

НЕЙРОСЕТЕВЫЕ ТЕХНОЛОГИИ ПРИ РЕШЕНИИ ЗАДАЧ РАЗГРАНИЧЕНИЯ ДОСТУПА

Рыжков А.П.¹, Катков О.Н.², Морозов С.В.³

В статье рассмотрены некоторые вопросы, касающиеся разработки процедур обработки речевого сигнала в системах речевой идентификации пользователя. Предложено при формировании кодовых книг использовать нейронные сети радиальных базисных функций и осуществлять поиск в них при помощи иерархического векторного квантования. Для функционирования нейросетевых векторных квантователей создан алгоритм классификации параметров сегментов речевого сигнала. Данный подход позволяет осуществлять речевую идентификацию пользователя при доступе к различным инфокоммуникационным системам.

Ключевые слова: речевой сигнал, речевая идентификация, классификация, векторное квантование, искусственные нейронные сети, радиальные базисные функции.

Введение

Одним из важнейших путей развития систем с речевым управлением является создание устройств идентификации личности абонента в целях защиты информационных баз данных от несанкционированного использования или преднамеренного искажения. Такая защита необходима не только в информационно-вычислительных системах специального назначения, но и, например, в автоматизированных системах управления технологическими процессами на предприятиях, выпускающих продукцию двойного назначения. Создание устройств с высокой надежностью (достоверностью) распознавания речи позволит обеспечить не только допуск легитимных абонентов к информационным сетям различного назначения, но и решать задачи по автоматической оценке эмоционального состояния операторов, управляющих сложными производственными процессами, а также других лиц, работающих в реальных или моделируемых стрессовых ситуациях. В таких системах существует актуальная задача по хранению и сравнению некоторых параметров речевого сигнала (РС) с базовыми эталонными значениями, получаемыми заранее на этапе обучения системы распознавания, и формирования выходных сигналов в зависимости от итогов сравнения в виде необходимых управляющих воздействий или, как результат, идентификации личности абонента.

Теоретическая цель работы заключается в обосновании использования искусственных нейронных сетей при создании защищенных систем с речевым разграничением доступа, основанных на применении радиальных базисных функций, а также разработке классификатора параметров речевого сигнала для функционирования предложенных нейронных сетей.

Классификация сегментов речевого сигнала. При построении дикторонезависимой системы разграничения доступа необходимо выполнить определенную классификацию элементов и параметров РС для дальнейшего сравнения и принятия решения. Как правило, разделение на элементы (сегментация) РС осуществляется оконными функциями длительностью 10–20 мс, что при частоте дискретизации 8 кГц соответствует 80–160 отсчетам. Для классификации сегментов РС на конечное число классов с целью дальнейшей обработки для выполнения процедуры идентификации по голосу используются статистические и параметрические характеристики речи.

К статистическим характеристикам, определяемым на сегменте, относятся:

- математическое ожидание M и средняя мощность (дисперсия) сигнала D ,
- функция автокорреляции B и функция плотности вероятности (ФПВ) $w(S)$.

Математическое ожидание M и дисперсия D для речевого сегмента определяются формулами

$$M = \sum_{i=1}^{N_{\text{сег}}} S(i) p_i, \quad (1)$$

$$D = \sum_{i=1}^{N_{\text{сег}}} (S(i) - M)^2 p_i, \quad (2)$$

где $N_{\text{сег}}$ – количество отсчетов; p_i – вероятность появления отсчета $S(i)$ в сегменте.

При совместном изучении центрированных случайных величин вводится автокорреляционная функция (АКФ):

$$B(j) = \sum_{i=0}^{N_{\text{сег}}} S(i+1) S(i+j+1). \quad (3)$$

1 Рыжков Александр Павлович, кандидат технических наук, Академия ФСО России, г. Орёл

2 Катков Олег Николаевич, кандидат технических наук, Академия ФСО России, г. Орёл

3 Морозов Святослав Викторович, Академия ФСО России, г. Орёл, fromnet@yandex.ru

Выражение (3) справедливо при вычислении функции автокорреляции в сегменте для случая равномерности появления отсчетов. Как правило, вычисление функции автокорреляции является частью процедуры нахождения коэффициентов линейного предсказания.

Статистические свойства речевого сигнала хорошо описываются четырьмя типами распределений со следующими функциями плотности вероятности (ФПВ): гауссовой, равномерной, лапласовой, гамма:

$$w(S) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\left(\frac{(S-M)^2}{2\sigma^2}\right)}, \quad (4)$$

$$w(S) = \begin{cases} \frac{1}{2\sqrt{3}\sigma}, & |S| \leq \sqrt{3}\sigma; \\ 0, & S > \sqrt{3}\sigma; \end{cases} \quad (5)$$

$$w(S) = \frac{1}{\sqrt{2}\sigma} e^{-\left(\frac{\sqrt{2}|S|}{\sigma}\right)}, \quad (6)$$

$$w(S) = \frac{\sqrt[4]{3}}{\sqrt{8|S|\pi}\sigma} e^{-\left(\frac{\sqrt{3}|S|}{2\sigma}\right)}, \quad (7)$$

где S – соответствующее значение отсчета РС; σ – среднеквадратическое отклонение сигнала (СКО), $\sigma = \sqrt{D}$.

