



биение веб-приложения на компоненты позволяет сократить дублирование кода между модулями, что дополнительно уменьшает и скомпилированный объём.

Итогом исследования является программный комплекс, который заранее предугадывает возможные пути посещения веб-приложения и заранее осуществляет предварительную загрузку модулей и компонентов. Тем самым, при переходе на конкретный «экран» приложения, у пользователя будет отсутствовать время ожидания, так как данные были загружены заранее. А совместно с не самой сложной в поддержке и отладке моделью для принятия предиктивных решений, мы получим и кодовую базу с умеренным порогом вхождения.

### Литература

- 1 Banu Deniz Gunel, "Investigating the Effect of Duration, Page Size and Frequency on Next Page Recommendation with Page Rank Algorithm", [Текст], 2010
- 2 Borges, Levene, "Evaluating Variable-Length Markov Chain Models for Analysis of User Web Navigation Sessions", [Текст], 2007
- 3 [https://en.wikipedia.org/wiki/Predictive\\_analytics](https://en.wikipedia.org/wiki/Predictive_analytics) [Электронный ресурс]
- 4 [https://en.wikipedia.org/wiki/Hidden\\_Markov\\_model](https://en.wikipedia.org/wiki/Hidden_Markov_model) [Электронный ресурс]

Н.Д. Беляев, И.А. Лёзин

## ИЗВЛЕЧЕНИЕ ПРИЗНАКОВ АУДИОСИГНАЛА ПРИ РЕШЕНИИ ЗАДАЧИ РАСПОЗНАВАНИЯ ЭМОЦИЙ В РЕЧИ ДИКТОРА

(Самарский университет)

### Введение

Речь – это основное средство передачи информации. Но не только слова содержат информацию. Мы также можем узнать много о ситуации, событии и т.д. из эмоций человека. Поэтому распознавание эмоций в голосе и мимике человека стало занимать одно из первых мест в различных отраслях сферы информационных технологий.

Акустические сигналы являются наиболее часто используемыми данными после мимических признаков для определения эмоционального состояния человека.

В этой статье мы рассмотрим использование относительно новой характеристики Harmonic To Noise Rate (HNR) в нашей системе распознавания эмоций с комбинацией других характеристик, таких как коэффициенты MFCC, ZCR и TEO. Последние 3 характеристики наиболее популярны в сфере распознавания аудиосигналов и, как правило, показывают хорошие результаты при решении любой связанной задачи.



## Алгоритмы извлечения признаков

### 1. MFCC

Чтобы вычислить коэффициенты MFCC, обратное быстрое преобразование Фурье применяется к логарифму модуля быстрого преобразования Фурье сигнала, отфильтрованного по шкале Мела [15].

Исходный речевой сигнал запишем в дискретном виде как:

$$x[n], \quad 0 \leq n < N \quad (1)$$

Применяем к нему преобразование Фурье:

$$X_a[k] = \sum_{n=0}^{N-1} x[n] e^{-\frac{2\pi i}{N} kn}, \quad 0 \leq k < N \quad (2)$$

Составляем гребенку фильтров, используя оконную функцию:

$$H_m = \begin{cases} 0 & k < f[m-1] \\ \frac{(k-f[m-1])}{(f[m]-f[m-1])} & f[m-1] \leq k < f[m] \\ \frac{(f[m+1]-k)}{(f[m+1]-f[m])} & f[m] \leq k \leq f[m+1] \\ 0 & k > f[m+1] \end{cases} \quad (3)$$

Для которой частоты  $f[m]$  получаем изравенства:

$$f[m] = \left(\frac{N}{F_s}\right) B^{-1}\left(B(f_1) + m \frac{B(f_h) - B(f_1)}{M+1}\right) \quad (4)$$

$B(b)$  — преобразование значения частоты в мел-шкалу, соответственно:

$$S[m] = \ln\left(\sum_{k=0}^{N-1} |X_a[k]|^2 H_m[k]\right), \quad 0 \leq m < M \quad (5)$$

Вычисляем энергию для каждого окна:

$$B^{-1}(b) = 700(\exp(b/1125) - 1) \quad (6)$$

Применяем ДКП:

$$c[n] = \sum_{m=0}^{M-1} S[m] \cos(\pi n(m+1/2)/M), \quad 0 \leq n < M \quad (7)$$

Получаем набор MFCC.

