

РАСПОЗНАВАНИЕ И ОБРАБОТКА ИЗОБРАЖЕНИЙ

IMAGE RECOGNITION AND PROCESSING

Оригинальная статья / Original article

<https://doi.org/10.21869/2223-1536-2025-15-4-123-136>



УДК 004.93, 004.896

Структурный синтез нейросетевых моделей биометрического распознавания в пространстве вторичных признаков многомерных динамических кривых

Е. А. Данилов¹✉, А. Х. Танцеров¹

¹ Пензенский государственный технологический университет
пр. Байдукова / ул. Гагарина, д. 1а / 11, г. Пенза 440039, Российская Федерация

✉ e-mail: danilov@penzgtu.ru

Резюме

Цель исследования. Целью работы является повышение достоверности биометрической идентификации пользователя по динамической подписи за счёт построения нейросетевых моделей, ориентированных на работу в пространстве вторичных признаков, полученных из многомерных динамических кривых. В центре внимания – структурный и параметрический синтез архитектуры классифицирующей нейронной сети на основе анализа статистических, гармонических и вейвлет-преобразованных характеристик динамической подписи.

Методы. Предлагается модель идентификации, реализующая параллельное распознавание многомерных фрагментов кривой различными методами – статистическими, метрическими и нейросетевыми. Исследование опирается на выборку параметров динамической подписи, включая координаты, давление, скорость, ускорение и производные от них признаки. Используются математические ожидания, дисперсии, коэффициенты вариации, энтропии и эквивокации, а также ДПФ-, ДКП- и ДВП-преобразования для формирования информативного признакового пространства. На основе этих признаков проводится синтез MLP-классификатора с адаптацией его структуры под входные данные.

Результаты. Экспериментально подтверждена возможность повышения достоверности идентификации пользователя при использовании вторичных признаков по сравнению с традиционными подходами. Использование 3–5 ключевых параметров и их спектральных признаков обеспечивает точность идентификации на уровне 0,8–0,95 в условиях ограниченного количества пользователей и удерживает её около 0,7 при масштабировании. Средний прирост точности составил 25–35% по сравнению со статистическими алгоритмами и 5–15% по сравнению с метрическими.

Заключение. Для достижения заданных показателей достоверности рекомендуется использовать многоуровневый подход к идентификации, предполагающий раздельную обработку параметров динамической подписи с последующим комплексированием результатов. Наиболее эффективными оказались нейросетевые модели в сочетании с метрическими и корреляционными методами в пространстве спектральных и статистических признаков.

© Данилов Е. А., Танцеров А. Х., 2025

Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering. 2025;15(4):123–136

Ключевые слова: динамическая подпись; вторичные признаки; нейросетевая идентификация; дискретные преобразования; спектральный анализ; вейвлет-преобразование; многомерные криевые.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Данилов Е. А., Танцеров А. Х. Структурный синтез нейросетевых моделей биометрического распознавания в пространстве вторичных признаков многомерных динамических кривых // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2025. Т. 15, № 4. С. 123–136. <https://doi.org/10.21869/2223-1536-2025-15-4-123-136>

Поступила в редакцию 06.10.2025

Подписана в печать 05.11.2025

Опубликована 26.12.2025

Structural synthesis of neural network models for biometric recognition in the feature space of multidimensional dynamic curves

Evgeny A. Danilov¹✉, Alexander K. Tantserov¹

¹ Penza State Technological Institute

1a/11 Baidukova Pass. / Gagarina Str., Penza 440039, Russian Federation

✉ e-mail: danilov@penzgtu.ru

Abstract

Purpose of research. The study aims to improve the reliability of biometric user identification based on dynamic signatures by developing neural network models operating in the feature space of multidimensional dynamic curves. The focus is on the structural and parametric synthesis of a classification neural network architecture using statistical, harmonic, and wavelet-transformed features extracted from the dynamic signature.

Methods. The proposed identification model performs parallel recognition of multidimensional curve fragments using various methods, including statistical, metric, and neural classifiers. The analysis is based on a set of dynamic signature parameters, such as pen coordinates, pressure, velocity, acceleration, and their derived features. Statistical metrics – mean values, standard deviations, coefficients of variation, entropy, and equivocation – are combined with Discrete Fourier Transform (DFT), Discrete Cosine Transform (DCT), and Discrete Wavelet Transform (DWT) to form an informative feature space. These features are then used to synthesize an MLP classifier whose architecture is adapted to the input data.

Results. Experimental results confirm that using secondary features significantly increases identification accuracy compared to traditional methods. A set of 3–5 key parameters along with their spectral derivatives allows for accuracy levels of 0,8 to 0,95 with a limited number of users, maintaining around 0,7 when scaling. The average improvement in identification accuracy was 25–35% over statistical methods and 5–15% over metric-based algorithms.

Conclusion. To ensure the required level of identification reliability, it is recommended to apply a multi-level approach involving separate processing of dynamic signature parameters followed by result integration. The most effective configurations were based on neural network models combined with metric and correlation methods operating in the space of spectral and statistical features.