К параметрическим характеристикам, которые могут быть использованы при разработке системы разграничения доступа, относятся:

- коэффициент огибающей O кодируемого сигнала,
- число переходов через ноль Z_n ,
- параметр сигнал тон/шум I (СТШ), вычисляемый на сегменте анализа и позволяющий разделить на 2 класса сегментов: шумовые и тоновые,
- частота основного тона $F_{от}$,
- число формантных областей ΔF_i на сегменте анализа.

Коэффициент огибающей кодируемого сигнала определяется по формуле:

$$o = \frac{1}{N_{сег}-1} \sum_{n=1}^{N_{сег}-1} |S(n+1)-S(n)|, \quad (8)$$

где $S(n)$ – отсчеты РС в сегменте анализа, $N_{сег}$ – длина сегмента, o характеризует среднюю скорость изменения сигнала.

Число переходов через ноль Z_n определяет шумовые свойства РС. Это частота смены знака текущего отсчета на сегменте анализа.

Для выделения параметра СТШ на сегменте анализа предполагается использовать метод, ос-

нованный на анализе АКФ [1], а также модифицированный метод Итакуры–Саито. Процесс нахождения I реализуется путем анализа АКФ сегмента сигнала длительностью 80 отсчетов и нахождения ее экстремума в заданной области определения, при этом вводится следующее правило принятия решения:

$$\begin{aligned} B(\tau_i) \geq kB(0) &\rightarrow I - \text{тон}; \\ B(\tau_i) < kB(0) &\rightarrow I - \text{шум} \end{aligned} \quad (9)$$

Рекомендуется использовать значение $k = 0,5$, определенное экспериментально.

Нахождение частоты основного тона производится для тоновых сегментов:

$$F_{от} = 1/\tau_i, \quad (10)$$

где τ_i – значение временного сдвига АКФ, при котором найден ее экстремум, удовлетворяющий правилу (9).

Оценка параметра СТШ и частоты ОТ методом Итакуры–Саито заключается в фильтрации остатка линейного предсказания рекурсивным НЧ-фильтром 6-го порядка (прототип фильтра Баттерворта с частотой среза от 300 до 600 Гц) для уменьшения влияния второй формантной области на результаты вычислений. Данный фильтр выбран из соображений равномерности амплитудно-частотной и линейности фазочастотной характеристик в полосе пропускания, а также приемлемой крутизны АЧХ в полосе расфильтровки.

Для оценки частоты ОТ применяются одновременно два метода: метод анализа АКФ и модифицированный метод Итакуры–Саито. За частоту ОТ принимается среднее арифметическое значение, вычисленное с помощью этих двух методов: $F_{от} = 0,5 (F_{от1} + F_{от2})$.

Частота среза фильтра в методе Итакуры–Саито выбирается в зависимости от предварительно полученных данных о частоте ОТ на основе анализа АКФ речевого сегмента. Правила адаптивного изменения граничной частоты F_g пропускания фильтра в зависимости от частоты ОТ представлены в таблице 1.

Таблица 1

Зависимость граничной частоты среза ФНЧ от частоты ОТ

$F_{от}, \text{Гц}$	$F_g, \text{Гц}$
< 130	300
130–200	400
> 200	600

Число формантных областей ΔF_i на сегменте анализа определяется посредством исследования спектра речевого сегмента, исследование формантной структуры речи представлено в [2]. Данный параметр отражает необходимое и достаточное количество коэффициентов линейного предсказания.

Качественные характеристики систем обработки речевого сигнала зависят от выбранного алгоритма классификации речевых сегментов.

Исследовались два альтернативных алгоритма классификации сегментов речи:

Классификатор, основанный на анализе статистических и параметрических характеристик речи.

Классификатор на базе анализа функции распределения исследуемого сигнала.

Классификатор первого типа основан на многоэтапном анализе сегмента. На первом этапе классификации сигнал делится на активные участки и паузы, критерием принятия решения служит соотношение

$$P \leq P_0 \begin{cases} \text{да, } S - \text{пауза,} \\ \text{нет, } S - \text{речь,} \end{cases} \quad (11)$$

где $P = \frac{1}{N_{\text{сег}}} \sum_{i=1}^{N_{\text{сег}}} S_i^2$, $N_{\text{сег}}$ – число отсчетов в анализируемом сегменте.

