

**САНКТ-ПЕТЕРБУРГСКИЙ  
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ**

**Математико-Механический факультет  
Кафедра Системного Программирования**

**Алгоритм верификации диктора для  
встроенных систем**

**Курсовая работа студента 344 группы  
Абрамова Ивана Александровича**

*Научный руководитель:  
аспирант КОРОЛЕВ А. И.*

Санкт-Петербург  
2014 г.

# Содержание

<b>1 Введение</b>	<b>3</b>
1.1 Область исследований . . . . .	3
1.2 Постановка задачи . . . . .	4
<b>2 Процесс верификации</b>	<b>5</b>
2.1 Цель . . . . .	5
2.2 Схема процесса верификации . . . . .	5
<b>3 Предобработка входных данных</b>	<b>7</b>
3.1 Извлечение информативных признаков . . . . .	7
3.2 Выделение речевых данных . . . . .	7
<b>4 Построение модели диктора</b>	<b>8</b>
4.1 Gaussian Mixture Model . . . . .	8
4.2 Описание модели GMM . . . . .	8
4.3 Настройка параметров GMM . . . . .	8
<b>5 Адаптация модели диктора</b>	<b>10</b>
5.1 Universal Background Model . . . . .	10
5.2 Адаптация модели диктора с использованием UBM . . . . .	10
5.3 Hidden Markov Model . . . . .	11
5.4 Адаптация модели диктора с использованием НММ . . . . .	11
<b>6 Принятие решения о верификации</b>	<b>12</b>
<b>7 Реализация</b>	<b>13</b>
<b>8 Результаты</b>	<b>15</b>

# 1 Введение

В современном мире достаточно остро стоит вопрос защиты информации. Компании желают обезопасить себя от несанкционированного доступа к данным. Поэтому для аутентификации пользователя в системе хочется использовать не только символьный пароль, но и биометрические данные, такие как голос, отпечатки пальцев, сетчатку глаза. Использование голосовых данных мотивировано тем, что нет необходимости оснащать защищаемую систему дополнительным оборудованием. У большинства устройств уже имеется встроенный микрофон, с которого можно записывать речевые данные. Представленный подход реализован компанией Nuance<sup>1</sup> и успешно применяется для подтверждения транзакций в банках или для получения доступа к информации в сфере здравоохранения.

Не смотря на то, что идея внедрения систем защиты, использующих голосовую информацию набирает популярность с каждым годом, готовых решений, предоставляющих требуемую функциональность для встроенных систем, ещё нет. Во многом это связано с тем, что традиционные методы верификации диктора не дают приемлемую точность распознавания для задач с ограниченным количеством входных данных[1]. Использование существующих библиотек для распознавания диктора, таких как [2, 3], осложнено из-за того, что данные средства не учитывают архитектурные особенности встроенных систем.

## 1.1 Область исследований

Задача верификации диктора заключается в том, чтобы определить по звуковому сигналу, является ли говорящий тем, за кого он себя выдает, или нет. Для решения поставленной задачи существует несколько основных подходов:

- Текстонезависимый подход
- Тектозависимый подход

Текстонезависимый подход применяется в случаях, когда система верификации не обладает информацией о том, какую фразу должен произнести диктор. Такой подход чувствителен к количеству речевого материала, необходимого при обработке. Эффективность данного решения заметно ухудшается при использовании записей длительностью менее 30-ти секунд[1].

Тектозависимый подход, напротив, основывается на начальном знании фразы-пароля. Данный подход часто используется при распознавании речи и моделировании отдельных предложений и слов. Тектозависимый подход предоставляет информацию о временной структуре фразы, используя которую можно улучшить эффективность текстонезависимого решения[4].

---

<sup>1</sup>Nuance Communications Corporation - ведущий разработчик и поставщик речевых технологий. <http://www.nuance.com> (дата обращения: 15.03.2014).