Keywords: dynamic signature; secondary features; neural identification; discrete transforms; spectral analysis; wavelet transform; multidimensional curves.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Danilov E.A., Tantserov A.K. Structural synthesis of neural network models for biometric recognition in the feature space of multidimensional dynamic curves. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering.* 2025;15(4):123–136. (In Russ.) <https://doi.org/10.21869/2223-1536-2025-15-4-123-136>

Received 06.10.2025

Accepted 05.11.2025

Published 26.12.2025

Введение

Динамическая подпись как способ биометрической идентификации получила широкое распространение благодаря высокой степени индивидуальности и сложности подделки [1]. В отличие от статической подписи она содержит богатую поведенческую информацию, такую как давление, скорость, ускорение и временные характеристики, что делает её перспективным инструментом в системах информационной безопасности [2]. Однако надёжность распознавания динамической подписи остаётся критически важной задачей из-за высокой вариативности поведения пользователя и влияния внешних факторов. Современные методы идентификации всё чаще используют не только первичные данные кривых, но и вторичные признаки – статистические, спектральные и комбинированные характеристики, извлекаемые из сигналов [3]. Это позволяет перейти от прямого сопоставления временных рядов к работе в более устойчивом и информативном признаковом пространстве. В данной работе рассматривается подход, основанный на формировании таких вторичных признаков и их использовании в структуре многослойной нейронной сети (MLP) для распознавания. Он заключается в разработке структурно-адаптивных нейросетевых моделей, обеспечивающих высокую достоверность идентификации по параметрам многомерных динамических

кривых, полученных при регистрации подписи пользователя [4]. Работа направлена на сравнение эффективности классификации с использованием нейросетевых методов и традиционных алгоритмов обнаружения различий многомерных сигналов, таких как байесовские, минимаксные и корреляционные подходы.

Материалы и методы

Исходными данными в рамках исследования служили временные ряды параметров, полученных при регистрации динамической подписи: координаты пера по осям X и Y, давление на экран, скорости и ускорения вдоль трёх пространственных осей. Эти параметры представляют собой многомерные кривые, каждое измерение которых соответствует одной из характеристик сигнала.

Для повышения информативности и устойчивости распознавания использовалось построение вторичных признаков. В контексте биометрической идентификации на основе динамической подписи под вторичными признаками многомерных траекторий понимается совокупность характеристик, полученных в результате предварительной обработки исходных сигналов [5]. К таким признакам относятся различные статистические параметры (средние значения, дисперсии, энтропии и др.), а также спектральные компоненты, извлекаемые с помощью преобразований Фурье,

косинусного и вейвлет-анализа [6]. Полученные векторы признаков далее используются в качестве входных данных для нейросетевых моделей классификации, в частности, многослойных персепtronов (MLP) и сетей с обратным распространением ошибки (BProp).

Решение задачи классификации в данной постановке можно интерпретировать как формализованную статистическую игру между двумя сторонами: системой распознавания (условный игрок А) и множеством возможных объектов (игрок В). Каждая сторона действует в рамках определённой стратегии, а сама игра описывается через структуру, задающую вероятности, выигрыши и риски. Основная цель системы распознавания – свести к минимуму вероятный риск ошибочной идентификации, для чего и подбирается соответствующая стратегия принятия решений [7]. В зависимости от доступной априорной информации и характера функции потерь применяются разные подходы: байесовский, минимаксный или стратегия Неймана – Пирсона.

Важно отметить, что при ряде допущений (например, симметрии распределений и равновероятности классов) перечисленные стратегии приводят к одинаковым решающим правилам, различаясь лишь в способах определения порогов принятия решений.

Если наблюдения организованы в виде непрерывной последовательности измерений динамической подписи, то идентификация может опираться не только на анализ каждой индивидуальной кривой, но и на агрегированные признаки, полученные из совокупности кривых. Такой подход позволяет выявлять изменения принадлежности подписи на

основе широкой палитры статистических характеристик, тем самым повышая надёжность последующей классификации [8].

Тогда распознавание осуществляется в квазиреальном масштабе времени (необходим интервал времени на получении всех кривых и расчет их статистических характеристик). На вход НС поступают:

1) математическое ожидание m_x каждой кривой:

$$m_x = \frac{1}{n} \sum_{i=1}^n x_i, \quad e_{mx} = \frac{\sigma}{\sqrt{n}}, \quad (1)$$

где n – количество отсчетов измеряемого параметра динамической подписи; σ – среднеквадратическое отклонение измеряемого параметра динамической подписи;

2) среднеквадратическое отклонение σ :

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - m_x)^2}, \quad e_{\sigma} = \frac{\sigma}{\sqrt{2n}}; \quad (2)$$

3) коэффициент вариации и его ошибка e_9 :

$$9 = \frac{\sigma}{m_x} 100\%, \quad e_9 = 9 \sqrt{\frac{0,5 + 0,00019^2}{n}}; \quad (3)$$

4) средняя разность Джинни:

$$g = \frac{1}{n(n-1)} \sum_{\substack{i,j=1 \\ i \neq j}}^n |x_i - x_j|, \quad (4)$$

5) удельная энтропия кривой:

$$H = \frac{1}{n} \sum_{i=1}^k a_i \log_2 a_i,$$

$$k = 3,32 \lg n + 1 = 1,44 \ln n + 1, \quad (5)$$

где n – число отсчетов измеряемого параметра динамической подписи;

6) показатель точности регистрации кривой:

$$p = \frac{1}{N} \sum_{s=1}^N \left(\frac{e_{s \text{ mx}}}{m_{s x}} 100\% \right), \quad (6)$$

$$e_p = p \sqrt{\frac{1}{2n} + \left(\frac{p}{100} \right)^2},$$

где N – количество измеряемых параметров динамической подписи; s – индекс измеряемого параметра динамической подписи; $m_{s x}$ – математическое ожидание s -го измеряемого параметра динамической подписи; $e_{s \text{ mx}}$ – ошибка математического ожидания s -го измеряемого параметра динамической подписи.

