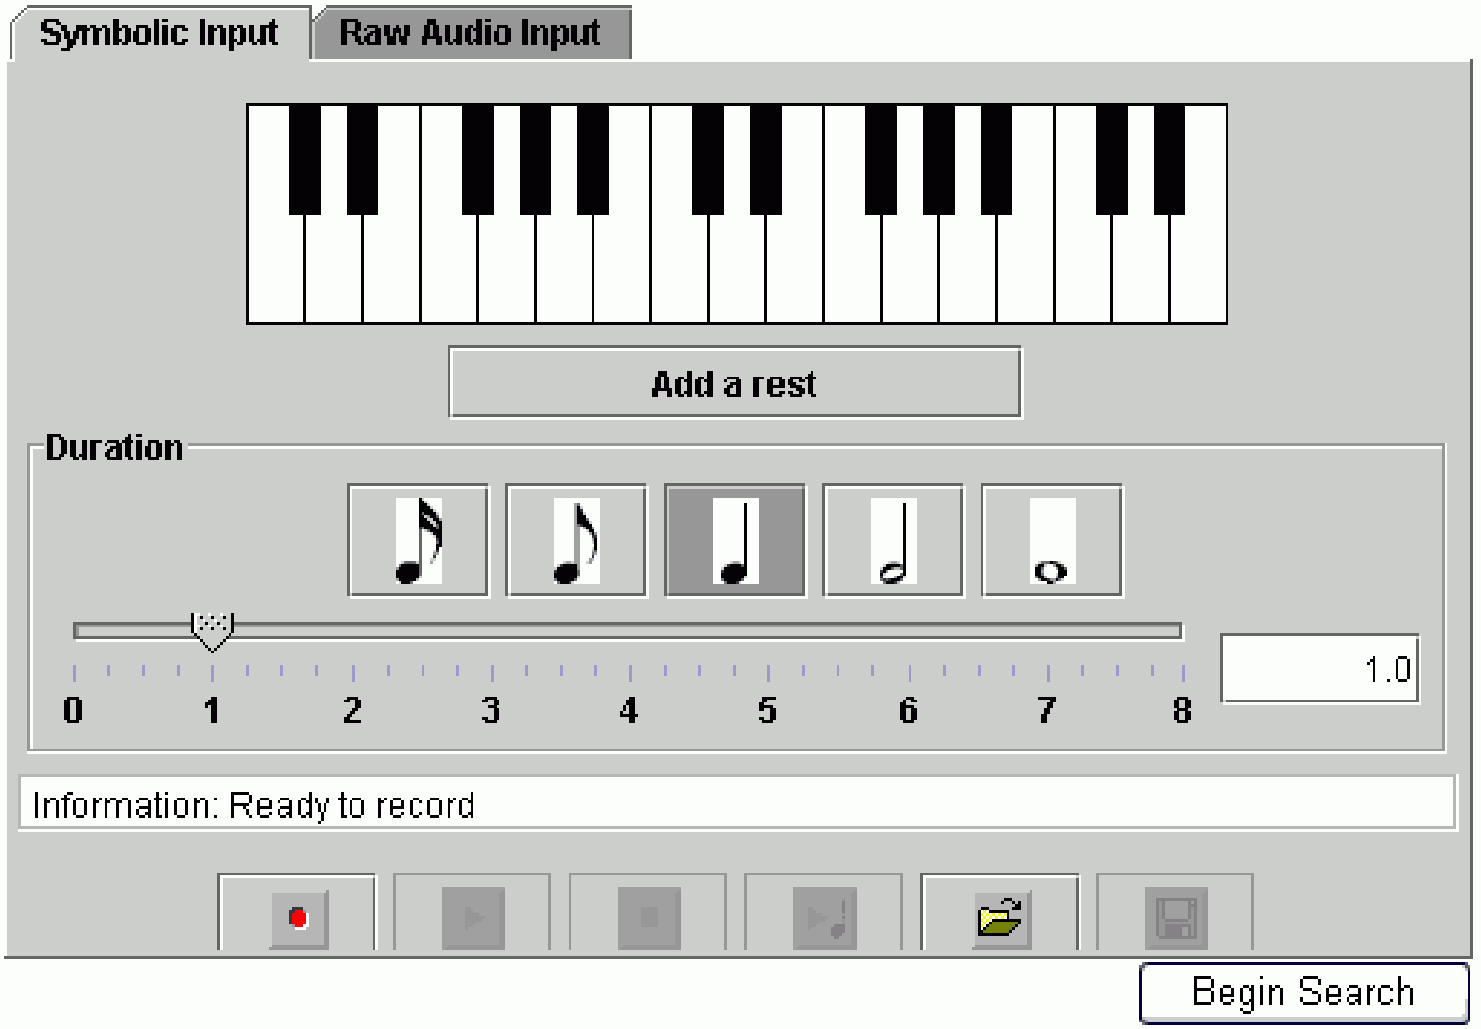

Przykład: system Musipedia

Kod Parsonsa i zwrócony wynik wyszukiwania

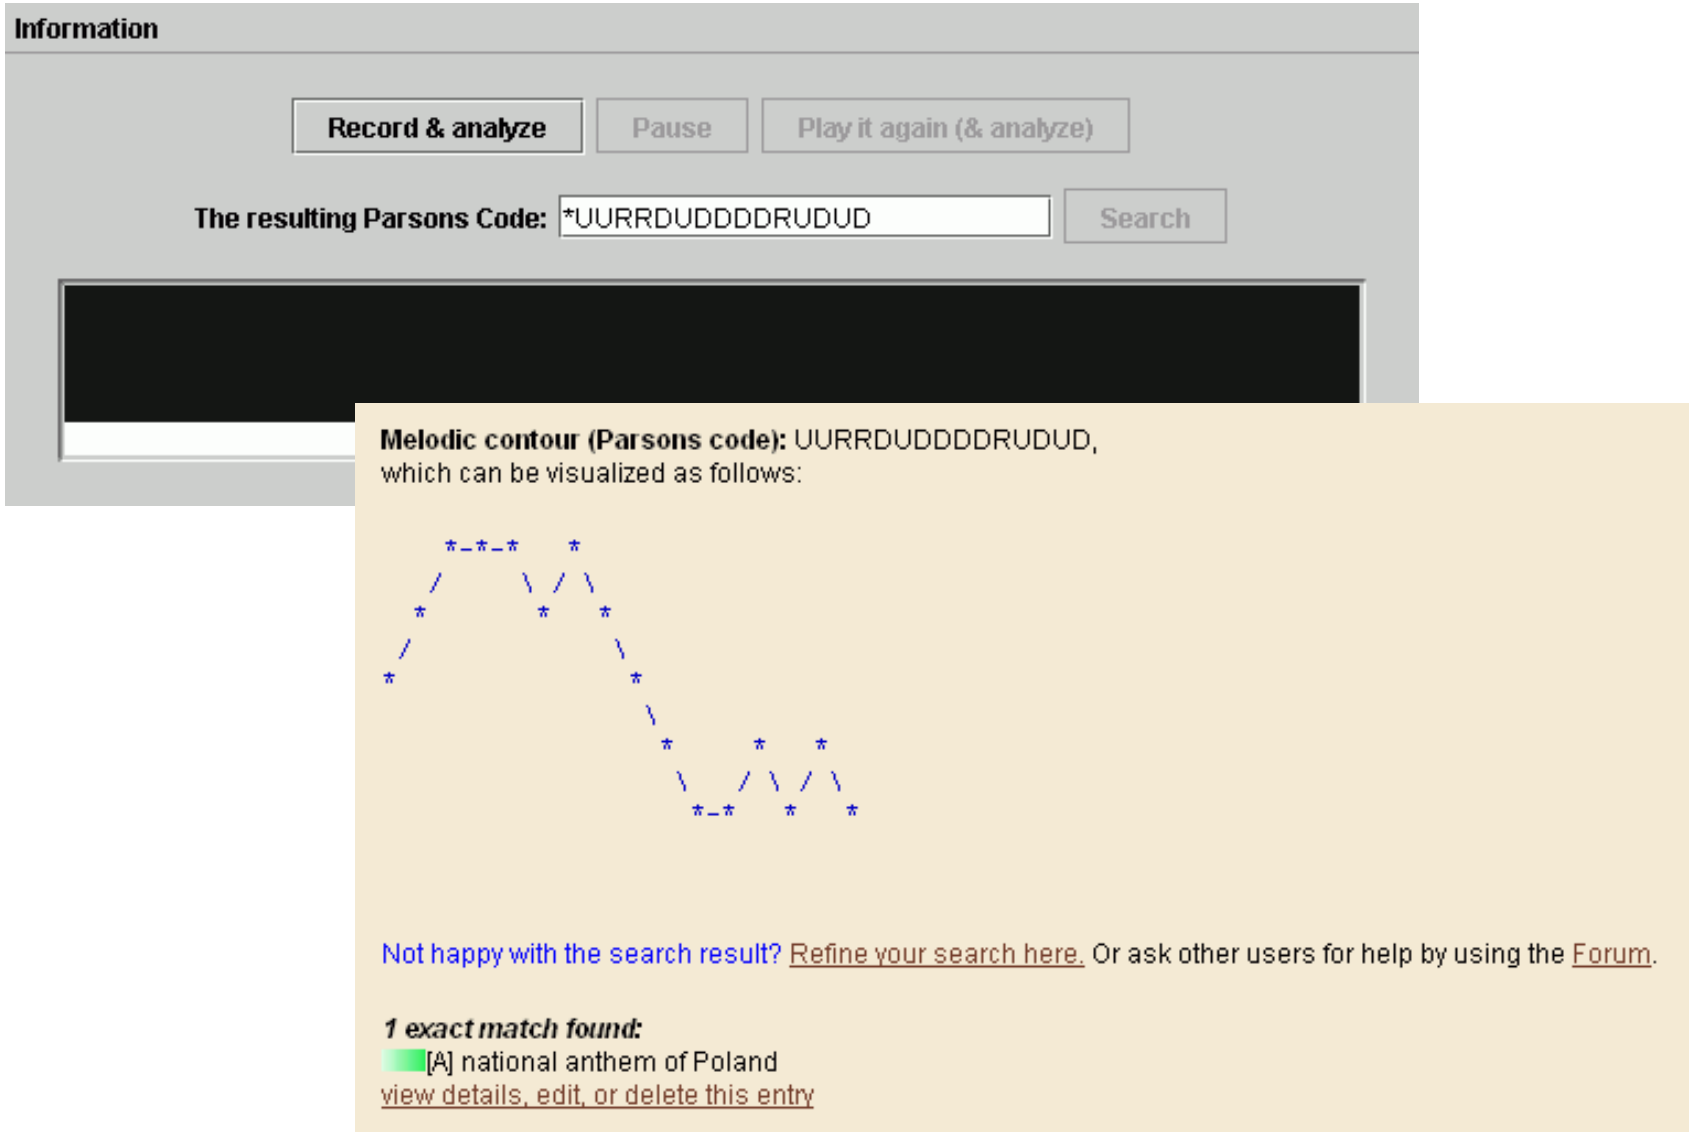

Musipedia - parametryzacja

Parametryzacja:

- podział sygnału na ramki
  (46 ms, zakładkowanie 50%)
- analiza widmowa każdej ramki (FFT) – decyzja:
  - sygnał – częstotliwość i amplituda maksimum
  - cisza
- ramki zawierające sygnał są łączone w nuty, rozdzielone ciszą lub gwałtowną zmianą częstotliwości
- częstotliwości nut zamieniane są na kod Parsonsa.

Parametry analizy mogą być ustawiane przez użytkownika.

Musipedia - wyszukiwanie

Wyszukiwanie danych w systemie Musipedia:

- obliczanie odległości między kodem Parsonsa szukanego nagrania a wszystkimi kodami zapisanymi w bazie danych
- miara odległości – ważona suma minimalnej liczby przekształceń kodu (wstawień, zamiany i usunięć znaków) potrzebnej do dokładnego dopasowania
- zwracana jest lista „najbliższych” elementów