## **1.2 Постановка задачи**

В рамках данной работы были поставлены следующие задачи:

- Изучить существующие методики верификации диктора
- Реализовать текстонезависимый алгоритм верификации диктора и улучшить его, используя текстозависимый подход
- Интегрировать средства для извлечения векторов признаков
- Интегрировать средства для выделения речевой активности
- Создать интерфейс для начального тестирования
- Протестировать систему верификации на речевом корпусе
- Определить оптимальные параметры разработанной системы

## 2 Процесс верификации

### 2.1 Цель

Допустим, что есть речевой сегмент  $Y$  и диктор  $S$ . Необходимо определить, был ли  $Y$ 所说由 диктором  $S$  или нет. Будем предполагать, что  $Y$  содержит речь только одного диктора.

Можем переформулировать задачу, определив гипотезы:

- $H_0$ :  $Y$ 所说由 диктором  $S$
- $H_1$ :  $Y$ 所说由 не диктором  $S$

Чтобы принять одну из представленных гипотез, мы должны рассмотреть отношение

$$\frac{p(Y|H_0)}{p(Y|H_1)} = \begin{cases} \geq \theta & \text{принимаем } H_0 \\ < \theta & \text{принимаем } H_1 \end{cases} \quad (1)$$

где  $p(Y|H_i)$ ,  $i = 0, 1$ , значение вероятностной функции плотности при условии гипотезы  $H_i$ , посчитанная для речевого сегмента  $Y$ , которая далее будет называться функцией правдоподобия, а  $\theta$  пороговое значение, которое определяет выбор гипотезы. Значение  $\theta$  рассчитывается и калибруется отдельно[5]. Система верификации диктора должна предоставить методику вычисления значения  $p(Y|H_i)$ ,  $i = 0, 1$ , для любого речевого сегмента  $Y$ , для любого диктора  $S$ .

### 2.2 Схема процесса верификации




Рис. 1: Общая схема процесса верификации

Процесс верификации диктора можно разбить на две стадии:

- Построение эталонной модели
- Сравнение эталонной модели с тестовым произнесением

Этапы стадии построения эталонной модели:

1. Выделение речевой активности
2. Извлечение информативных признаков
3. Построение и адаптация модели диктора

Этапы стадии сравнения эталонной модели с тестовым произнесением:

1. Выделение речевой активности
2. Извлечение информативных признаков
3. Сравнение модели диктора и входящих данных
4. Принятие решения о верификации

### **3 Предобработка входных данных**

#### **3.1 Извлечение информативных признаков**

Одним из основных компонентов системы по распознаванию или верификации диктора является процесс извлечения полезной информации из звукового сигнала. Применяя частотные фильтры к участку исходной записи получаем параметры, описывающие данный участок, из которых формируется вектор признаков[6]. Популярным решением для генерации векторов признаков является подход, использующий мел-кепстральные коэффициенты - MFCC (Mel-Frequency Cepstral Coefficients)[7]. Вектор признаков, характеризующий звуковой фрагмент, составляется из величины энергии, MFC коэффициентов, и их первой и второй производной. Рассматриваемые вектора признаков предоставляют достаточное количество информации о звуковом сигнале[8], поэтому было принято решение использовать их для последующего анализа и моделирования.

#### **3.2 Выделение речевых данных**

Для того, чтобы система по верификации диктора предоставляла стабильный результат для звуковых записей, сделанных в различных шумовых обстановках, необходимо пройти этап предобработки входных данных. Применение детектора речевой активности предоставит возможность разметить данные на речевые и неречевые сегменты. Раздельная обработка описанных сегментов позволит улучшить результат верификации[9].

## 4 Построение модели диктора

### 4.1 Gaussian Mixture Model

Основываясь на опыте и результатах исследований, представленных в работах [4, 5, 10] для создания модели, характеризующей диктора и сказанную им фразу, был выбран метод, использующий вероятностную модель, построенную на гауссовых смесях (GMM, Gaussian Mixture Model). Преимущество данной модели заключается в способности точно описывать распределение векторов акустических признаков.

