эксплуатации; несоответствие приводит к необходимости разработки новой техники

- б) Заданные требования можно обеспечить в структурах разных типов на основе серийных ЭВМ, причем для каждого типа существует несколько вариантов. Каждый вариант отличается по количеству ЭВМ или модулей и требованиям к их характеристикам, причем число устройств невелико: $2 \leq K \leq 5$.
- с) Расчет производительности для серийных средств приводит к значениям K больше 5.

По имеющимся выводам рассчитываем полную стоимость производства различных структур и выявляем более подходящую.

Для каждой из них производится расчет стоимости их построения и работы с ней.

Если сделан вывод о возможности применения варианта а), то такой вариант выбирается, однако при проверке условия $\Pi > \tilde{\Pi}_{max}$ следует предусматривать некоторый запас производительности и памяти (20-30%) для возможной модернизации системы.

Если сделан вывод о применении варианта б), то прежде всего следует оценить затраты. Для серийных ЭВМ или модулей их стоимости S известны и указаны в ценниках и прейскурантах. Затраты на эксплуатацию обычно рассчитывают по формуле:

$$S_{\text{экспл}} = c_э k_э + c_p k_p + c_з k_з,$$

где $c_э + c_p + c_з$ – стоимости энергии, ремонта и зарплата обслуживающего персонала соответственно; $k_э + k_p + k_з$ – коэффициенты пропорциональности.

Если сделан вывод о применении варианта с), то в этом случае решение можно принять только после анализа целесообразности разработки новых технических средств. Такая целесообразность может быть подтверждена только экономическими расчетами с учетом сроков разработки и фактора времени. Трудность заключается в том, что, естественно, соответствующих точных данным для проектируемых устройств нет и приходится использовать аппроксимации по малому числу точек и эмпирические оценки. Кроме того, возникает новая задача расчета рационального количества основных устройств ИВК.

1. Я.А. Хетагуров, Ю.Г. Древс «Проектирование информационно-вычислительных комплексов»: Учеб. для вузов по спец. "АСУ". - М.: Высш. шк., 1987. - 280 с.
2. Гордеев А.В. «Операционные системы. 2-е изд.» / СПб.: Питер, 2004. – 415с.
3. Бурдонов И. Б., Косачев А. С., Пономаренко В. Н. «Операционные системы реального времени»/ Институт системного программирования РАН, 2006. - 98с.
4. Жмакин А. П. «Архитектура ЭВМ: 2-е изд.», перераб. и доп.: учеб. пособие. — СПб.: БХВ-Петербург, 2010. - 352 с

Колесников Р.А.

Жанровая классификация музыки с помощью акустических признаков

*Российский технологический университет МИРЭА
(Россия, Москва)*

doi: 10.18411/lj-05-2021-13

Аннотация

В статье рассмотрены аудио признаки, которые наиболее часто используются в анализе и классификации аудио и представлен план разработки и краткий пример жанрового классификатора на языке программирования Python.

Ключевые слова: аудиоанализ, аудио, классификация аудио, нейронные сети.

Abstract

The article discusses the indicators most often used in analyzes and presented development plans and presents an example of how a genre classifier works in the Python programming language.

Key words: audio analysis, audio, audio classification, neural network.

Аудиоанализ это область, относящаяся к извлечению информации и признаков из аудиосигналов для анализа, классификации, хранения, поиска, синтеза и т.д. Большинство алгоритмов классификации музыкальных жанров прибегают к так называемому методу извлечения характеристик.

Описанные ниже спектральные признаки наиболее часто встречаются в решениях проблем классификации или определения аудио.

Скоростью пересечения нуля называют частоту изменения знака сигнала, т. е. частоту, с которой сигнал меняется с положительного на отрицательный и обратно в определенный промежуток времени (чаще всего 1 секунда). Данный признак наглядно демонстрирует количество ударных и присутствие человеческой речи в музыке. В тяжелых жанрах музыки (рок, метал) этот показатель выше, чем в других жанрах.

Спектральный центроид определяется как:

$$SC = \frac{\sum_{n=1}^N (n+1) * X_i(n)}{\sum_{n=1}^N X_i(n)} \quad (1)$$

где $X_i(n)$ – коэффициент дискретного Фурье-преобразования последовательности $x_i(n)$, $n = 1..N$.

Спектральный центроид позволяет определить частоту в которой находится центр масс спектра в конкретном кадре. Данный признак часто описывают как «яркость» звука.

Спектральная ширина определяет самые значимые и связанные частоты для спектрального центроида. Это определение тесно коррелируется с определением воспринимаемого тембра. В EDM и рок-музыке данный параметр будет намного выше из-за большего и богатого диапазона частот в перегруженных гитарах и синтезаторах, чем в классической или акустической музыке, где инструменты не искажены и не перегружены эффектами.

Спектральный контраст представляет собой разницу в децибелах между пиком и нулевой точкой на спектре сигнала. При обработке звука он дает информацию об изменениях его мощности.

Мел-кепстральные коэффициенты это набор признаков, содержащие в себе информацию о формантах, спектральной огибающей и т.д.

На рисунке 1 представлена визуализация в виде 13 строк этих признаков, где числовые значения для каждого кадра представлены в виде разных цветов.