7) параметр эквивокации между двумя реализациями № 1 (состояние покоя пользователя) и № 2 (идентифицируемое) постановки подписи, вычисляемый как

$$D = \frac{1}{N} \sum_{s=1}^N |I_s^1 - I_s^2|, \quad (7)$$

где N – количество измеряемых параметров динамической подписи; I_s^1 – избыточность первой реализации многомерной кривой; I_s^2 – избыточность второй реализации многомерной кривой,

Показатель эквивокации отражает степень структурных изменений, происходящих в процессе выполнения подписи в пространстве признаков, поддающихся измерению. Данный параметр позволяет количественно оценить различие между двумя реализациями одного и того же биометрического действия (например, подписи), выполненного пользователем в идентичных условиях.

Для вычисления эквивокации формируются два вектора статистических характеристик, соответствующие различным временным отрезкам – первому и второму интервалу регистрации сигнала. Эти векторы содержат числовые описания динамики подписи и включают такие параметры, как математическое ожидание, дисперсия, энтропия и прочее. Сравнение указанных векторов позволяет выявить латентные изменения в структуре поведения, даже несмотря на то, что пользователь формально находился в одном и том же функциональном состоянии в обоих интервалах. Таким образом, эквивокация служит чувствительным индикатором внутренней вариативности моторных характеристик при выполнении подписи [9].

В дополнение к статистике применялись спектральные методы анализа: дискретное преобразование Фурье, дискретное косинусное преобразование и дискретное вейвлет-преобразование. Целью было выявление устойчивых частотных компонентов и локальных изменений сигнала, отражающих индивидуальные особенности пользователя. Результаты преобразований представлялись в виде коэффициентов, служащих входными параметрами для обучения нейросети [10]. Параллельно нейросетевому подходу проводилось сравнение с традиционными стратегиями классификации: байесовской, минимаксной и методом корреляции [11]. Это позволило оценить эффективность предложенной модели на фоне классических методов.

Результаты и их обсуждение

В качестве рабочей гипотезы рассматривалась идея о том, что при переводе анализируемых данных из амплитудной в частотную область могут проявиться характерные признаки или

устойчивые взаимосвязи параметров, которые могут быть использованы в качестве показателей для выработки критериев – базовых элементов разрабатываемых классификаторов.

Основные преобразования исходных данных реализованы на базе

дискретного преобразования Фурье (ДПФ) [12]. На рисунке 1 и 2 приведены графики положительных значений результатов ДПФ кривых, полученные для параметров: площадь пятна нажатия на экран при постановке подписи пальцем, а не стилусом, и ускорение по оси Z.

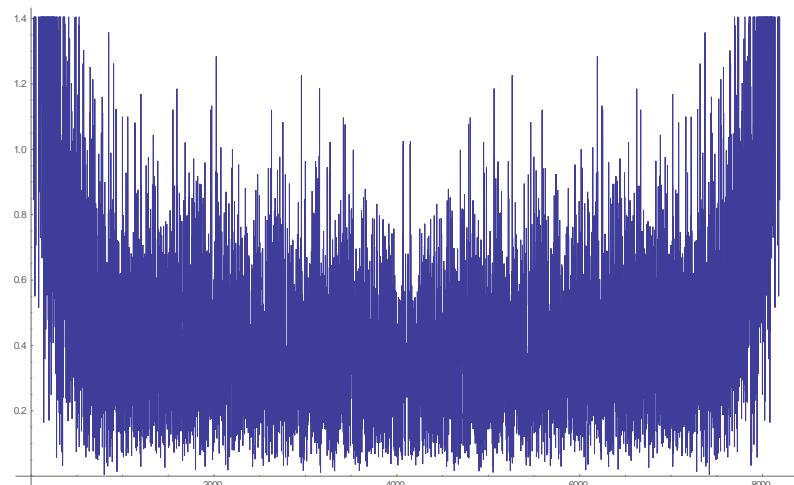


Рис. 1. Результаты ДПФ для параметра «площадь пятна нажатия на экран»

Fig. 1. DFT results for the "touch area on the screen" parameter

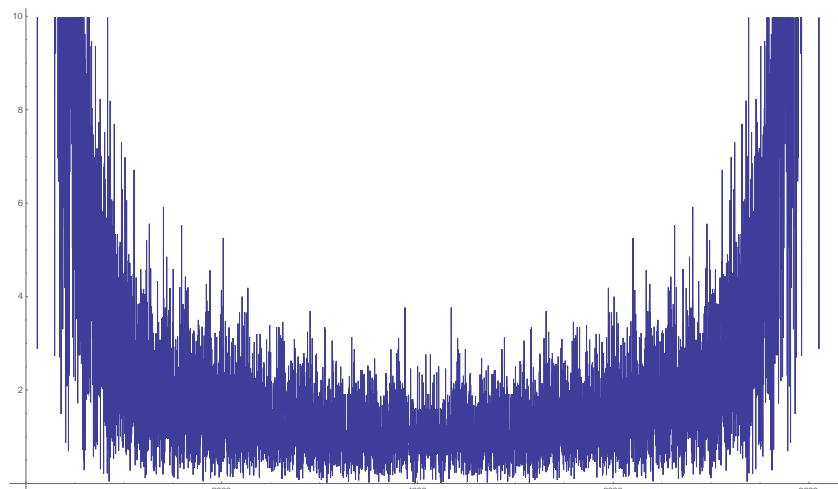


Рис. 2. Результаты ДПФ для параметра «ускорение по оси Z»