Определение P_0 заключается в разделении сегмента в 80 отсчетов на паузы и активные участки с выбором начального уровня P_0 . Сформированный экспертом сигнал пауз подвергается прослушиванию и в нем определяется средняя мощность этих фрагментов для коррекции значения P_0 с учетом рекомендаций, высказанных экспертом. Определение дисперсии сигнала паузы производится для большого числа дикторов с различными свойствами речи. Таким образом, за несколько итераций находится граничное значение дисперсии, которое принимается за величину P_0 .

Рассчитанное значение P_0 позволяет делить РС на два класса (пауза/речь) таким образом, что доля времени пауз в речи составляет около 50 %, что соответствует результатам исследований речи другими авторами [3].

На втором этапе классификации сегменты активной речи делятся на четыре типа: тоновые, шумовые, переходные 1 типа и переходные 2 типа. Для такого деления вычисляется параметр СТШ I_i и частота ОТ F_{om} на сегменте анализа.

Вычисления параметра СТШ и частоты ОТ производятся совместно на основе анализа АКФ РС и метода Итакуры–Саито. Использование двух ме-

тодов в совокупности уменьшает вероятность ошибки в классификации сегментов речи.

Целесообразность выбора данных методов для выделения параметра СТШ и частоты ОТ объясняется уменьшением общей вычислительной сложности за счет повторного применения результатов, полученных в ходе их вычисления на последующих этапах обработки РС.

Правила принятия решения о типе сегмента сформулированы следующим образом:

- тоновые сегменты: метод анализа АКФ определяет сегмент как тоновый, метод Итакуры–Саито – как тоновый;

- шумовые сегменты: метод анализа АКФ определяет сегмент как шумовой, метод Итакуры–Саито – как шумовой;

- переходные сегменты первого типа: метод анализа АКФ определяет сегмент как шумовой, метод Итакуры–Саито – как тоновый;

- переходные сегменты второго типа: метод анализа АКФ определяет сегмент как тоновый, метод Итакуры–Саито – как шумовой.

На третьем этапе все тоновые и переходные сегменты делятся на мужские и женские по правилу: если $F_{от} > F_{гр}$, то сегмент женский, если $F_{от} \leq F_{гр}$, то сегмент мужской.

Граничная частота ОТ $F_{гр}=180$ Гц определена экспериментально и соответствует результатам исследований [4].

Таким образом, с помощью трехэтапного классификатора активные сегменты РС будут делиться на 7 типов.

Алгоритм классификации речевых сегментов на конечное число классов с использованием характеристик РС представлен на рисунке 1, а варианты классифицированных сегментов – на рисунке 2.

Принцип построения классификатора второго типа состоит в использовании четырех основных функций плотности вероятности, законы распределения которых хорошо описывают статистические свойства РС. Такой классификатор строится на основе критерия согласия Колмогорова–Смирнова с четырьмя возможными аналитическими моделями функций плотности вероятности (4)–(7). Данный классификатор дополнительно может применять и такие характеристики, как мощность сигнала на участке анализа, параметр тон/шум и частоту ОТ, функцию корреляции сигнала на сегменте анализа (3). Результаты исследования функций плотности вероятности отсчетов РС на сегменте анализа и способы построения классификатора на их основе, а также полученные при этом результаты показаны в [5].

