УДК 004.85:004.946
DOI: 10.26102/2310-6018/2026.62.11.008

Нечеткие нейронные сети для классификации эмоциональных состояний и оценки рисков в VR-экспозиционной терапии

Д.А. Поздняков, Т.В. Азарнова✉

Воронежский государственный университет, Воронеж, Российская Федерация

Резюме. Современный этап развития VR-направлений характеризуется экспоненциальным ростом внедрения VR-технологий в сфере здравоохранения. Способность VR-систем понимать и реагировать на эмоции пользователя открывает революционные возможности в здравоохранении и психотерапии. Российские и зарубежные исследования в данной сфере показывают, что VR-технологии могут обеспечить персонализированную и адаптивную терапию при тревожных расстройствах, депрессии и посттравматических стрессовых расстройствах. Данные технологии могут в реальном времени отслеживать состояние пациента и динамически подстраивать сложность упражнений в рамках когнитивно-поведенческой, экспозиционной терапии и нейрореабилитации. Особую актуальность имеют современные исследования, направленные на реализацию технологий адаптивного мониторинга эмоциональных состояний пользователей виртуальной реальности (VR) на основе подходов искусственного интеллекта. Это направление позволит осуществить переход от статичных к по-настоящему адаптивным и иммерсивным системам, базирующимся на аффективных вычислениях и достижениях искусственного интеллекта. В работе анализируется метод адаптивного мониторинга эмоциональных состояний пользователей виртуальной реальности на основе нечетких нейронных сетей ANFIS (Adaptive Neuro-Fuzzy Inference System). Апробация предложенного подхода осуществлялась на данных окулографии (eye-tracking), представленных в открытом датасете VREED. Используется гибридное обучение, совмещающее метод наименьших квадратов при настройке параметров заключений и градиентный спуск с адаптивным шагом Adam при настройке параметров гауссовых функций принадлежности. Выход нейросети формирует нечеткий индекс дистресса (Fuzzy Distress Index, FDI), позволяющий в реальном времени принимать решение об адаптации или прерывании VR-сессий. Предложенная архитектура ANFIS достигает Accuracy = 0,77 и F1 = 0,77 на задаче четырехклассовой классификации по двумерной модели аффекта (валентность × активация), что существенно превосходит результаты применения FNN на упорядоченных нечетких числах (OFN), KNN и деревьев решений. Статистическая значимость различий подтверждается критерием МакНемара.

Ключевые слова: нечеткие нейронные сети, ANFIS, окулография, виртуальная реальность, VR-экспозиционная терапия, классификация эмоций, нечеткий индекс дистресса, оценка рисков, упорядоченные нечеткие числа.

Для цитирования: Поздняков Д.А., Азарнова Т.В. Нечеткие нейронные сети для классификации эмоциональных состояний и оценки рисков в VR-экспозиционной терапии. *Моделирование, оптимизация и информационные технологии.* 2026;14(11). URL: https://moitvivt.ru/ru/journal/article?id=2612 DOI: 10.26102/2310-6018/2026.62.11.008

Fuzzy neural networks for emotional state classification and risk assessment in VR exposure therapy