Fig. 2. DFT results for the "Z-axis acceleration" parameter

Анализ преобразованных параметров по Фурье (включая не представленные на графиках координаты по оси X, координаты по оси Y, давление на экран, скорость по оси X, скорость по оси Y, ускорение по оси X, ускорение

по оси Y), показал нестабильные (от выборки к выборке) результаты. Аналогичная ситуация наблюдалась при проведении дискретного косинус – преобразования (ДКП) в соответствии с выражениями:

$$\text{ДКП-I: } \sqrt{\frac{2}{n-1}} \left(\frac{u_1}{2} + \sum_{r=2}^{n-1} u_r \cos \left(\frac{\pi}{n-1} (r-1)(s-1) \right) + (-1)^{s-1} \frac{u_n}{2} \right), \quad (8)$$

$$\text{ДКП-II: } \frac{1}{\sqrt{n}} \sum_{r=1}^n u_r \cos \left(\frac{\pi}{n} \left(r - \frac{1}{2} \right) (s-1) \right), \quad (9)$$

$$\text{ДКП-III: } \frac{1}{\sqrt{n}} \left(u_1 + 2 \sum_{r=2}^n u_r \cos \left(\frac{\pi}{n} (r-1) \left(s - \frac{1}{2} \right) \right) \right), \quad (10)$$

$$\text{ДКП-IV: } \sqrt{\frac{2}{n}} \left(\sum_{r=1}^n u_r \cos \left(\frac{\pi}{n} \left(r - \frac{1}{2} \right) \left(s - \frac{1}{2} \right) \right) \right). \quad (11)$$

На рисунке 3 и 4 приведены графики положительных значений результатов

ДКП четырех типов, полученные для параметра «давление».

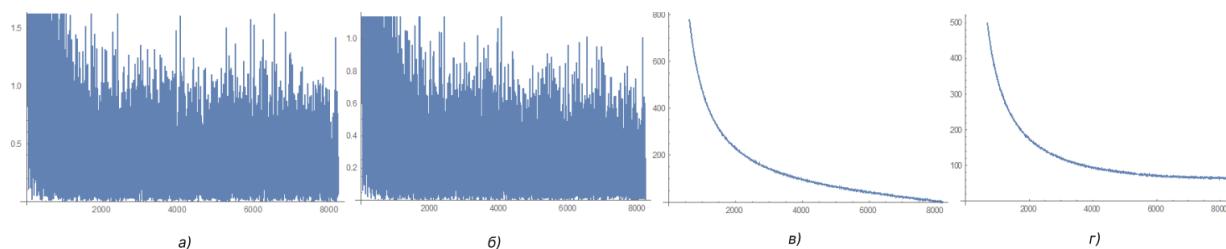


Рис. 3. Результаты дискретного косинусного преобразования одной кривой подписи:
а – FourierDCT+1; б – FourierDCT+2; в – FourierDCT+3; г – FourierDCT+4

Fig. 3. Results of the discrete cosine transform of a single signature curve:
а – FourierDCT+1; б – FourierDCT+2; в – FourierDCT+3; г – FourierDCT+4

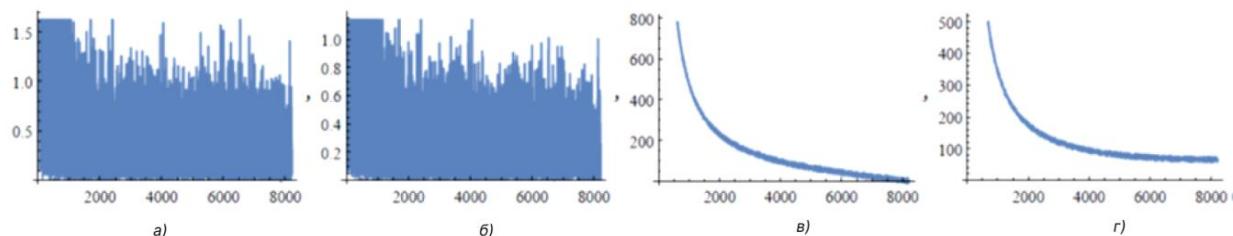


Рис. 4. Результаты дискретного синусного преобразования одной кривой подписи:
а – FourierDCT+1; б – FourierDCT+2; в – FourierDCT+3; г – FourierDCT+4

Fig. 4. Results of the discrete sine transform of a single signature curve:
а – FourierDCT+1; б – FourierDCT+2; в – FourierDCT+3; г – FourierDCT+4

Коэффициенты гармонических преобразований, так же как и статистические моменты, показали статистическую

устойчивость при разделении пространства признаков на классы аутентифицируемых пользователей¹.

¹ Пат. 2553094 Российская Федерация, МПК G06K 9/62, G06T. Способ идентификации личности по рукописному тексту /

Добрица В. П., Милых В. А.; заявитель и патентообладатель ФГБОУ ВПО ЮЗГУ. № 2014120101/08; заявл. 20.05.2014; опубл. 10.06.2015, Бюл. № 16. 11 с.

Таким образом, проведение частотного анализа с целью выявления характерных признаков анализируемого сигнала представляется целесообразным.

К предмету гармонического анализа относятся все разновидности временно-частотного представления, элементами которых являются, в том числе, и вейвлет-преобразования [13].