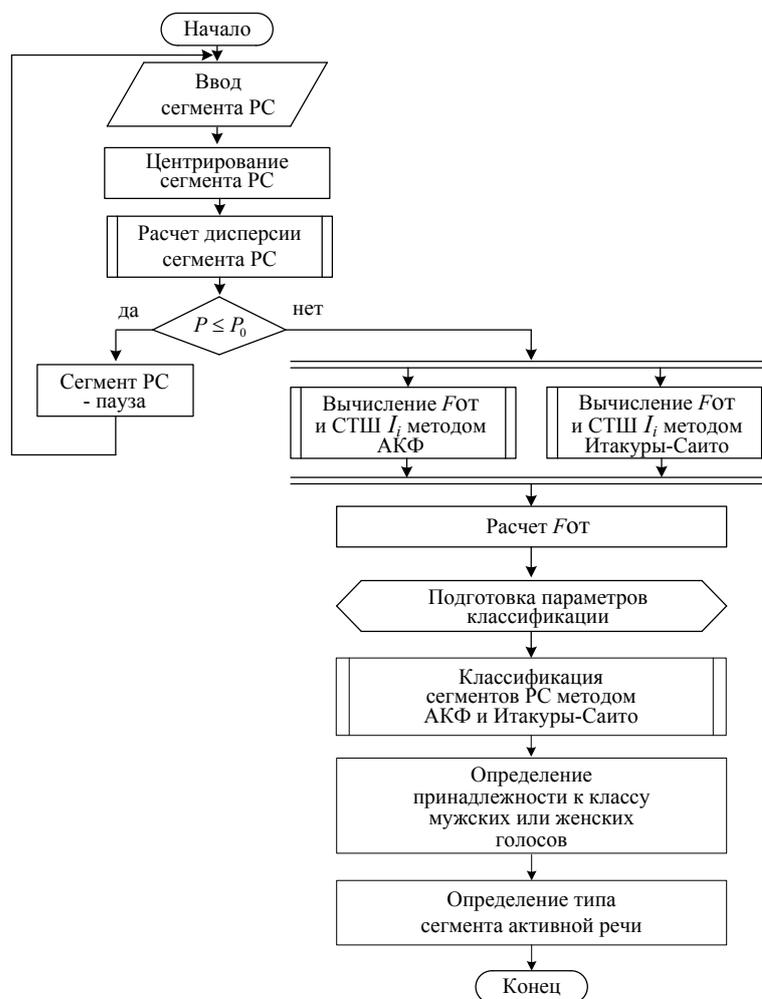


Рис. 1. Блок-схема алгоритма классификации сегментов РС

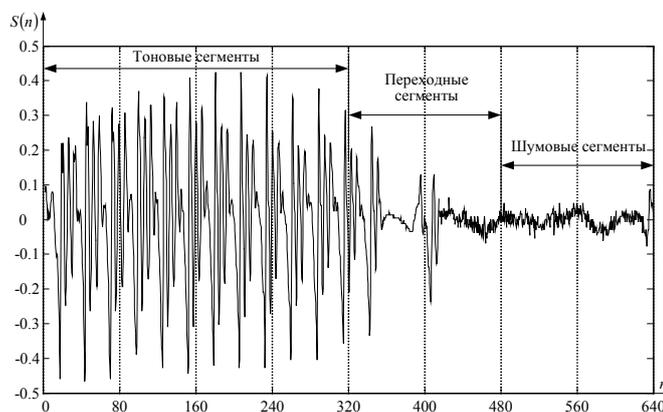


Рис. 2. Виды речевых сегментов во временной области

Для обоснованного выбора типа классификатора было проведено моделирование, которое показало, что лучший результат по критерию суммарного отношения сигнал/шум обеспечивает классификатор 1-го типа, поэтому он выбран в качестве классификатора сегментов РС для дальнейшего использования в системах разграничения доступа.

Нейросетевая обработка сегментов речевого сигнала. Хранение и сравнение элементов и

параметров речевого сигнала при функционировании систем разграничения доступа по голосу невозможны без применения принципа векторного квантования (ВК). В качестве перспективного направления ВК предлагается использование каскадного ВК [6]. Его алгоритмы достаточно хорошо согласуются с процедурой обучения и поиска в нейронных сетях – классификаторах, которые выступают в качестве векторных квантователей эле-

ментов и параметров РС. В контексте нейронных сетей возможно применение нейронных сетей радиальных базисных функций RBF, поскольку в [7, 8] доказано, что каждое множество образов, случайным образом размещенных в многомерном пространстве, является φ -разделимым при условии большой размерности этого пространства.

Основанием использования сетей типа RBF по сравнению с аналогичными (многослойными персептронами, рекуррентными, с самоорганизацией) в первую очередь является высокая скорость обучения, а следовательно, и создание кодовых книг при векторном квантовании.

Нейронная сеть RBF функционирует по принципу многомерной интерполяции, состоящей в отображении p различных входных векторов $x_i (i=1, 2, \dots, p)$ из входного N -мерного пространства во множество из p рациональных чисел $d_i (i=1, 2, \dots, p)$. Для реализации необходимо применить p скрытых нейронов радиального типа и задать функцию отображения $F(x)$ вида $F(x)=d_i$. Чаще всего в качестве радиальной функции выступает функция Гаусса. При размещении ее центра в точке c_i она может быть определена как

$$\varphi(x) = \varphi(\|x - c_i\|) = \exp\left(-\frac{\|x - c_i\|^2}{2\sigma_i^2}\right), \quad (12)$$

где σ_i – параметр, от значения которого зависит ширина функции.

Решение, представляющее аппроксимирующую функцию в многомерном пространстве в виде взвешенной суммы локальных базисных радиальных функций, может быть интерпретировано радиальной нейронной сетью, представленной на рисунке 3, в которой φ_j определяется зависимостью (12). Это сеть с трехслойной архитектурой, в которой только скрытый слой выполняет нелинейное отображение, реализуемое нейронами с базисными радиальными функциями. Выходной нейрон линеен, а его роль сводится к взвешенному суммированию сигналов, поступающих от нейронов скрытого слоя.

Процесс обучения сети RBF с учетом выбранного типа радиальной базисной функции сводится к подбору центров c_i и параметров σ_i формы базисных функций, а так же подбору весов нейронов выходного слоя.

Определяющим при обучении является подбор параметров нелинейных радиальных функций, особенно центров c_i . Известны три основных метода подбора: самоорганизация, обучение с учителем и гибридный.