D.A. Pozdnyakov, T.V. Azarnova✉

Voronezh State University, Voronezh, the Russian Federation

© Поздняков Д.А., Азарнова Т.В., 2026

Abstract. The current stage of VR development is characterized by exponential growth in the implementation of VR technologies in healthcare. The ability of VR systems to understand and respond to user emotions opens up revolutionary possibilities in healthcare and psychotherapy. Russian and international research in this field demonstrates that VR technologies can provide personalized and adaptive therapy for anxiety disorders, depression, and Post-Traumatic Stress Disorder. These technologies can monitor a patient's condition in real time and dynamically adjust the difficulty of exercises within cognitive-behavioral therapy, exposure therapy, and neurorehabilitation. Of particular relevance is current research aimed at implementing adaptive monitoring technologies for the emotional states of virtual reality (VR) users based on artificial intelligence approaches. This approach will enable the transition from static to truly adaptive and immersive systems based on affective computing and advances in artificial intelligence. This paper analyzes a method for adaptive monitoring of the emotional states of virtual reality (VR) users based on fuzzy neural networks, ANFIS (Adaptive Neuro-Fuzzy Inference System). The proposed approach was tested using eye-tracking data available in the open-source VREED dataset. The study utilizes hybrid learning, combining the least-squares method for configuring inference parameters and gradient descent with an adaptive Adam step for configuring Gaussian membership function parameters. The neural network output generates a fuzzy distress index (FDI), which enables real-time decisions about adapting or terminating VR sessions. The proposed ANFIS architecture achieves Accuracy = 0.77 and F1 = 0.77 on a four-class classification task using a two-dimensional affect model (valence × activation), significantly outperforming the results of using FNN on ordered fuzzy numbers (OFN), KNN, and decision trees. The statistical significance of the differences is confirmed by the McNemar test.

Keywords: fuzzy neural networks, ANFIS, oculography, virtual reality, VR exposure therapy, emotion classification, fuzzy distress index, risk assessment, ordered fuzzy numbers.

For citation: Pozdnyakov D.A., Azarnova T.V. Fuzzy neural networks for emotional state classification and risk assessment in VR exposure therapy. *Modeling, Optimization and Information Technology.* 2026;14(11). (In Russ.). URL: https://moitvivt.ru/ru/journal/article?id=2612 DOI: 10.26102/2310-6018/2026.62.11.008

Введение

VR-экспозиционная терапия (VRET) применяется при лечении фобий, посттравматических стрессовых расстройств (ПТСР) и тревожных состояний. Данный вид терапии позволяет пациенту постепенно сталкиваться с пугающими стимулами в контролируемой иммерсивной среде [1, 2]. Ключевое условие безопасности VRET – непрерывный мониторинг аффективного состояния пациента с возможностью своевременного прерывания или смягчения экспозиции при признаках острого дистресса [3].

Данные окулографии (eye-tracking) – амплитуды саккад, длительность фиксаций, частота морганий, параметры микросаккад – являются информативными, неинвазивными маркерами аффективного состояния, доступными в реальном времени через встроенные сенсоры современных VR-гарнитур [4, 5]. Саккады представляют собой быстрые, скачкообразные движения глаз, а микросаккады являются их малоамплитудной разновидностью. Эти параметры являются чувствительными индикаторами когнитивной нагрузки и эмоционального возбуждения. Исследования показывают, что изменения в паттернах этих движений служат надежными маркерами перехода в состояние повышенной эмоциональной активности. Длительность фиксаций, то есть время, в течение которого взгляд удерживается на одной точке, тесно связана с глубиной когнитивной обработки и эмоциональной значимостью стимула. В контексте VR этот параметр позволяет понять, на каких элементах виртуальной среды пользователь фокусирует внимание и как эмоционально на них реагирует. Изменения в длительности фиксаций могут сигнализировать о таких состояниях, как удивление, интерес или, наоборот, скука. Частота морганий также является классическим крайне

эффективным маркером, отражающим уровень эмоционального напряжения и когнитивной нагрузки. В состоянии стресса или сильной эмоциональной вовлеченности частота морганий может меняться. Это делает данный параметр ценным индикатором для систем, стремящихся оценить психоэмоциональное состояние пользователя в реальном времени. Современные исследования подчеркивают, что наибольшая точность в распознавании эмоций достигается не при анализе какого-то одного показателя, а при мультимодальном подходе, который объединяет все эти данные. Бенчмарк-оценки показывают, что объединение (fusion) многогранных окулографических сигналов значительно улучшает точность распознавания эмоций. Окулографические данные представляют собой не просто набор технических показателей, а ключ к пониманию эмоционального состояния пользователя в VR. Их неинвазивность, доступность в реальном времени и высокая информативность, особенно при комплексном анализе, делают их идеальным инструментом для создания эмоционально-адаптивных виртуальных сред, способных реагировать на состояние пользователя и улучшать его опыт в терапии и других сферах. Датасет VREED (VR Eyes: Emotions Dataset) содержит записи 34 испытуемых в 12 иммерсивных 360°-видеосредах, размеченных по двумерной модели аффекта (валентность × активация) [6]. Несмотря на то, что датасет включает также физиологические сигналы (ЭДА, фотоплетизмография), настоящая работа сфокусирована на окулографических данных как модальности, нативно встроенной в большинство современных VR-гарнитур и не требующей дополнительных внешних датчиков. Это обеспечивает практическую применимость системы в стандартных клинических условиях, мультимодальное расширение рассматривается как направление дальнейших исследований.