- podawane są również informacje dodatkowe o utworze, jeżeli zostały wprowadzone do bazy (np. zapis nutowy, odnośnik do sklepu, itp.)

Musipedia - skuteczność

Skuteczność systemu Musipedia oceniana za pomocą zbioru testowego, przy gwizdaniu melodii:

- przy braku zakłóceń w sygnale wejściowym uzyskuje się średnią liczbę poprawnych odpowiedzi 4 na 5
- szum pochodzący od oddechu ma największy wpływ na skuteczność (szum ten jest filtrowany, parametry filtracji mogą być regulowane przez użytkownika)
- liczba nut mniejsza niż 8 znacząco pogarsza skuteczność
- najbardziej podatne na błędy w kodzie Parsonsa są elementy R (taka sama wysokość)
- najczęstsze zniekształcenia w kodzie Parsonsa to kody wstawienia (nieistniejące nuty)
- skuteczność zależy też od muzyki (uzyskano większą skuteczność dla muzyki klasycznej)

Midomi / SoundHound

Midomi – obecnie część systemu *SoundHound* (www.soundhound.com)

- jedyny komercyjny system wykorzystujący technologię QBH (nucenie, śpiewanie)
- oprócz tego umożliwia wyszukiwanie według przykładu oraz przez rozpoznawanie głosu (wypowiedzenie tytułu lub wykonawcy)
- baza QBH w 100% opracowana przez użytkowników
- technologia wyszukiwania nosi nazwę *Sound2Sound*
- aplikacje klienta dla urządzeń mobilnych

Midomi / SoundHound

Technologia rozpoznawania muzyki wykorzystuje m.in. informacje o:

- zmianach wysokości dźwięku,
- rytmie,
- położeniu pauz,
- zawartości fonetycznej,
- treści mowy.

Dane są wykorzystywane w zależności od typu zapytania. Np. treść mowy jest wykorzystywana przy śpiewaniu, a nie jest wykorzystywana przy nuceniu.

Wyszukiwanie jest niezależne od tonacji, tempa, języka i (do pewnego stopnia) jakości śpiewu.

Systemy MIR audio

Drugą grupę systemów MIR stanowią systemy, w których parametryzuje się:

- pliki dźwiękowe (np. mp3)
- strumień audio (np. z radia „na żywo”)

Systemy tego typu nazywa się czasami QBE (ang. *Query by Example* – zapytanie przez przykład).