### 4.2 Описание модели GMM

GMM модель состоит из  $M$  компонент. Каждая компонента характеризуется: весом  $p_i$ , математическим ожиданием  $\mu_i$  размерности  $D \times 1$ , матрицей ковариации  $\Sigma_i$  размерности  $D \times D$ , где  $i = 1, \dots, M$ , а  $D$  - длина вектора признаков. Будем обозначать GMM модель говорящего  $\lambda$ , где

$$\lambda = \{p_i, \mu_i, \Sigma_i\} \quad i = 1, \dots, M. \quad (2)$$

Функция плотности GMM вычисляется как взвешенная сумма плотностей  $M$  компонент её составляющих

$$p(\vec{x}) = \sum_{i=1}^M p_i b_i(\vec{x}) \quad (3)$$

где  $\vec{x} \in X = \{\vec{x}_1, \dots, \vec{x}_T\}$  - совокупность векторов признаков, построенных по произношению  $Y$ ;  $i = 1, \dots, M$ ; веса  $p_i$  удовлетворяют равенству  $\sum_{i=1}^M p_i = 1$ .

Плотность каждой компоненты GMM вычисляем как функцию

$$b_i(\vec{x}) = \frac{1}{(2\pi)^{\frac{D}{2}} |\Sigma_i|^{\frac{1}{2}}} \exp\left\{-\frac{1}{2} (\vec{x} - \vec{\mu}_i)^T \cdot \Sigma_i^{-1} \cdot (\vec{x} - \vec{\mu}_i)\right\} \quad (4)$$

где  $\mu_i$  математическое ожидание, а  $\Sigma_i$  матрица ковариации  $i$ -й компоненты GMM.

### 4.3 Настройка параметров GMM

Для настройки параметров  $\mu_i$  и  $\Sigma_i$ , характеризующих конкретный речевой сегмент  $Y$ , воспользуемся итеративным алгоритмом EM (Expectation maximization)[10]. Необходимо максимизировать значение функции правдоподобия -  $p(X|\lambda)$  для GMM модели  $\lambda = \{p_i, \mu_i, \Sigma_i\}$ ,  $i = 1, \dots, M$  на тренировочных данных  $X$ . Например, для данных  $X = \{\vec{x}_1, \dots, \vec{x}_T\}$  функция правдоподобия вычисляется как:

$$p(X|\lambda) = \prod_{t=1}^T p(\vec{x}_t|\lambda). \quad (5)$$

где  $p(\vec{x}_t|\lambda)$  вычисляется по формулам (3) и (4).

На практике используется не функция правдоподобия, а логарифм функции правдоподобия, усредненный на длину тестового произнесения:

$$\mathcal{L}(\lambda) = \frac{1}{T} \sum_{t=1}^T \log \left( \sum_{i=1}^M p_i b_i(\vec{x}_t) \right) \quad (6)$$

где  $b_i(\vec{x}_t)$  вычисляется по формуле (4) с параметрами модели  $\lambda$ .

Начиная с базовой модели  $\lambda$ , переходим к модели  $\bar{\lambda}$  так, что на каждом шаге  $\mathcal{L}(\bar{\lambda}) \geq \mathcal{L}(\lambda)$ . Для этого обновляем:

**Веса:**

$$\overline{p}_i = \frac{1}{T} \sum_{t=1}^T p(i|\vec{x}_t, \lambda) \quad i = 1, \dots, M. \quad (7)$$

**Математическое ожидание:**

$$\overrightarrow{\mu}_i = \frac{\sum_{t=1}^T p(i|\vec{x}_t, \lambda) \vec{x}_t}{\sum_{t=1}^T p(i|\vec{x}_t, \lambda)} \quad i = 1, \dots, M. \quad (8)$$

**Ковариационную матрицу:**

$$\overrightarrow{\sigma}_i^2 = \frac{\sum_{t=1}^T p(i|\vec{x}_t, \lambda) \vec{x}_t^2}{\sum_{t=1}^T p(i|\vec{x}_t, \lambda)} - \overrightarrow{\mu}_i^2 \quad i = 1, \dots, M. \quad (9)$$

Где слагаемое из формул (7),(8),(9) вычисляется как:

$$p(i|\vec{x}_t, \lambda) = \frac{p_i b_i(\vec{x}_t)}{\sum_{k=1}^M p_k b_k(\vec{x}_t)} \quad i = 1, \dots, M. \quad (10)$$

## 5 Адаптация модели диктора

### 5.1 Universal Background Model

Допустим, что существует настроенная GMM модель диктора  $\lambda$ . Используя данную модель, мы сможем посчитать значение функции правдоподобия (5) при условии гипотезы  $H_0$ . В соотношении (1) фигурирует альтернативная гипотеза  $H_1$ . Для моделирования альтернативной гипотезы вводится UBM(Universal Background Model)[5].