Настоящая работа предлагает применение ANFIS к задаче классификации эмоций по данным окулографии в VR-среде и вводит нечеткий индекс дистресса (FDI) – агрегированный показатель, служащий критерием адаптации или останова VR-сессии. Ставится задача разработать систему мониторинга эмоциональных состояний на основе ANFIS и теоретически обосновать ее применение для обеспечения безопасности в VR-экспозиционной терапии. Выбор нечетких нейронных сетей обоснован тем, что они позволяют объединить обучаемость нейронных сетей с интерпретируемостью нечеткой логики [7, 8]. Это принципиально важно для клинических приложений: правило вида «ЕСЛИ частота морганий высокая И амплитуда саккад низкая, ТО высокая тревожность» понятно терапевту без дополнительных пояснений. ANFIS реализуют нечеткий вывод по схеме Такаги–Сугено первого порядка с гибридным обучением [8].

Применению технологий машинного обучения и искусственного интеллекта в области адаптации VR посвящено несколько современных работ. Alharbi (2024) применяет Bi-LSTM и Attention LSTM к датасету VREED с использованием SHAP-значений для интерпретируемости, достигая точности до 81 % в задаче многоклассовой классификации [5]. Mevlevioğlu et al. (2024) разработали систему классификации тревожности в VRET в режиме реального времени на основе сверточной нейронной сети по физиологическим сигналам (ЭДА, ФПГ, ЭЭГ), показав точность 79 % [3]. Rahman et al. (2023) предложили конвейер определения уровня возбуждения из мультимодальных данных для самоуправляемой VR-терапии [9].

В области нечетких нейросетей Czerniak et al. (2025) публикуют систематический обзор архитектур FNN с анализом применений в прогнозировании и классификации [7]. Apiecionek et al. (2023) описывают FNN на упорядоченных нечетких числах (OFN) для задач оценки качества жизни [10]. Обзор Małolepsza O., Mikołajewski D. и Prokopowicz P. (2025) систематизирует перспективы FNN на OFN в медицинских и инженерных приложениях [11] Cao Q. и Quek C. (2024) предлагают нечеткую встраиваемую

рекуррентную архитектуру FE-RNN для повышения интерпретируемости глубоких сетей [12].

Применение FNN к оценке рисков в VRET остается недостаточно изученной областью: существующие подходы либо используют классические нейросети без лингвистической интерпретируемости, либо ограничиваются задачами прогнозирования вне клинического контекста. В настоящей работе делается попытка построить интерпретируемую систему мониторинга с механизмом управления сессией.

Материалы и методы

Формализованную постановку основной задачи исследования можно сформулировать следующим образом. Пусть для i-го наблюдения задан вектор признаков окулографии:

$$x^{(i)} = \left(x_1^{(i)}, x_2^{(i)}, \dots, x_n^{(i)}\right)^T \in R^n, \quad (1)$$

где n – число признаков (в эксперименте $n = 20$). Все наблюдения разбиты на классы $y^{(i)} \in \{1, 2, 3, 4\}$, которые соответствуют квадранту двумерной модели аффекта: HV/HA (высокая валентность / высокая активация), HV/LA (высокая валентность / низкая активация), LV/HA (низкая валентность / высокая активация), LV/LA (низкая валентность / низкая активация). Требуется построить классификатор $f : R^n \to \{1, 2, 3, 4\}$, обеспечивающий высокую точность и интерпретируемость.