Parametryzacja jest trudniejsza niż w QBH.

Philips Audio Fingerprinting

- *Philips Audio Fingerprinting Technology*
  – algorytm opracowany przez firmę Philips, służący do identyfikacji nagrań muzycznych :
  - przesyłanych w postaci strumienia (*on-air*),
  - przesłanych w postaci pliku
- Technologia komercyjna, dostarczana jako zestaw procedur (API) do zaimplementowania w oprogramowaniu klienta.
- System „klient-serwer”.
- Nie jest znana dokładna struktura algorytmów parametryzujących i wyszukujących dane.

Philips Audio Fingerprinting

- Oprogramowanie po stronie klienta oblicza sygnaturę (*fingerprint*, „odcisk palca”):
  - *sub-fingerprints* – obliczone na podstawie krótkich ramek czasowych (kilka ms)
  - *fingerprint blocks* – sygnatury złożone z 256 *sub-fingerprints* (ok. 3 sek.)
- *Fingerprint-blocks* są przesyłane do serwera, który dokonuje ich identyfikacji.
- Serwer przesyła identyfikator utworu (*Song ID*) oraz pozycję wewnątrz pliku, odpowiadającą sygnaturze.

Philips Audio Fingerprinting

Według autorów, system jest niewrażliwy na:

- zmniejszanie przepływności do 64 kbit/s,
- filtrację,
- dodawanie echa,
- przepróbkowanie,
- transpozycję,
- zaszumienie.

Wystarczy fragment o długości 3 s.

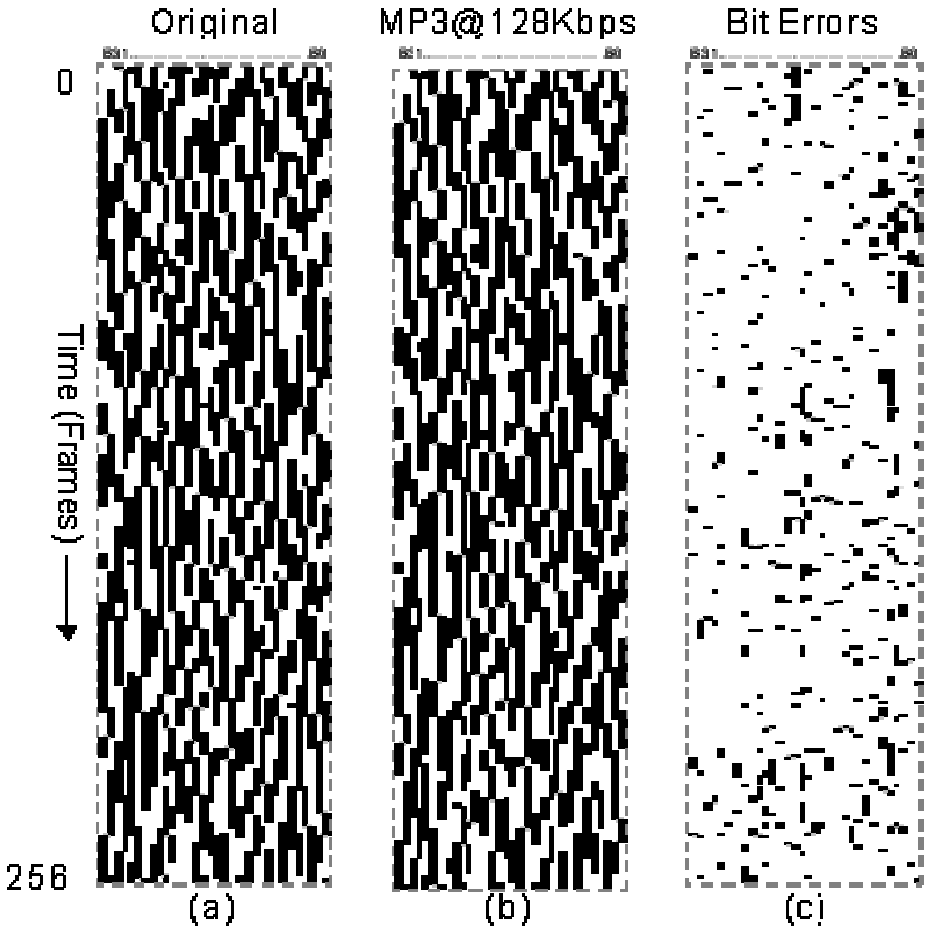

AcoustID / MusicBrainz

- AcoustID – system rozpoznawania muzyki, opracowany na licencji Open Source.
- Adres: acoustid.org
- Wykorzystuje algorytm parametryzacji o nazwie *Chromaprint*.
- Jest wykorzystywany m.in. w systemie *MusicBrainz* (www.musicbrainz.org) do opisywania (tagowania) plików muzycznych na podstawie zawartości.