### 2. ZCR

ZCR - это скорость, с которой сигнал изменяется с положительного значения до нуля и до отрицательного значения или наоборот. [1] Его значение широко использовалось как для распознавания речи, так и для поиска музыкальной информации, являясь ключевой функцией для классификации ударных звуков [2].

ZCR формально определяется как:

$$zcr = \frac{1}{T-1} \sum_{t=1}^{T-1} 1_{\mathbb{R}<0}(s_t s_{t-1}) \quad (8)$$

где  $s$  - сигнал длины  $T$ , а  $1_{\mathbb{R}<0}$  - индикаторная функция.



### 3. ТЕО

Функции Teager Energy Operator (ТЕО) проверяют характеристики речи, когда высказывание представляет собой определенного вида стресс. Функции ТЕО обрабатывают поведение сигнала по частоте и во временной области.

Для оценки ТЕО каждый выходной сигнал М-сигнала сегментируется на кадры одинаковой длины (например, 25 миллисекунды со смещением кадра 10 миллисекунд); где М - количество критических зон, а f – количество кадров, для которого извлекается ТЕО. В нашей работе мы извлекаем ТЕО из суммы сигналов по следующей формуле:

$$\Psi_M [x_f [t]] = (x_f [t])^2 - (x_f [t-1] x_f [t+1]) \quad (9)$$

### 4. Harmonic To Noise Rate

По определению HNR - это параметр, в котором взаимосвязь между гармоническими и шумовыми компонентами обеспечивает указание локализованных компонентов речевого сигнала путем количественной оценки взаимосвязи между периодической и аperiodической составляющими, выраженной в дБ [1] [3] [4]. Общее значение HNR сигнала варьируется, потому что разные конфигурации речевого тракта подразумевают разные амплитуды гармоник. Эта единица измерения связывает энергию, передаваемую голосовым сигналом через голосовые импульсы, и энергию фракции голосового шума после фильтрации через голосовой тракт. Этот шум возникает из-за турбулентности, возникающей при прохождении воздушного потока через голосовую щель во время фонации, возникающей, например, когда голосовые связки смыкаются ненадлежащим образом [4].

Существуют различные подходы к автоматическому определению HNR, например использовали кепстр для измерения гармонических и шумовых составляющих, в то время как [4] использовали автокорреляцию. С математической точки зрения звонкий сигнал с гармонической структурой в частотной области может быть выражен уравнением 10.

$$X(w) = H(w) + N(w) \quad (10)$$

Где X (w) соответствует речевому сигналу в частотной области, H (w) - гармонической составляющей, а N (w) - шумовой составляющей.

HNR - это логарифмическая мера отношения энергии, которое связано с гармонической и шумовой составляющими. С помощью уравнения 11 можно интегрировать спектральную мощность по слышимому диапазону частот.

$$HNR = 10 \times \log_{10} \frac{\int_w |H(w)|^2}{\int_w |N(w)|^2} \quad (11)$$



В этом алгоритме HNR был реализован с учетом исследований, опубликованных Voersma [4]. В этом исследовании Боерсма использует процедуру, основанную на свойствах автокорреляционной функции, чтобы получить разделение компонентов, описанное ранее. Автокорреляция состоит из корреляции сигнала с самим собой. Если мы рассмотрим голосовой сигнал  $x(t)$ , функция автокорреляции  $r_x(\tau)$  представлена в уравнении 12.

$$r_x(\tau) \equiv \int x(t)x(t+\tau)dt. \quad (12)$$

В этой функции есть глобальный максимум при  $\tau = 0$ . Если есть пиковые значения вне 0, сигнал периодический и есть фазовый сдвиг  $T_0$ , называемый периодом, так что все эти максимумы помещаются в смещение  $nT_0$  для каждого целого числа  $n$ , с  $r_x(nT_0) = r_x(0)$ . Основная частота  $F_0$  этого периодического сигнала определяется соотношением  $F_0 = 1 / T_0$ . Если нет глобальных максимумов, кроме 0, могут быть максимальные пики. Если наибольший из них находится в смещении  $\tau_{\max}$ , и если его высота  $r_x(\tau_{\max})$  достаточна, сигнал обозначается как имеющий периодическую часть, а его гармоническая сила  $R_0$  - это число от 0 до 1, равное локальному максимуму  $r'_x(\tau_{\max})$  нормированной автокорреляции (уравнение 13).