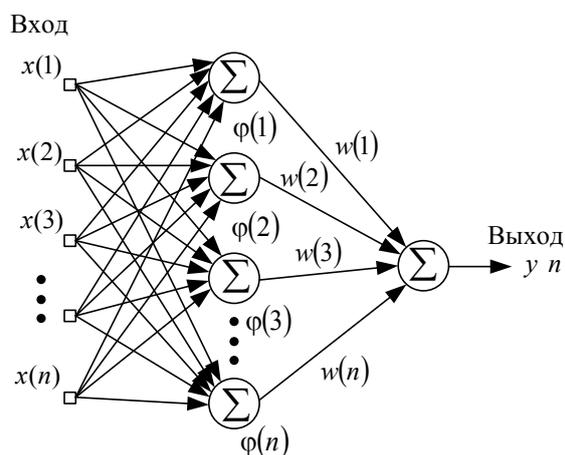


Рис. 3. Обобщенная структура радиальной сети RBF

Анализ рассмотренных методов обучения нейронных сетей на основе радиальных базисных функций и результатов моделирования показывает, что лучшим в целях обучения является гибридный метод, включающий в себя как процедуры настройки на основе самоорганизации, так и обучение с учителем.

Этап обучения на основе самоорганизации. Его целью является оценка подходящих положений центров радиальных базисных функций скрытого слоя. При реализации каскадного ВК этап самоорганизации должен состоять из трех циклов. Увеличение количества циклов обучения не приводит к существенному уменьшению ошибки классификации (рис. 4).

Этап обучения с учителем. Завершается оценка центров радиальных базисных функций скрытого слоя и определяются линейные веса выходного слоя.

Алгоритм можно описать следующим образом:
Этап 1

1. **Инициализация.** Выбираются случайные значения для исходных центров радиальных базисных функций c_i . Единственным требованием к их выбору на данном шаге является различие всех начальных значений.

2. **Выборка.** Нейронной сети RBF предъявляется вектор x из обучающего множества X . В случае проведения эксперимента в качестве обучающей выборки предъявлялись векторы линейных спектральных частот.

3. **Проверка подобия.** Согласно критерию минимального Евклидова расстояния, определяется индекс победившего нейрона (центра) для вектора x :

$$i(x) = \arg \min_i \|x(n) - c_i(n)\|, i=1, 2, \dots, C, \quad (13)$$

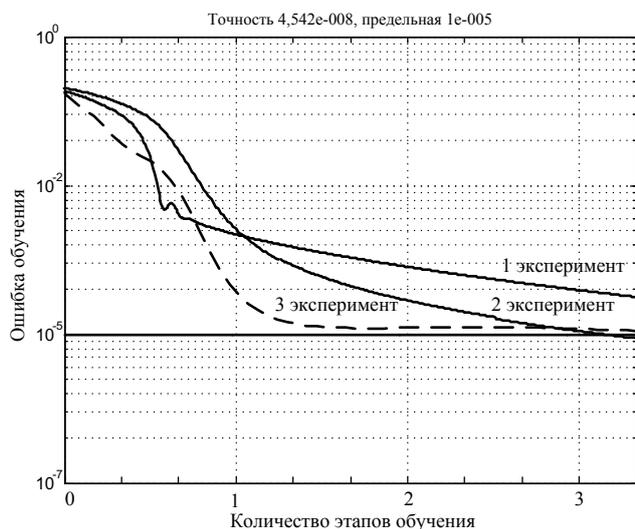


Рис. 4. Зависимость ошибки обучения нейронной сети RBF от числа циклов на первом этапе обучения

где c_i – центр i -й радиальной базисной функции, n – номер итерации, C – количество центров.

4. **Корректировка.** Центры радиальных функций корректируются по правилу

$$c_i(n+1) = \begin{cases} c_i(n) + \eta[x - c_i(n)], & i=i(x), \\ c_i(n) - \text{в противном случае,} \end{cases} \quad (14)$$

где η – параметр скорости обучения, $0 < \eta < 1$.

5. **Повторение шагов 3–4** (увеличение шага на 1) до тех пор, пока положение центров скрытых нейронов не перестанет существенно изменяться (как правило, достаточно трех итераций).

По завершении первого этапа для обучающей выборки пространство скрытых нейронов трехслойной сети RBF оказалось равным 145–157 для серии из повторяющихся экспериментов (рис. 5).

При формировании кодовых книг на первом этапе значение η выбрано 0,005, необходимое для хорошей статистической точности на этапе сходимости (рис. 6).