Рисунок 1. График мел-кепстральных коэффициентов

Признак или вектор цветности обычно представлен вектором признаков из 12 элементов, в котором указано количество энергии каждого высотного класса {C, C#, D, D#, E, ..., B} в сигнале. Используется для описания меры сходства между музыкальными произведениями.

Рисунок 2. График вектора цветности

Для разработки музыкального классификатора была выбрана сверточная нейронная сеть.

Работа свёрточной нейронной сети обычно интерпретируется как переход от конкретных особенностей изображения к более абстрактным деталям, и далее к ещё более абстрактным деталям вплоть до выделения понятий высокого уровня. При этом сеть самонастраивается и вырабатывает сама необходимую иерархию абстрактных признаков (последовательности карт признаков), фильтруя маловажные детали и выделяя существенное.

Для реализации алгоритма выбраны библиотеки Keras, TensorFlow, Pandas. Для извлечения аудио признаков была использована библиотека librosa.

Работа алгоритма будет осуществляться в бесплатном облачном сервисе Google Colab на основе Jupyter Notebook, предоставляющий все необходимое для машинного обучения. Плюсами этого сервиса является скорость исполнения алгоритмов, позволяющая выполнять продолжительные операции и обучение сети за короткий промежуток времени прямо в браузере, а также все предустановленные библиотеки необходимые для реализации и удобная синхронизация с Google Drive.

Для обучения системы определения жанра будет использована база данных GTZAN Genre Collection которая состоит из 1000 звуковых треков, длина каждого составляет 30 секунд. Он содержит 10 жанров, каждый из которых представлен 100 треками. Все дорожки — это монофонические 16-битные аудиофайлы 22050 Гц в формате .wav.

Для сверточной нейронной сети была сформирована следующая конфигурация:

- 2D Convolution Layer, 5x5 sized 32 filters, LeakyReLU activation function
- Max Pooling Layer
- 2D Convolution Layer, 5x5 sized 32 filters, LeakyReLU activation function
- Max Pooling Layer
- 2D Convolution Layer, 5x5 sized 32 filters, LeakyReLU activation function
- Max Pooling Layer
- 2D Convolution Layer, 5x5 sized 32 filters, LeakyReLU activation function
- Average Pooling Layer
- Flatten Layer
- Dense Layer, 256 nodes, LeakyReLU activation function
- Dense Layer, 128 nodes, LeakyReLU activation function

- Dense Layer, 64 nodes, LeakyReLU activation function
- Dense Layer, 10 nodes, Softmax activation function, as output layer

В данной статье были рассмотрены аудио признаки, и представлен краткий пример жанрового классификатора на языке Python.

1. Сорокин А.Б. Искусственные нейронные сети прямого распространения: учебно-методическое пособие / Сорокин А.Б., О.В. Платонова. – М.: МИРЭА – Российский технологический университет, 2018. – 68с (дата обращения: 05.03.2021)
2. Д. С. Муzychuk. Сегментация, шумоподавление и фонетический анализ в задаче распознавания речи [Электронный ресурс] URL: <https://moluch.ru/archive/53/7058/> (дата обращения: 07.03.2021).
3. Nizamettin Aydin. Music Genre Classification and Recommendation by Using Machine Learning Techniques / Ahmet Elbir, Hilmi Bilal Cam, Mehmet Emre Iyican, Berkay Ozturk, Nizamettin Aydin. (дата обращения 6.04.2021)
4. Nagesh Singh Chauhan. Audio Data Analysis Using Deep Learning with Python (Part 1) [Электронный ресурс] URL: <https://www.kdnuggets.com/2020/02/audio-data-analysis-deep-learning-python-part-1.html/> (дата обращения 15.04.2021)

Кочкарова П.А., Катчиева А.К.

Цифровизация банковского сектора Российской Федерации в условиях цифровой трансформации экономики

*ФГБОУ ВО «Северо-Кавказская государственная академия»
(Россия, Черкесск)*

doi: 10.18411/lj-05-2021-14

Аннотация

Цифровая трансформация банков относится к важнейшим задачам преобразования национальной экономики в целях движения страны к лидирующим позициям во всех сферах общественной жизни. В статье рассматриваются предпосылки внедрения цифровых технологий в банковский сектор, анализируется текущий уровень цифровизации российских банков.

Ключевые слова: цифровизация, цифровая экономика, банковский сектор, цифровые технологии, искусственный интеллект.

Abstract

The digital transformation of banks is one of the most important tasks of transforming the national economy in order to move the country to leading positions in all spheres of public life. The article discusses the prerequisites for the introduction of digital technologies in the banking sector, analyzes the current level of digitalization of Russian banks.

Keywords: digitalization, digital economy, banking sector, digital technologies, artificial intelligence.

В настоящее время информационные технологии активно проникают во все сферы деятельности человека. Процесс цифровизации является одним из современных тенденций развития общества и важнейшим показателем развития страны.

Особая роль в данном процессе отводится банковскому сектору, который активно внедряет в свою работу новые инновационные решения, служащие в дальнейшем катализаторами цифровизации в других отраслях экономики.

Уровень цифровизации российского банковского сектора на данный момент достаточно высок и по своим показателям практически не отстает от наиболее развитых экономик мира. Согласно данным компании КПМГ 86 % российских банков уже внедряют в свою деятельность программу цифровой трансформации.