Chromaprint

Krótki opis algorytmu:

- analizowane są pierwsze 2 minuty utworu,
- obliczenie widma (FFT),
- chromagram - analiza prowadzona dla 12 zakresów wysokości (*pitch classes*)
- zapis parametrów 8 razy na sekundę dla każdego zakresu
- postprocessing – usunięcie nadmiarowych danych przy zachowaniu wzorca

Chromaprint

Bardziej szczegółowy opis

(na podstawie: http://oxygene.sk/2011/01/how-does-chromaprint-work/)

Postać czasowa

Spektrogram

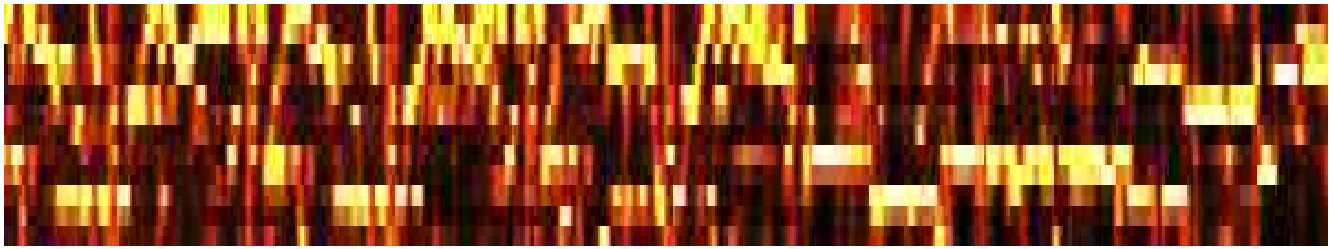

Chromagram

Chromaprint

Wyniki analizy – wykresy chromagramów uzyskane dla poszczególnych okien analizy, są parametryzowane za pomocą filtrów graficznych:

- 16 filtrów
- każdy daje wynik w postaci liczby od 0 do 3
- wynik zapisywany na dwóch bitach
- sumaryczny wynik: liczba 32-bitowa

Zbiór tych liczb dla kolejnych okien analizy stanowi wzorzec (*fingerprint*)

Chromaprint - przykład

Heaven FLAC

Heaven 32kbps MP3

Differences between Heaven FLAC and Heaven 32kbps MP3

Pierwszy utwór

Under The Ice FLAC

Under The Ice 32kbps MP3

Differences between Under The Ice FLAC and Under The Ice 32kbps MP3

Drugi utwór

Differences between Heaven FLAC and Under The Ice FLAC

Różnica obu utworów

Shazam

Shazam (www.shazam.com) – przykład popularnego, komercyjnego systemu typu *Query by Mobile Phone*

- aplikacje klienckie dla większości używanych systemów mobilnych
- strumień audio rejestrowany przez mikrofon
- według autorów, wystarcza nagranie o długości 1 sekundy (w praktyce do 15 s.)
- obliczony wzorzec przesyłany jest do serwera
- wyniki: dane o utworze, odnośniki do sklepów, informacje o wykonawcy, itp.

Shazam – zasada działania

Opis działania systemu Shazam w roku 2011
(na podstawie: http://www.soyoucode.com/2011/how-does-shazam-recognize-song)

Sposób wyznaczania wzorca:

- obliczenie spektrogramu
- wyznaczenie dominujących składowych

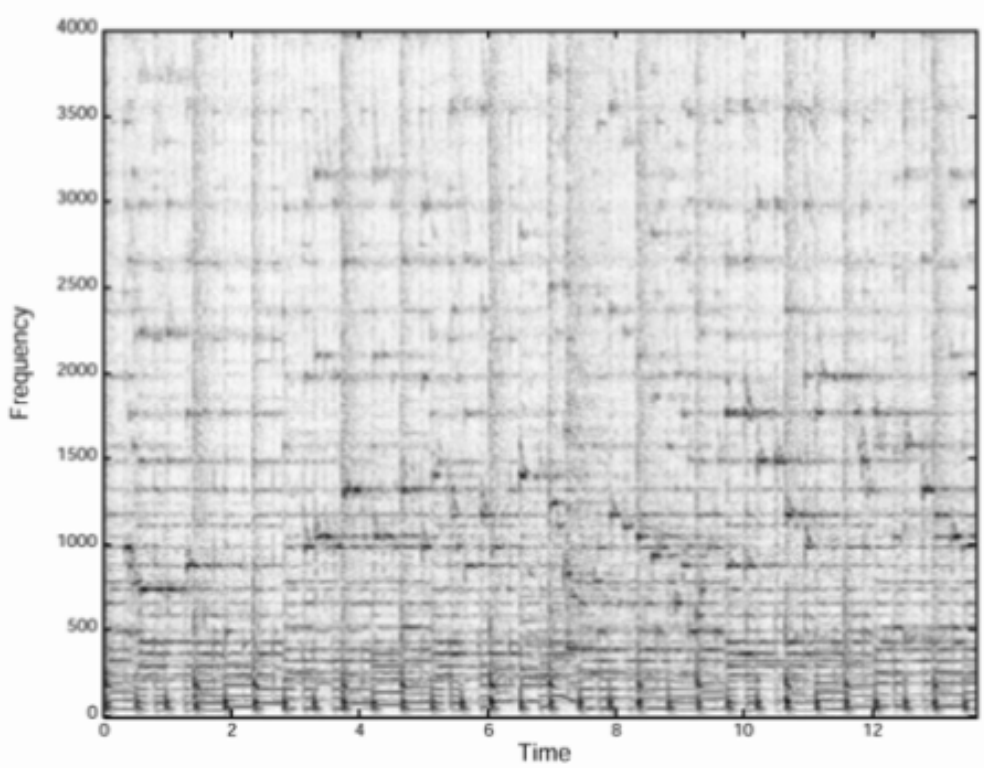

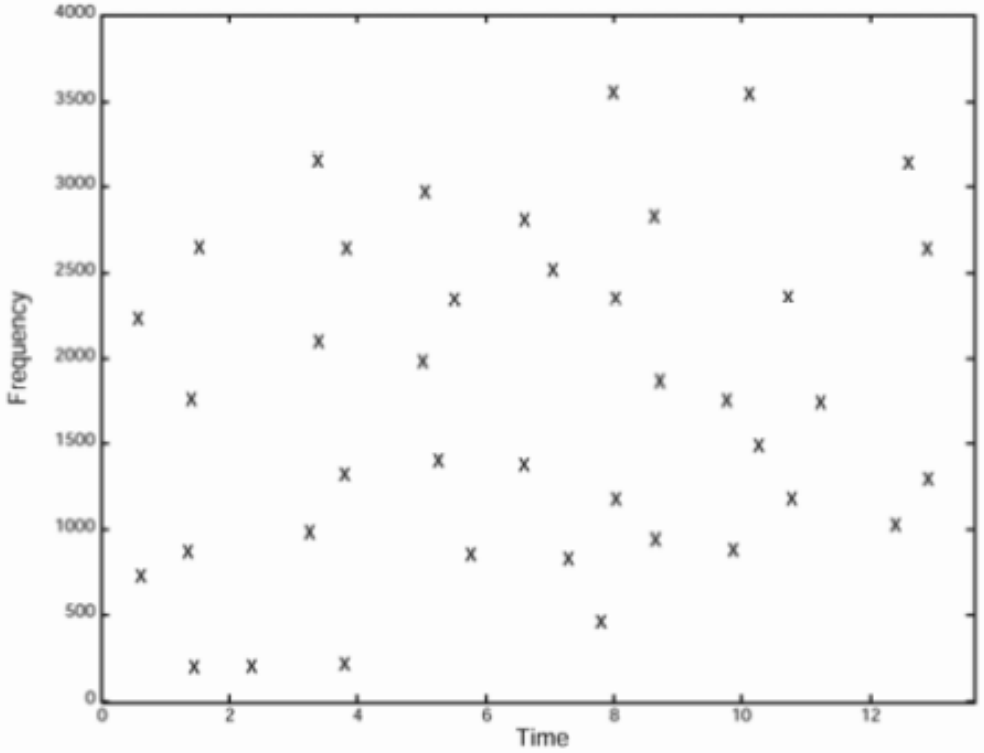

Shazam – zasada działania (cd.)

- Wybierane są punkty (*anchor points*) i strefy w ich pobliżu (*target zones*)
- Obliczane są odległości między punktem *anchor* i każdym z punktów w strefie
- Odległość zapisywana jako *hash*,
  np. punkty
  (t_1, f_1) i (t_2, f_2)
  hash =
  (f1+f2+(t2-t1))+t1
- Wszystkie hashe zapisywane we wzorcu