Принимая во внимание дискретный характер обрабатываемого сигнала, по отношению к нему проверялся аппарат

дискретного вейвлет-преобразования (ДВП) [14]:

$$y[n] = (x \cdot g)[n] = \sum_{k=-\infty}^{\infty} x[k]g[n-k]. \quad (12)$$

В результате получаются детализирующие коэффициенты и коэффициенты аппроксимации, которые в качестве вторичных признаков подавались на НС [15]. Описанное преобразование поясняет схема, представленная ниже (рис. 5).



Рис. 5. Схема разложения кривой подписи в ДВП

Fig. 5. Diagram of signature curve decomposition into DWT components

Путем отбрасывания ряда коэффициентов (детализирующих или, напротив, аппроксимирующих) имеется возможность реализовать низко- или высокочастотную фильтрацию входного сигнала [16].

Предположительно, что данные преобразования, будучи разновидностью временно-частотного представления, должны позволить локализовать искомый фрагмент сигнала на временной оси, что в конечном счете позволит решить задачу распознавания и классификации образцов подписи.

Применительно к классу решаемых задач наиболее эффективными являются вейвлет-сглаживание, удаление шума и компрессия сигналов при выборе оптимального базиса и при изменяемом пороге удаления части вейвлет-коэффициентов.

В дальнейшем вейвлет-коэффициенты или статистические признаки кривых подаются на вход НС для последующей классификации подписи.

Протокол наблюдений Ω_1 прецедентов вида (13) представляет собой матрицу обучающей выборки вида «объект-признак»:

$$\Omega_1 = \begin{bmatrix} k_1^1 & \dots & k_{L_k}^1 & v_1^1 & \dots & v_{L_v}^1 & y_1^1 & \dots & y_m^1 & p_1^1 & \dots & p_{L_p}^1 & z_1^1 & \dots & z_{L_z}^1 & q_1^1 & \dots & q_N^1 \\ \dots & \dots \\ k_1^i & \dots & k_{L_k}^i & v_1^i & \dots & v_{L_v}^i & y_1^i & \dots & y_m^i & p_1^i & \dots & p_{L_p}^i & z_1^i & \dots & z_{L_z}^i & q_1^i & \dots & q_N^i \\ \dots & \dots \\ k_1^L & \dots & k_{L_k}^L & v_1^L & \dots & v_{L_v}^L & y_1^L & \dots & y_m^L & p_1^L & \dots & p_{L_p}^L & z_1^L & \dots & z_{L_z}^L & q_1^L & \dots & q_N^L \end{bmatrix}, \quad (13)$$

где $(n + L_z + N)$ – размер параметрического описания каждого прецедента; L – количество строк матрицы, характеризует объем обучающей выборки.

Каждый из векторов $\{Z^i\}_{i=1}^L$, зафиксированный в момент времени t_i , $i = \overline{1, L}$, содержит параметрическое описание кривых подписи в виде

$$Z^i = (z_1^i, z_2^i, \dots, z_j^i, \dots, z_{L_z}^i), \quad (14)$$

$$i = \overline{1, L}, j = \overline{1, L_z},$$

где z_j^i – j -й параметр описания подписи, определенный в i -й момент времени; L_z – общее количество признакового пространства описания подписи.

На этапе синтеза модели распознавания вида подписи (т. е. ее принадлежность) вектор $\{Z^i\}_{i=1}^L$ является выходным для отображения $\Psi_1: \{X\} \rightarrow \{Z\}$ и входным для отображения $\Psi_2: \{P, Z\} \rightarrow \{Q\}$.

Этап формирования протокола матрицы Ω_1 завершается предобработкой значений матрицы (13). Как входами, так и выходами модели распознавания вида подписи могут быть совершенно разнородные величины. Результаты синтеза и использования модели не должны зависеть от единиц измерения этих величин.

Основной операцией предварительной обработки является приведение значений $\{X^i\}_{i=1}^L$ к единичному масштабу, что обеспечивается нормировкой каждой j -й переменной $x_1^i, x_2^i, \dots, x_p^i, \dots, x_n^i$,

$p = \overline{1, n}$, $i = \overline{1, L}$ на диапазон разброса ее значений по всем отсчетам $i = \overline{1, L}$.

Этап структурного синтеза модели распознавания заключается в определении количества слоев MLP-классификатора, числа рабочих и избыточных нейронов в каждом слое, задания вида функции активации в каждом слое, количества избыточных нелинейных преобразователей в каждом слое [17]. Основной принцип использования модели на основе MLP-классификатора состоит в неизменности форматов данных, используемых для параметрического синтеза и данных, на основе которых осуществляется распознавание вида подписи [18].

Так как модель реализует два отображения: $\Psi_1: \{X\} \rightarrow \{Z\}$ и $\Psi_2: \{P, Z\} \rightarrow \{Q\}$, рассмотрим структуру нейроклассификатора каждого из них.

На рисунке 6 представлена схема подачи компонент обучающих векторов, образующих строки матриц. Распознаваемые параметры находятся в крайних (справа) столбцах обучающей выборки.

Для отображения $\Psi_1: \{X\} \rightarrow \{Z\}$ $N_2 = (n + L_z)$, для отображения $\Psi_2: \{P, Z\} \rightarrow \{Q\}$ $N_2 = (N + L_p + L_z)$.

Таким образом, определённая структура MLP-классификатора для отображений $\Psi_1: \{X\} \rightarrow \{Z\}$, $\Psi_2: \{P, Z\} \rightarrow \{Q\}$ и сформированные по данным протокола Ω_1 обучающие выборки позволяют перейти к параметрическому синтезу модели распознавания вида подписи и ее принадлежности [19].