Этап 2

Сформированное пространство ячеек векторов является приближенным с точки зрения размещения опорных векторов-центроидов в N -мерной системе координат. В качестве механизма точной подстройки необходимо произвести квантование векторов:

1) в случае максимальной близости вектора Вороного W_i ко входному вектору X_i

$$w_i(n+1) = w_i(n) + \alpha_n [x_i - w_i(n)], \text{ где } 0 < \alpha_n < 1.$$

2) при несовпадении $w_i(n+1) = w_i(n) - \alpha_n [x_i - w_i(n)].$

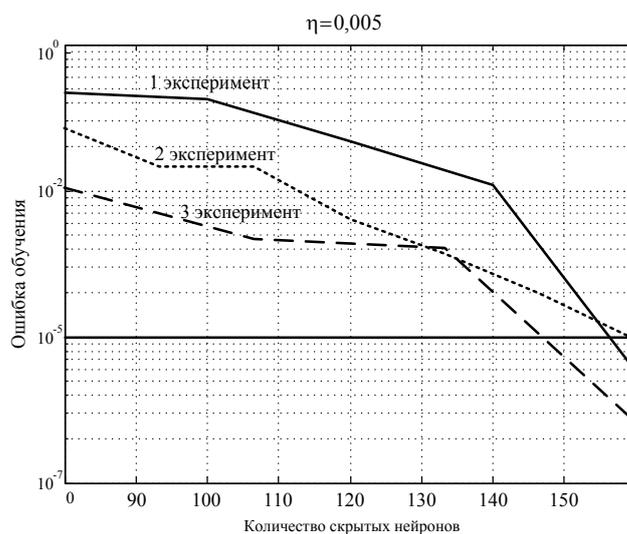


Рис. 5. Формирование пространства скрытых нейронов по завершении первого этапа обучения сети RBF

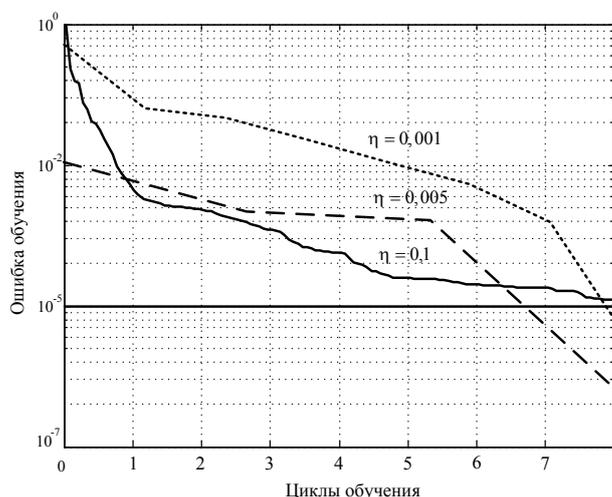


Рис. 6. Влияние параметра скорости обучения на первом этапе формирования кодовых книг для векторов линейных спектральных частот

3) остальные векторы Вороного не изменяются. Постоянную обучения α_n для формирования кодовых книг выбирают с начальным значением 0,09 (рис. 7).

В результате процедуры квантования после нескольких проходов по входным данным координаты опорных векторов Вороного перестают изменяться, а следовательно, и завершается создание пространства многоугольников Вороного.

Особенностями алгоритма являются:

1) функция стоимости – выпуклая по линейному параметру W , однако невыпуклая по отношению к центрам c_i и матрице σ_i ;

2) для второго этапа можно использовать разные параметры скорости обучения α_n ;

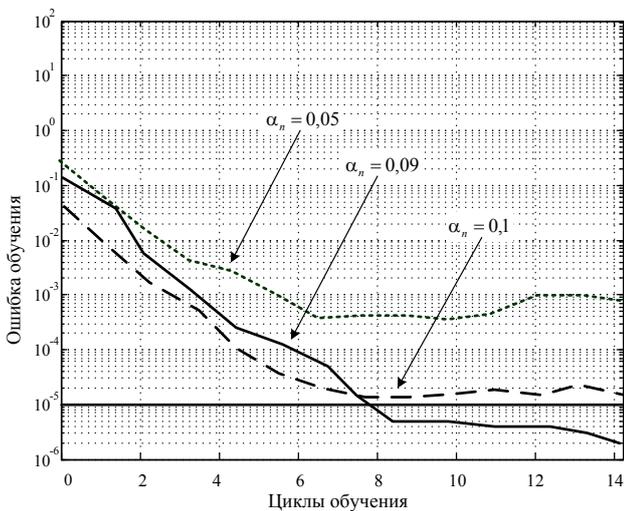


Рис. 7. Влияние постоянной обучения α_n на втором этапе формирования кодовых книг для векторов линейных спектральных частот

3) в отличие от алгоритма обратного распространения, этап обучения с учителем, являющийся процедурой градиентного спуска для сети RBF, не предполагает обратного распространения сигнала ошибки.

Блок-схема алгоритма гибридного обучения сети RBF представлена на рисунке 8.

При осуществлении поиска используется многоступенчатая иерархическая процедура, которая ускоряет поиск в отличие от древовидного поиска опорного вектора-центроида [9]. Многоступенчатое иерархическое ВК разделяет общую операцию поиска на множество подопераций, каждая из которых требует малого объема вычислений. В каждой подоперации обрабатывают остаток вектора, формируемый на предыдущем подэтапе. Входной вектор квантуют k_i -уровневым векторным квантователем, остаток (ошибка) квантования подают на вход второго k_j -уровневого векторного квантователя. Процесс может повторяться для любого количества подэтапов. Окончательное квантованное значение вектора для кодовых книг представляют в виде суммы выходных векторов промежуточных и конечного квантователя.