UBM - это GMM модель, созданная на основе большого корпуса речи, отражающая информацию о речевых признаках группы людей. Используя UBM модель, вычисляется значение функции правдоподобия для  $H_1$ .

### 5.2 Адаптация модели диктора с использованием UBM

В этой главе описывается процесс, называемый МАР адаптацией модели диктора[5], использующий UBM. Проблема заключается в том, что полезной информации, извлеченной из короткой речевой фразы  $Y$  не хватит на создание полноценной модели. Поэтому в данном случае используется UBM модель, только не для моделирования альтернативной гипотезы, а для компенсации недостатка входных данных при создании модели диктора и сказанной им фразы.

Последовательность действий:

1. Создаем UBM на основе речевого корпуса, используя ЕМ алгоритм
2. Извлекаем вектора признаков  $X$  по записанному речевому сегменту  $Y$
3. Создаем адаптированную модель диктора

Процесс создания адаптированной модели диктора состоит из 2-х этапов:

1. Применяя формулы (7), (8), (9), вычисляем статистики, используя вектора признаков  $X$  и UBM модель  $\lambda$ . Полученные параметры обозначим как:

$$\hat{\lambda} = \{\hat{p}_i, \hat{\mu}_i, \hat{\Sigma}_i\}, \quad i = 1, \dots, M$$

2. На основе параметров  $\lambda$  и новых параметров  $\hat{\lambda}$  вычисляем результирующие параметры  $\bar{\lambda}$ .

Результирующие параметры  $\bar{\lambda}$  находятся из следующих соотношений:

$$\bar{p}_i = \alpha_i \hat{p}_i + (1 - \alpha_i) p_i \quad (11)$$

$$\bar{\mu}_i = \alpha_i \hat{\mu}_i + (1 - \alpha_i) \mu_i \quad (12)$$

$$\begin{aligned} \bar{\sigma}_i^2 &= \alpha_i \hat{\sigma}_i^2 + (1 - \alpha_i)(\sigma_i^2 + \mu_i^2) - \bar{\mu}_i^2 \\ i &= 1, \dots, M \end{aligned} \quad (13)$$

Параметр  $\alpha_i$ , контролирующий баланс между  $\lambda$  и  $\bar{\lambda}$  выбирается как:

$$\alpha_i = \frac{\hat{p}_i}{\hat{p}_i + r} \quad (14)$$

где значение  $r = 16$  было подобрано экспериментально[5].

### 5.3 Hidden Markov Model

Для того, чтобы использовать информацию о временной структуре пароля диктора вводится Скрытая Марковская модель(HMM, Hidden Markov Model)[11], построенная с использованием адаптированной модели диктора. Таким образом модель будет совмещать в себе дикторскую и лингвистическую информацию.

### 5.4 Адаптация модели диктора с использованием НММ

Предположим, что имеется модель диктора  $\lambda$ , адаптированная при помощи UBM с использованием векторов признаков  $X = \{\vec{x}_1, \dots, \vec{x}_T\}$ . Для извлечения дополнительной текстозависимой информации проводится двухэтапный процесс адаптации, использующий НММ.

На первом этапе адаптации вектора  $X$  разбиваются на  $N$  сегментов одинакового размера  $\{seg_i\}, i = 1, \dots, N$ . Далее, для каждого сегмента  $seg_i$  независимо проводится настройка параметра веса модели  $\lambda$  по формулам (7), (11).

На втором этапе адаптации осуществляется пересегментация  $X$  на основе пути Витерби[11], вычисляемого для  $X$ , и матрицы переходов, рассчитываемой в зависимости от относительной длины сегментов[12]. На каждом новом сегменте  $seg_i$  проводится настройка параметра веса модели  $\lambda$  по формулам (7), (11). Второй этап повторяется до тех пор, пока процесс сегментации не стабилизируется.