Каждый входной признак x_j $(j = 1, \dots, n)$ описывается M нечеткими термами $A_{j1}, \dots A_{jm}$, заданными на универсальном множестве $U = R$. Степень принадлежности x_j к l-му терму A_{jl} определяется гауссовой функцией принадлежности:

$$\mu_{jl}(x_j) = \exp\left(-\frac{(x_j - c_{jl})^2}{2\sigma_{jl}^2}\right), \quad (2)$$

где $c_{jl} \in \mathbb{R}$ – центр и $\sigma_{jl} > 0$ – ширина l-го терма j-й переменной. Параметры (c_{jl}, σ_{jl}) образуют множество обучаемых параметров Θ_a предпосылок (левых частей правил), их называют параметрами антецедентов. В рамках представленного в статье вычислительного эксперимента $M = 3$ терма (низкий, средний, высокий) для каждого из $n = 20$ признаков, общее количество параметров левых частей правил $|\Theta_a| = 2 \cdot M \cdot n = = 120$.

Мощность полной решетки правил, содержащей всевозможные комбинации термов 20 признаков, равна $M^n = 3^{20} \approx 3{,}5 \cdot 10^9$ правил. Обработать такое количество правил сложно, для сокращения числа правил применяется субтрактивная кластеризация: алгоритм находит плотные области в нормированном признаковом пространстве $\mathbb{R}^n$ и назначает каждой области одно правило. Радиус кластеризации $ra \in (0, 1]$ является основным управляющим параметром, причем меньшее значение данного радиуса ra дает больше кластеров и, соответственно, правил. В рамках проведенного в статье вычислительного эксперимента $ra = 0{,}5$, что при размерности $n = 20$ и количестве наблюдений обучающей выборки – 408 , приводит к формированию $Q \approx 30$ правил. Каждое r-е правило $(r = 1, \dots, Q)$ задается в форме нечеткого логического вывода Такаги-Сугено первого порядка:

$$R_r\text{: ЕСЛИ } x_1 \text{ есть } A_{1r} \text{ И } \dots \text{ И } x_n \text{ есть } A_{nr}\text{, ТО } y_r = p_r^T x + q_r, \quad (3)$$

где A_{jr} – терм j-й переменной в r-м правиле, представленный гауссовой функцией принадлежности $\mu_{jr}(x_j)$, параметры (c_{jr}, σ_{jr}) которой инициализируются по

результатам кластеризации, $p_r \in \mathbb{R}^n$ и $q_r \in \mathbb{R}$ – параметры линейной функции, стоящей в заключении. Множество комбинаций параметров (p_r, q_r) (параметры консеквента) для каждого класса $c \in \{1, 2, 3, 4\}$ обозначим Θ_c.

Мера принадлежности конкретного объекта $x^{(i)} = \left(x_1^{(i)}, x_2^{(i)}, \dots, x_n^{(i)}\right)^T$ левой части r-го правила определяется как произведение степеней принадлежности:

$$\tau_r = \prod_{j=1}^{n} \mu_{jr}(x_j) = \prod_{j=1}^{n} \exp\left(-\frac{(x_j - c_{jr})^2}{2\sigma_{jr}^2}\right). \quad (4)$$

Полученные значения нормируются:

$$\bar{\tau_r} = \frac{\tau_r}{\sum_{s=1}^{R} \tau_s}, \sum_{r=1}^{R} \bar{\tau_r} = 1. \quad (5)$$

Выход нечеткой системы для класса c определяется по формуле:

$$f_{out}(c) = \sum_{j=1}^{R} \bar{\tau_r} \cdot (p_r^T x + q_r). \quad (6)$$

Итоговый результат нечеткого логического вывода формируется как:

$$\hat{y} = argmax\{c \in \{1, 2, 3, 4\}\} f_{out}(c). \quad (7)$$

Обучение ANFIS выполняется в два последовательных прохода (прямой и обратный) для каждой эпохи и заключается в определении оптимальных параметров $(c_{jr}, \sigma_{jr}), j = 1, \dots, n$ левых частей и параметров заключений (p_r, q_r) каждого правила.