$$r'_x(\tau) \equiv \frac{r_x(\tau)}{r_x(0)} \quad (13)$$

Полная автокорреляция сигнала представляет собой сумму автокорреляции его гармонической и шумовой составляющих, как можно увидеть в уравнении 14.

$$r_x(0) = r_H(0) + r_N(0) \quad (14)$$

Если шум белый (корреляция невозможна), локальный максимум равен  $\tau_{\max} = T_0$  с высотой  $r_x(\tau_{\max}) = r_H(T_0) = r_H(0)$  [4]. При этом автокорреляционная функция устойчивого речевого сигнала отображает локальные максимумы для нескольких значений  $\tau$ , которые все кратны основному периоду. Таким образом, для определения HNR необходимо только вычислить автокорреляционную функцию речевого сигнала и идентифицировать первый локальный максимум, который будет соответствовать гармонической составляющей. Величина шумовой составляющей определяется уравнением 6, а HNR - уравнением 15.

$$HNR(dB) = 10 \times \log_{10} \frac{r'_x(\tau_{\max})}{1 - r'_x(\tau_{\max})} \quad (15)$$



### Литература

- 1 А.Мерибан Communication without words[Текст]/А. Мерибан. – 1968. – С. 53-56.
- 2 Б. Фасель, Д. Лютин, Automatic Facial Expression Analysis: A Survey, Pattern Recognition[Текст]/ Б. Фасель, Д. Лютин. – 2003. - С. 259-275.
- 3 К. Рао,Т. Кумар, К. Ануша, Emotion Recognition from Speech – 2012. - (<https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.437.2775&rep=rep1&type=pdf>)
- 4 И. Саксмит., С. Алиссон, С. Барон-Коэн, Empathy and emotion recognition in people with autism, first-degree relatives, and controls[Текст]/ И. Саксмит., С. Алиссон, С. Барон-Коэн – 2013. – С. 98-105.

А.Д. Божимов, О.П. Солдатова

## ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ СЖАТИЯ МОДЕЛИ НЕЙРОННОЙ СЕТИ ДЛЯ ПЕРЕДАЧИ ПРОИЗВОЛЬНОГО СТИЛЯ ИЗОБРАЖЕНИЯ

(Самарский университет)

Современные реалии всё чаще подталкивают нас к использованию нейронных сетей при решении обширного диапазона задач. Одним из направлений, где реализация алгоритма средствами классического программирования является труднореализуемой или и вовсе невыполнимой, является художественное творчество. Развитие технологий машинного обучения позволило появиться успешным попыткам воссоздания уникальных особенностей художественных произведений техническими средствами. Это обусловлено в первую очередь способностью моделей к «обучению» - процессу, где нейронная сеть должна выявлять сложные зависимости между входными и выходными данными [1].

Большинство существующих алгоритмов переноса стиля изображения требуют отдельного обучения сети и создания новой модели для работы с каждым новым стилем. Это накладывает серьезные ограничения на используемое аппаратное обеспечение, а также увеличивает затраты времени [2]. Оптимальным решением было бы иметь модель, которая способна выполнять быструю передачу стиля на любых парах изображения, не требуя переобучения.

Рассматриваемый процесс переноса произвольного стиля изображения состоит из двух этапов: получение вектора стиля из одного изображения и стилизация другого на основе векторизованных данных.

Для выделения стиля на первом этапе используется сеть предсказания, создающая на выходе 100-мерный вектор. Такой подход позволяет также комбинировать стили, используя средневзвешенное значение [3].

На втором этапе стилизации применяется сеть переноса стиля, принимающая чистое изображение и вектор представления стиля и на выходе создаю-