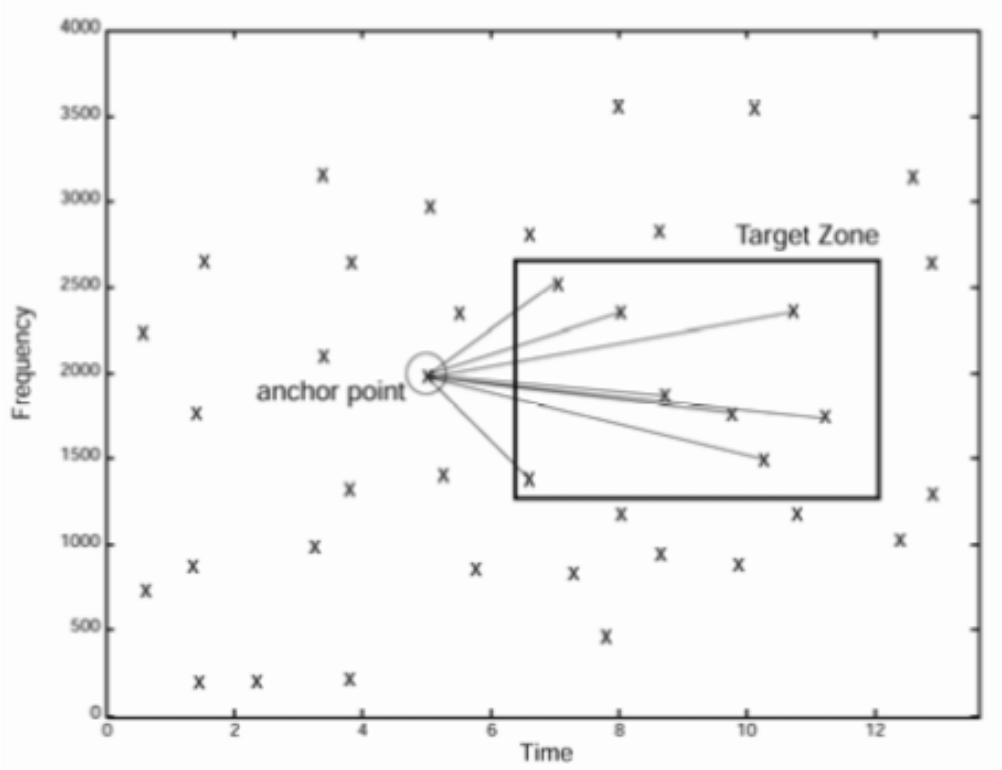

Shazam – zasada działania (cd.)

Wyszukiwanie:

- obliczenie wzorca dla wyszukiwanego utworu
- znalezienie pasujących hashów z obu wzorców
- zaznaczenie na wykresie (*scatter graph*) czasu wystąpienia dopasowania
- ciąg dopasowań tworzących linię prostą oznacza znalezienie dopasowania