Заключение

Проверка разработанных алгоритмов, согласно требованиям, предъявляемым к ним, в среде MATLAB показала их соответствие и возможность дальнейшей реализации на современной элементной базе [10]. Тестирование разработанных алгоритмов выполнено на реальных РС длительностью не менее 15 мин для 13 дикторов. Таким образом, использование предложенных выше элементов системы разграничения доступа для целей регистра-

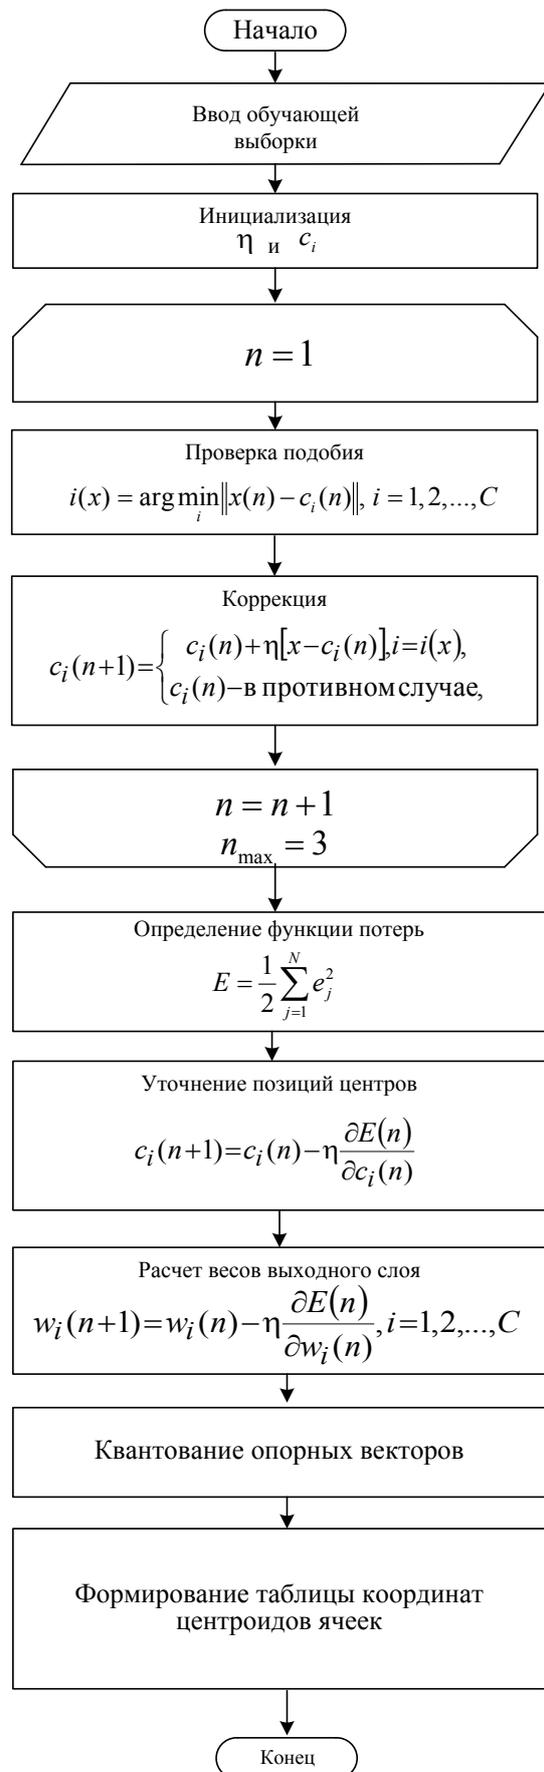


Рис. 8. Блок-схема алгоритма гибридного обучения нейронных сетей радиальных базисных функций

ции и идентификации пользователей инфокоммуникационных систем обеспечивает выполнение двух технических задач:

- повышение надежности функционирования системы разграничения и контроля доступа к информации аппаратно-программным способом;
- реализацию широких функциональных возможностей по изменению критериев доступа в за-

висимости от информационной важности данных.

В целом система распознавания пользователей на основе речевого классификатора и нейросетевого ВК может выступать как часть программно-аппаратных средств управления доступом и комбинироваться как с традиционными средствами подтверждения подлинности, так и с иными биометрическими системами.