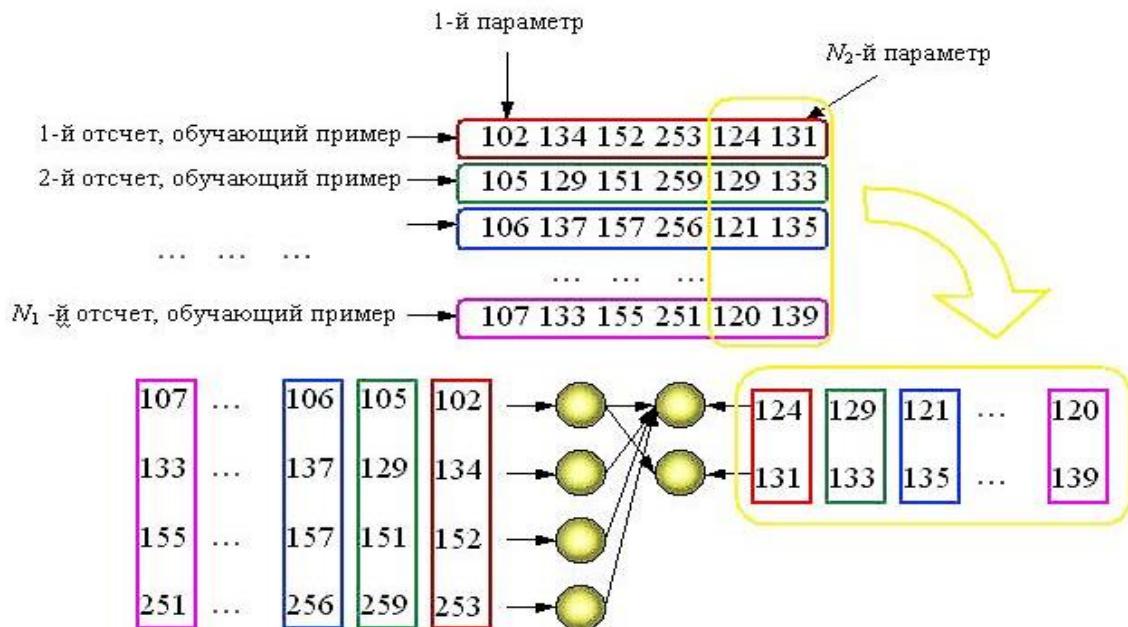


Рис. 6. Структура «Вход-выход» для обучающих векторов НС идентификации фрагмента многомерной кривой

Fig. 6. Input-output structure for identification training vectors HC fragment of a multidimensional curve

Результаты показывают, что использование структурно-адаптивной нейросетевой архитектуры в пространстве вторичных признаков позволяет достигать высокой точности идентификации, устойчивой к вариативности поведения пользователей и шумам входных данных. Объединение статистических и спектральных признаков создаёт основу для построения надёжных биометрических систем.

Выводы

Выполненное исследование подтвердило эффективность применения нейросетевых моделей, структурно адаптированных под пространство вторичных признаков, в задаче биометрической идентификации по динамической подпись. Использование статистических, гармонических и вейвлет-преобразованных характеристик позволило существенно повысить точность и

устойчивость идентификации даже в условиях неопределённости и масштабирования пользовательской базы.

Наиболее информативными оказались признаки, полученные после вейвлет-преобразования и интеграции со статистическими характеристиками. Такая комбинация позволила обеспечить прирост точности до 35% по сравнению с классическими статистическими методами и улучшение результатов на 5–15% по сравнению с метрическими подходами. Показано, что нейросетевой классификатор на основе архитектуры MLP способен эффективно заменять традиционные схемы принятия решений, особенно при наличии шумов, нестабильного поведения пользователей и ограниченной априорной информации. Сравнение с байесовской стратегией показало, что при наличии априорных вероятностей классов различие в результатах минимально. Однако в условиях

неопределенности минимаксная стратегия уступала MLP-модели как по точности, так и по способности к адаптации. Наибольшее преимущество нейросетевой архитектуры проявилось в условиях, когда пользовательские данные демонстрировали значительные вариации. Визуализация результатов, полученных с помощью преобразований, подтверждает наличие устойчивых признаков в частотной области для каждого пользователя. Это особенно выражено в области низкочастотных коэффициентов ДКП и аппроксимационных коэффициентов ДВП. Эти признаки обладают потенциальной

дискретной инвариантностью и могут быть полезны при построении обобщающих идентификаторов.

Разработанный синтез нейросетевых моделей биометрического распознавания может быть применен для построения гибких систем аутентификации в реальном времени и адаптирован под иные биометрические каналы, где возможно формирование вторичных признаков. В дальнейшем планируется исследование влияния различных стратегий ансамблирования и интеграции дополнительных сенсорных каналов в общую систему идентификации.