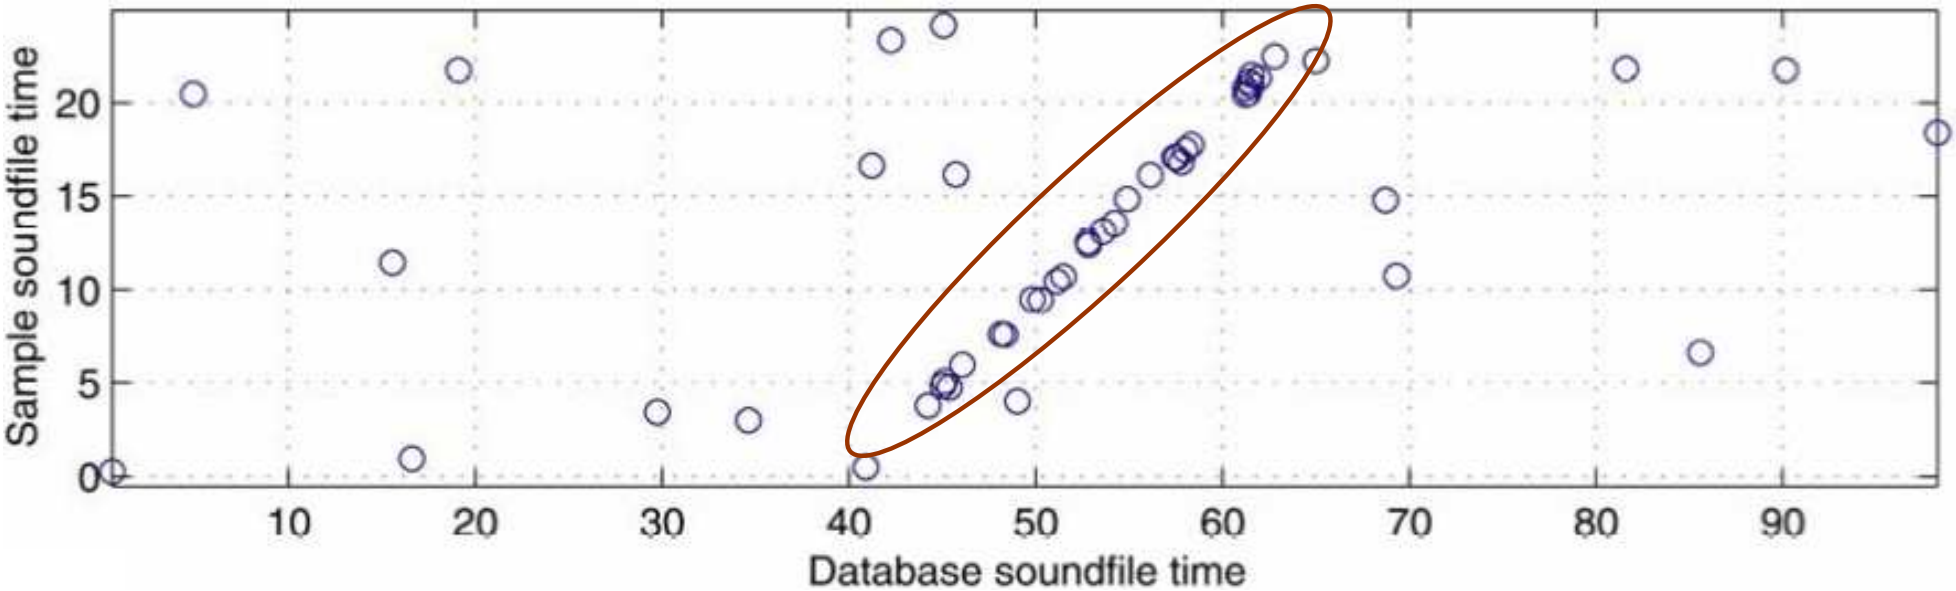

Shazam – zasada działania (cd.)

- Różnice czasu wystąpienia dopasowania są zaznaczano na histogramie.
- Wysoki słupek histogramu = stała różnica, zatem mamy dopasowanie utworu.

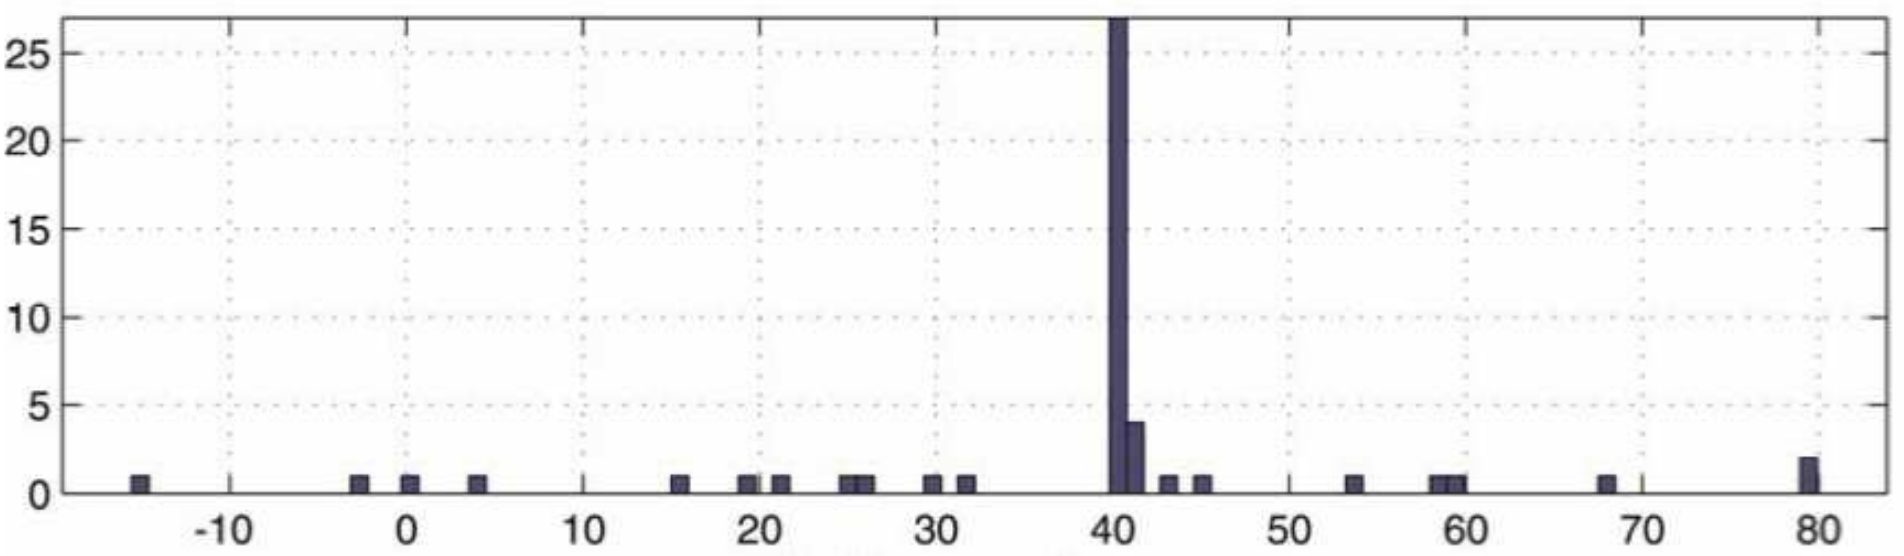

Opis na podstawie: http://www.soyoucode.com/2011/how-does-shazam-recognize-song