Рецензент: Цирлов Валентин Леонидович, кандидат технических наук, доцент МГТУ им. Н.Э. Баумана, Москва, v.tsirlov@bmstu.ru

Литература:

1. Айвазян С.А., Бухштабер В.М., Енюков И.С., Мешалкин Л.Д. Прикладная статистика: классификация и снижение размерности. – М.: Финансы и статистика, 1989. Т. 3. – 607 с.
2. Маркел Д., Грей А.Х. Линейное предсказание речи: под ред. Ю.Н. Прохорова и В.С. Звездина. – М.: Связь, 1980. – 308 с.
3. Волчихин В.И., Иванов А.И., Назаров И.Г., Фунтиков В.А., Язов Ю.К. Нейросетевая защита персональных биометрических данных: монография / Под ред. Ю. К. Язова. – М.: Радиотехника, 2012. – 160 с.
4. Афанасьев А.А., Рыжков А.П. Использование взаимозависимостей параметров линейного предсказания при реализации процедур обработки речевых данных // Телекоммуникации. 2012. № 13. С. 36-39.
5. Рыжков А.П., Афанасьев А.А. Реализация нейросетевой обработки сегментов при линейном предсказании речи // Известия Тульского государственного университета. Технические науки. 2012. № 11-2. С. 173-179.
6. Макхоул Д., Рукос С., Гиш Г. Векторное квантование при кодировании речи // ТИИЭР, 1985. Т. 73. № 11. С. 19–61.
7. Cover T.M. Nearest neighbor pattern classification. IEEE Transactions on Information Theory, 1967, vol. IT-13, p.21–27.
8. Cover T.M. Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition. IEEE Transactions on Electronic Computers, 1965, vol. EC-14, p.326–334.
9. Хайкин С. Нейронные сети: полный курс, 2-е издание. – М.: Издательский дом «Вильямс», 2006. – 1104 с.
10. Медведев В. С., Потемкин В. Г. Нейронные сети. MATLAB 6. – М.: Диалог-МИФИ, 2002. – 496 с.

NEURAL NETWORK TECHNOLOGIES IN SOLVING THE PROBLEM OF ACCESS CONTROL

Ryzhkov A.P.⁴, Katkov O.N.⁵, Morozov S.V.⁶

The article discusses some of the issues of development of speech signal processing procedures in the users voice identification systems. It is proposed the formation of codebooks to use neural network of radial basis functions and search them using hierarchical vector quantization. For the functioning of neural network vector quantizers established classification algorithm parameters of the speech signal segments. Using this approach allows the voice user authentication when accessing various infocommunication systems.

Keywords. *Speech, voice identification, classification, vector quantization, artificial neural networks, radial basis function.*

References:

1. Ayvazyan S.A., Bukhshtaber V.M., Enyukov I.S., Meshalkin L.D. Prikladnaya statistika: klassifikatsiya i snizhenie razmernosti. – М.: Finansy i statistika, 1989. T. 3. – 607 P.
2. Markel D., Grey A.Kh. Lineynoe predskazanie rechi: pod red. Yu.N. Prokhorova i V.S. Zvezdina. – М.: Svyaz', 1980. – 308 P.
3. Volchikhin V.I., Ivanov A.I., Nazarov I.G., Funtikov V.A., Yazov Yu.K. Neyrosetevaya zashchita personal'nykh biometricheskikh dannykh: monografiya, Pod red. Yu. K. Yazova. – М.: Radiotekhnika, 2012. – 160 P.
4. Afanas'yev A.A., Ryzhkov A.P. Ispol'zovanie vzaimozavisimostey parametrov lineynogo predskazaniya pri realizatsii protsedur obrabotki rechevykh dannykh, Telekomunikatsii. 2012. No 13, pp. 36-39.
5. Ryzhkov A.P., Afanas'yev A.A. Realizatsiya neyrosetevoy obrabotki segmentov pri lineynom predskazanii rechi, Izvestiya Tul'skogo gosudarstvennogo universiteta. Tekhnicheskie nauki. 2012. No 11-2, pp. 173-179.
6. Makhoul D., Rukos S., Gish G. Vektornoe kvantovanie pri kodirovani rechi // TIIEP, 1985. T. 73. No 11, pp. 19–61.
7. Cover T.M. Nearest neighbor pattern classification. IEEE Transactions on Information Theory, 1967, vol. IT-13, p.21–27.
8. Cover T.M. Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition. IEEE Transactions on Electronic Computers, 1965, vol. EC-14, p.326–334.
9. Khaykin S. Neyronnye seti : polnyy kurs, 2-e izdanie. – М.: Izdatel'skiy dom «Vil'yams», 2006. – 1104 P.
10. Medvedev V. S., Potemkin V. G. Neyronnye seti. MATLAB 6. – М.: Dialog-MIFI, 2002. – 496 P.

- 4 Aleksandr Ryzhkov, Ph.D., The Academy of Federal Security Guard Service of the Russian Federation, Orel
- 5 Oleg Katkov, Ph.D., The Academy of Federal Security Guard Service of the Russian Federation, Orel
- 6 Svatoslav Morozov, The Academy of Federal Security Guard Service of the Russian Federation, fromnet@yandex.ru