Список литературы

1. Ломов Н., Петрова Д., Рязанцева Ю. Биометрия в финансовой сфере 2020: Выгоды для потребителя. URL: <https://www.fintechru.org/analytics/analiticheskaya-zapiska-po-biometrii/?ysclid=lvwb2xh8z610856013> (дата обращения: 08.09.2025).
2. Отчет об анализе размера, доли и тенденций мирового рынка биометрических систем – обзор отрасли и прогноз до 2032 года // Data Bridge.
3. Танцеров А. Х., Данилов Е. А. Современные подходы к распознаванию и аутентификации подписей: методы обработки изображений // XXI век: итоги прошлого и проблемы настоящего плюс. 2025. Т. 14, № 2 (70). С. 71–76. EDN SCSZTT
4. Advances in Computer Vision and Pattern Recognition / S. Marcel, M. S. Nixon, J. Fierrez, N. Evans. Springer, 2023. 522 р.
5. Старовойтов В. В., Ахунджанов У. Ю. Распределение значений локальной кривизны как структурный признак для off-line верификации рукописной подписи // Системный анализ и прикладная информатика. 2023. № 2. С. 49–58.
6. Танцеров А. Х., Данилов Е. А., Мартышкин А. И. Обзор и сравнение некоторых методов аутентификации подписи по динамическим параметрам // Вестник Рязанского государственного радиотехнического университета. 2025. № 92. С. 213–224. <https://doi.org/10.21667/1995-4565-2025-92-213-224>
7. Carmona P. L., Salvador S. A., Fred L. N. Mathematical Methodologies in Pattern Recognition and Machine Learning: Contributions from the International Conference on Pattern Recognition Applications and Methods. Springer, 2022. 204 р.
8. Иванов А. И. Использование обратного критерия хи-квадрат Пирсона при мультиплективном синтезе новых статистических критериев из уже известных критериев для проверки гипотезы нормального распределения данных малых выборок // Известия высших учебных заведений. Поволжский регион. Технические науки. 2023. № 2 (66). С. 15–23. EDN LPXYSF

9. Иванов А. И. Синтез новых интегро-дифференциальных статистических критериев и эквивалентных им искусственных нейронов для малых выборок. Самара: Издательство Самарского научного центра РАН, 2022. С. 161–163. EDN JHGXB1
10. Танцеров А. Х., Данилов Е. А. Кинематическая модель формирования эталонных динамических параметров подписи пользователя // Вестник Рязанского государственного радиотехнического университета. 2025. № 92. С. 170–178. <https://doi.org/10.21667/1995-4565-2025-92-170-178>
11. Jain A. K., Griess F. D., Connell S. D. Online signature verification // Pattern Recognition. 2022. N 35. P. 2963–2972.
12. Wijdan Yassen A. AlKarem, Khawla H. Ali, Eman Thabet Khalid. Handwritten Signature Verification Method Using Convolutional Neural Network // Iraqi Journal for Electrical And Electronic Engineering. 2024. N 20 (2), P. 77–84. <https://doi.org/10.37917/ijeee.20.2.7>
13. DeepSign: Deep learning for signature analysis / R. Tolosana, R. Vera-Rodriguez, J. Fierrez, J. Ortega-Garcia // IEEE Transactions on Information Forensics and Security. 2020. N 15(1). P. 229–240. <https://doi.org/10.1109/TBIOM.2021.3054533>
14. Off-line handwritten signature GPDS-960 corpus / J. F. Vargas, M. A. Ferrer, C. M. Travieso, J. B. Alonso // IEEE Transactions on Information Forensics and Security. 2017. N 12(3). P. 596–605. <https://doi.org/10.1109/ICDAR.2007.4377018>
15. Learning hierarchical features for scene labeling / C. Farabet, C. Couprie, L. Najman, Y. LeCun. // IEEE Transactions on Pattern Analysis and Machine Intelligence 2023. N 8 (35). P. 1915–1929.
16. Batista L., Granger E., Sabourin R. Dynamic selection of generative – discriminative ensembles for off-line signature verification // Pattern Recognition. 2016. N 52. P. 182–197. <https://doi.org/10.1016/j.patcog.2011.10.011>
17. Ахунджанов У. Ю., Старовойтов В. В. Предварительная обработка изображений рукописных подписей для последующего распознавания // Системный анализ и прикладная информатика. 2022. № 2. С. 4–9.
18. Иванов А. И., Куприянов Е. Н. Синтез новых более мощных статистических критериев через мультиплективное объединение классических критериев Фроцини и Мурота – Такеучи с критерием Херста для проверки гипотезы нормальности малых выборок // Надежность. 2022. Т. 22, № 1. С. 52–55. <https://doi.org/10.21683/1729-2646-2022-22-1-52-55>. EDN CWHSKS
19. Вдовкина С. А., Шибанов С. В. Библиотека для онлайн-верификации рукописной подписи // Вестник Пензенского государственного университета. 2022. № 2. С. 76–84.

References

1. Lomov N., Petrova D., Ryazantseva Yu. Biometrics in the financial sector 2020: Benefits for the consumer. URL: <https://www.fintechru.org/analytics/analiticheskaya-zapiska-pobiometrii/?ysclid=lvwb2xh8z610856013> (accessed 08.09.2025).
2. Report on the analysis of the size, share and trends of the global biometric systems market – an overview of the industry and forecast up to 2032 // Data Bridge.