В процессе прямого прохода при фиксированных параметрах предпосылок Θ_a вычисляются нормированные значения $\bar{\tau_r}$. Для N обучающих примеров формируется матрица регрессора $\Phi \in \mathbb{R}^{N \times Q(n+1)}$, i-я строка которой содержит блоки для каждого из Q правил:

$$\Phi_i = \left[\bar{\tau}_1^i, \bar{\tau}_1^i x_1^i, \dots, \bar{\tau}_1^i x_n^i, \bar{\tau}_2^i, \bar{\tau}_2^i x_1^i, \dots, \bar{\tau}_2^i x_n^i, \dots, \bar{\tau}_Q^i, \bar{\tau}_Q^i x_1^i, \dots, \bar{\tau}_Q^i x_n^i\right], \quad (8)$$

каждый блок из $(n + 1)$ элементов соответствует одному правилу. В рамках вычислительного эксперимента, проведенного в данной работе суммарный размер строки $R \cdot (n + 1) = 30 \cdot 21 = 630$. Для нахождения параметров консеквентов в работе используется решение нормальных уравнений МНК с регуляризацией Тихонова:

$$\Theta_c = (\Phi^T \Phi + \lambda I)^{-1} \Phi^T Y, \quad (9)$$

где $Y \in \mathbb{R}^{N \times 4}$ – матрица меток, $\lambda > 0$ – коэффициент регуляризации ($\lambda = 0{,}01$ в рамках вычислительного эксперимента). Регуляризация устраняет возможную вырожденность матрицы $\Phi^T \Phi$ при малых размерах выборки.

В процессе обратного прохода при фиксированных значениях параметров консеквента Θ_c вычисляется градиент функции потерь (мультиклассовая перекрестная энтропия L_{CE}) по параметрам предпосылок:

$$\frac{\partial L_{CE}}{\partial c_{jm}} = \sum_i \sum_r \delta_{ir} \cdot \left(\frac{\partial \bar{\tau_r}}{\partial \mu_{jm}}\right) \cdot \left(\frac{\partial \mu_{jm}}{\partial c_{jm}}\right), \quad (10)$$

$$\frac{\partial \mu_{jm}}{\partial c_{jm}} = \frac{2(x_j - c_{jm})}{\sigma_{jm}^2} \cdot \mu_{jm}(x_j), \quad (11)$$

$$\frac{\partial \mu_{jm}}{\partial \sigma_{jm}} = \frac{2(x_j - c_{jm})^2}{\sigma_{jm}^3} \cdot \mu_{jm}(x_j), \quad (12)$$

где δ_{ir} – компонент чувствительности ошибки.

Параметры обновляются по схеме Adam с адаптивным шагом:

$$\theta(t+1) = \theta(t) - \eta \cdot \frac{\hat{m}(t)}{\sqrt{\hat{v}(t)}+\varepsilon}, \quad (13)$$

где $\hat{m}(t)$ и $\hat{v}(t)$ – скорректированные на смещение первый и второй моменты градиента, $\eta = 0{,}001$, $\beta_1 = 0{,}9$, $\beta_2 = 0{,}999$, $\varepsilon = 10^{-8}$.

На основе апостериорных вероятностей классов, выдаваемых ANFIS, формируется нечеткий индекс дистресса:

$$FDI(t) = w_1 \cdot P(LV/HA \mid t) + w_2 \cdot P(LV/LA \mid t), \quad (14)$$

где LV/HA (низкая валентность / высокая активация) соответствует тревожности и страху, LV/LA – грусти и подавленности; $w_1 = 0{,}6$, $w_2 = 0{,}4$ – весовые коэффициенты. Значения $FDI(t) \in [0, 1]$ сглаживаются по скользящему окну длиной $T_w = 10$ с:

$$\overline{FDI(t)} = \left(\frac{1}{T_w}\right) \cdot \sum\{\tau = t - T_w + 1\}^{\{t\}FDI(\tau)}. \quad (15)$$

Формируется трехпороговая логика управления VR-сессией:

– ЕСЛИ $\overline{FDI(t)} > \theta_2 = 0{,}75$ → ПРЕРВАТЬ экспозицию, уведомить терапевта;

– ЕСЛИ $\theta_1 < \overline{FDI(t)} \leq \theta_2$, т. е. $0{,}5 < \overline{FDI(t)} \leq 0{,}75$ → СНИЗИТЬ интенсивность сцены (уменьшить аудио, затемнить изображение);

– ЕСЛИ $\overline{FDI(t)} \leq \theta_1 = 0{,}5$ → ПРОДОЛЖИТЬ сценарий штатно.