## 6 Принятие решения о верификации

Для принятия решения о верификации диктора вычислим логарифм соотношения (1). Гипотезу  $H_1$  характеризует UBM модель  $\lambda^{UBM}$  с параметрами  $\{p_i^{UBM}, \mu_i^{UBM}, \Sigma_i^{UBM}\}$ ,  $i = 1, \dots, M$ . Используя равенство (6) вычисляем  $\mathcal{L}(\lambda^{UBM})$  на входных данных  $X = \{\vec{x}_1, \dots, \vec{x}_T\}$ .

При помощи HMM адаптации извлекается информация о временной структуре фразы, представленная наборами весов  $p_j^k$ , где  $j = 1, \dots, M$ ,  $k = 1, \dots, \mathcal{N}$ . Используя адаптированную модель  $\lambda^{GMM}$  с параметрами  $\{p_i^{GMM}, \mu_i^{GMM}, \Sigma_i^{GMM}\}$ ,  $i = 1, \dots, M$  по матрице  $X = \{\vec{x}_1, \dots, \vec{x}_T\}$ , разбитой на сегменты  $\{seg_i\}$ ,  $i = 1, \dots, \mathcal{N}$  вычисляем логарифм значения функции правдоподобия для гипотезы  $H_0$ :

$$\mathcal{L}(\lambda^{HMM}) = \frac{1}{T} \sum_{t=1}^T \log \left( \sum_{i=1}^M p_i^k b_i(\vec{x}_t) \right) \quad (15)$$

где  $b_i(\vec{x}_t)$  вычисляется по формуле (4) с параметрами  $\mu_i^{GMM}, \Sigma_i^{GMM}$ , а  $p_i^k$  весовой параметр  $i$ -й компоненты GMM, настроенной на сегменте  $seg_k$ .

Результатирующее значение  $\mathcal{S}$  получается из формулы [12]:

$$\mathcal{S} = \mathcal{L}(\lambda^{HMM}) - \mathcal{L}(\lambda^{UBM}) \quad (16)$$

В соответствии с пунктом (1) значение  $\mathcal{S}$  сравнивается с пороговым значением  $\theta$  и принимается решение о верификации.

## 7 Реализация

Были выбраны вектора признаков размерности  $42 \times 1$ , содержащие значение энергии, 13 MFC коэффициентов, их первые и вторые производные. Для извлечения векторов использовалась библиотека VOICEBOX.<sup>2</sup> Представленная библиотека также использовалась для выделения речевой активности.

Для тестирования был выбран речевой корпус MIT[13]. В данном корпусе данные распределены на группы:

1. Зарегистрированные пользователи
2. Самозванцы

В записи данных участвовали мужчины и женщины, в регистрационной записи - 48 человек, в записи самозванцев - 40 человек. Регистрационная запись проводилась дважды. Каждый человек произнес 54 фразы из определенного списка. Для записи использовались 2 разных микрофона. Запись проводилась в 3-х различных шумовых обстановках.

Для создания UBM, состоящих из 128 и 64 компонент, использовались данные первой регистрационной записи.

Сравнение модели диктора со входными данными считалось целевым, если модель и сказанная фраза принадлежали одному диктору и сказанная фраза совпадала с требуемым паролем. Иначе сравнение считалось нецелевым. Ожидается, что система верификации должна подтверждать целевое сравнение и отклонять нецелевое.

Было сформировано 2 протокола тестирования. Протокол *A* содержал целевые сравнения и нецелевые сравнения различных дикторов. Протокол *B* содержал целевые сравнения, нецелевые сравнения различных дикторов, нецелевые сравнения одинаковых дикторов с различающимися паролями. По каждому из протоколов проводилось 20000 сравнений.

По оси X (Рис.2) в процентном отношении представлена вероятность ошибки первого рода, вероятность ошибочно отвергнуть гипотезу  $H_0$  из (1). По оси Y в процентном отношении представлена вероятность ошибки второго рода, вероятность ошибочно принять гипотезу  $H_0$ . Значение, при котором совпадают вероятности ошибки первого и второго рода, называется равновероятной ошибкой (EER, Equal Error Rate). EER описывает точность системы верификации диктора.