3. Dancers A.Kh., Danilov E.A. Modern approaches to the recognition and authentication of signatures: methods of image processing. *XXI vek: itogi proshlogo i problemy nastoyashchego plus = XXI Century: Results of the Past and Problems of the Present Plus.* 2025;14(2):71–76. (In Russ.) EDN SCSZTT
4. Marcel S., Nixon M.S., Fierrez J., Evans N. *Advances in Computer Vision and Pattern Recognition*. Springer, 2023. 522 p.
5. Starovoitov V.V., Akhundzhanov U.Yu. Distribution of local curve values as a structural feature for off-line verification of a handwritten signature. *Sistemnyi analiz i prikladnaya informatika = System Analysis and Applied Informatics*. 2023;(2):49–58. (In Russ.)
6. Dancers A.Kh., Danilov E.A., Martyshkin A.I. Review and comparison of some methods of signature authentication by dynamic parameters. *Vestnik Ryazanskogo gosudarstvennogo radiotekhnicheskogo universiteta = Bulletin of the Ryazan State Radio Engineering University*. 2025;(92):213–224. (In Russ.) <https://doi.org/10.21667/1995-4565-2025-92-213-224>
7. Carmona P.L., Salvador S.A., Fred L.N. *Mathematical Methodologies in Pattern Recognition and Machine Learning: Contributions from the International Conference on Pattern Recognition Applications and Methods*. Springer; 2022. 204 p.
8. Ivanov A.I. Using the inverse chi-square Pearson criterion in the multi-plicative synthesis of new statistical criteria from already known criteria to test the hypothesis of the normal distribution of these small samples. *Izvestiya vysshikh uchebnykh zavedenii. Povolzhskii region. Tekhnicheskie nauki = News of Higher Educational Institutions. Volga region. Technical Sciences*. 2023;(2):15–23. (In Russ.) EDN LPXYSF
9. Ivanov A.I. Synthesis of new integro-differential statistical criteria and their equivalent artificial neurons for small samples. Samara: Izdatel'stvo Samarskogo nauchnogo tsentra RAN; 2022. P. 161–163. (In Russ.) EDN JHGXB1
10. Dancers A.Kh., Danilov E.A. Kinematic model of the formation of reference dynamic parameters of the user's signature. *Vestnik Ryazanskogo gosudarstvennogo radiotekhnicheskogo universiteta = Bulletin of the Ryazan State Radio Engineering University*. 2025;(92):170–178. (In Russ.) <https://doi.org/10.21667/1995-4565-2025-92-170-178>
11. Jain A. K., Griess F.D., Connell S.D. Online signature verification. *Pattern Recognition*. 2022;(35):2963–2972.
12. Wijdan Yassen A. AlKarem, Khawla H. Ali, Eman Thabet Khalid. Handwritten Signature Verification Method Using Convolutional Neural Network. *Iraqi Journal for Electrical and Electronic Engineering*. 2024;(20):77–84. <https://doi.org/10.37917/ijeee.20.2.7>
13. Tolosana R., Vera-Rodriguez R., Fierrez J., Ortega-Garcia J. DeepSign: Deep learning for signature analysis. *IEEE Transactions on Information Forensics and Security*. 2020;(15):229–240. <https://doi.org/10.1109/TBIOM.2021.3054533>
14. Vargas J.F., Ferrer M.A., Travieso C.M., Alonso J.B. Off-line handwritten signature GPDS-960 corpus. *IEEE Transactions on Information Forensics and Security*. 2017;(12):596–605. <https://doi.org/10.1109/ICDAR.2007.4377018>
15. Farabet C., Couprie C., Najman L., LeCun Y. Learning hierarchical features for scene labeling. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2023;(8):1915–1929.

-
16. Batista L., Granger E., Sabourin R. Dynamic selection of generative – discriminative en-sembles for off-line signature verification. *Pattern Recognition*. 2016;(52):182–197. <https://doi.org/10.1016/j.patcog.2011.10.011>
 17. Akhundzhanov U.Yu., Starovoitov V.V. Preliminary processing of images of hand-written signatures for subsequent recognition. *Sistemnyi analiz i prikladnaya informatika = System Analysis and Stock Informatics*. 2022;(2):4–9. (In Russ.)
 18. Ivanov A.I., Kupriyanov E.N. Synthesis of new more powerful statistical Cree-Terii through the multiplicative union of the classical Frozini and Murota – Takeuchi criteria with the Hirst criterion to test the hypothesis of the normality of small samples. *Nadezhnost' = Reliability*. 2022;22(1):52–55. (In Russ.) <https://doi.org/10.21683/1729-2646-2022-22-1-52-55>. EDN CWHSKS
 19. Vdovkina S.A., Shibanov S.V. Library for online verification of handwritten signatures. *Vestnik Penzenskogo gosudarstvennogo universiteta = Bulletin of Penza State University*. 2022;(2):76–84. (In Russ.)

Информация об авторах / Information about the Authors

Данилов Евгений Александрович,
кандидат технических наук, доцент
кафедры программирования, Пензенский
государственный технологический институт,
г. Пенза, Российская Федерация,
e-mail: danilov@penzgtu.ru,
Researcher ID: OUI-0415-2025,
ORCID: 0000-0003-4114-7036

Evgeny A. Danilov, Candidate of Sciences
(Engineering), Associate Professor
at the Department of Programming,
Penza State Technological Institute,
Penza, Russian Federation,
e-mail: danilov@penzgtu.ru,
Researcher ID: OUI-0415-2025,
ORCID: 0000-0003-4114-7036

Танцеров Александр Хабибуллоевич,
аспирант кафедры программирования,
Пензенский государственный технологический
институт, г. Пенза, Российская Федерация,
e-mail: alex.tancerov@mail.ru,
Researcher ID: O-0537-2025,
ORCID: 0009-0006-7695-0514

Alexander K. Tantserov, Postgraduate
at the Department of Programming,
Penza State Technological Institute,
Penza, Russian Federation,
e-mail: alex.tancerov@mail.ru,
Researcher ID: O-0537-2025,
ORCID: 0000-0003-4114-7036