Для UBM состоящей из 128 компонент, для протокола *A*, на 6819 целевых и 13181 нецелевых сравнениях EER = 15.15% (Рис.2).

Для UBM состоящей из 128 компонент, для протокола *B*, на 5141 целевых и 14859 нецелевых сравнениях EER = 17.12% (Рис.3).

Для UBM состоящей из 64 компонент, для протокола *A*, на 6819 целевых и 13181 нецелевых сравнениях EER = 18.21%.

Для UBM состоящей из 64 компонент, для протокола *B*, на 5141 целевых и 14859 нецелевых сравнениях EER = 19.04%.

---

<sup>2</sup>VOICEBOX - открытая библиотека по обработке речи, реализованная на MATLAB.  
<http://www.ee.ic.ac.uk/hp/staff/dmb/voicebox/voicebox.html> (дата обращения: 11.04.2014)




Рис. 2: Результаты тестирования системы верификации по протоколу *A* для UBM из 128 компонент




Рис. 3: Результаты тестирования системы верификации по протоколу *B* для UBM из 128 компонент

## 8 Результаты

В рамках курсовой работы были получены следующие результаты:

- Изучены основные алгоритмы верификации диктора
- Реализован текстозависимый алгоритм верификации диктора
- Интегрированы средства для извлечения векторов признаков
- Интегрированы средства для выделения речевой активности
- Создан интерфейс для тестирования
- Проведено тестирование на речевом корпусе MIT[13]

## Список литературы

- [1] Fauve B., Evans N., Pearson N., Bonastre J.-F., Mason J.S.: Influence of task duration in text-independent speaker verification// Annual Conference of the International Speech Communication Association. 2007. P.794–797.
- [2] Bonastre, J.-F, Wils, F., Meignier, S.: ALIZE, a free Toolkit for Speaker Recognition// IEEE International Conference on Acoustics, Speech, and Signal Processing. Vol. 1. 2005. P.737 - 740.
- [3] Sadjadi, S. O., Slaney, M., Heck L.: MSR Identity Toolbox v1.0: A MATLAB Toolbox for Speaker-Recognition Research, November 2013. <http://www.signalprocessingociety.org/technical-committees/list/sl-tc/spl-nl/2013-11/IdentityToolbox/>
- [4] Larcher, A.B., Mason J.F., John S.D.: Constrained Temporal Structure For Text-dependent Speaker Verification// Digital Signal Processing. Vol. 23. 2013. P.1910-1917.
- [5] Reynolds, D. A., Quatieri, T. F., Dunn, R. B.: Speaker Verification using adapted Gaussian mixture models// Digital Signal Processing. Vol. 10. 2000. P.19–41.
- [6] Young S., Evermann G., Gales M., Hain T., Kershaw D.: The HTK Book 3. 1999. P.77-78, 191-193, 217-222.
- [7] Benesty, J., Sondhi, M.M., Huang, Y.: Handbook of Speech Processing. Springer. 2008.
- [8] O'Shaughnessy, D.: Formant Estimation and Tracking// Springer Handbook of Speech Processing. 2008. P.213–227.
- [9] Droppo, J., Acero, A.: Environmental Robustness// Springer Handbook of Speech Processing. 2008. P.662–663.
- [10] Reynolds, D. A., Rose, R. C.: Robust text-independent speaker identification using Gaussian mixture speaker models// IEEE Transactions on Audio, Speech and Language Processing. Vol.3. 1995. P.72–83.
- [11] Huang, X., Acero, A., Hon, H-W, Spoken Language Processing: A Guide to Theory, Algorithm and System Development. 2001. 377-413.
- [12] Larcher, A.B., Mason J.F., John S.D.: From GMM to HMM for Embedded Password-Based Speaker Recognition// European Signal and Image Processing Conference. 2008
- [13] Woo R.H., Park A., Hazen T.: The MIT Mobile Device Speaker Verification Corpus: Data collection and preliminary experiments// Proceedings of IEEE Odyssey. 2006