Пороги θ_1 и θ_2 могут быть персонализированы по результатам калибровочной сессии, что соответствует принципам индивидуальной адаптации VRET [3, 9].

В рамках исследования подход ANFIS будет сравниваться еще с несколькими подходами для решения построения классификатора. Кратко остановимся на методологии FNN (OFN). FNN (OFN) – нейронная сеть на базе упорядоченных нечетких чисел (OFN), имеющая гибридную нейро-нечеткую архитектуру, которая объединяет принципы нейронных сетей и нечеткой логики. Вместо работы с четкими числами, все ключевые элементы сети (входы, веса, выходы) представляются в виде упорядоченных нечетких чисел. Это позволяет сети оперировать не просто значениями, а целыми нечеткими интервалами с заданным направлением, что предоставляет уникальные возможности для работы с неопределенностью.

Упорядоченное нечеткое число (OFN) задается упорядоченной парой функций f_{UP}, f_{DOWN}, где f_{UP} характеризует восходящий компонент (тенденция роста), f_{DOWN} нисходящий:

$$\tilde{A} = (f_{UP}, f_{DOWN}), \quad (16)$$

причем важен порядок данных функций. Порядок между восходящей и нисходящей частями определяет направление: если f_{UP} идет первой, число имеет положительное направление ↑, если f_{DOWN} идет первой, число имеет отрицательное направление ↓. Для положительного трапециевидного OFN $\tilde{A} = (a_1, a_2, a_3, a_4)$ ↑, f_{UP} линейно возрастает от a_1 до a_2, f_{DOWN} линейно убывает от a_3 до a_4. Сложение и умножение OFN осуществляется по правилам:

$$\tilde{A} \oplus \tilde{B} = (f_{UP}^A + f_{UP}^B, f_{DOWN}^A + f_{DOWN}^B), \quad (17)$$

$$\tilde{A} \otimes \tilde{B} = (f_{UP}^A \cdot f_{UP}^B, f_{DOWN}^A \cdot f_{DOWN}^B). \quad (18)$$

В FNN(OFN) каждый вес $\widetilde{w_{ij}}$ является OFN. Выход нейрона вычисляется как:

$$\widetilde{y_j} = \tilde{\sigma}\left(\sum_i \widetilde{w_{ij}} \otimes \widetilde{x_i} \oplus \widetilde{b_j}\right), \quad (19)$$

где $\tilde{\sigma}$ применяется поэлементно к восходящему и нисходящему компонентам.

Достоинство OFN перед классическими нечеткими числами – явное кодирование направления изменения (тренда) признака, что повышает интерпретируемость динамических признаков [10, 11].

Архитектура таких сетей во многом схожа с классической многослойной нейронной сетью прямого распространения, но с фундаментальным отличием на уровне вычислений. Все входные сигналы и их веса являются OFN. Вместо скалярного произведения вычисляется сумма произведений OFN с использованием специально определенных для них арифметических операций. Результат суммирования (также OFN) передается на нечеткую функцию активации. Ее роль – преобразовать полученное OFN в итоговый выход нейрона (тоже OFN). Ключевая проблема заключается сравнение OFN-чисел. Поскольку стандартных операторов сравнения для OFN не существует, в таких сетях, как применяются альтернативные метрики, например, модифицированное расстояние Канберры. Процесс обучения таких сетей также является гибридным и включает прямой и обратный проход. Сети на основе OFN способны решать те же задачи, что и обычные глубокие нейросети, но с меньшим количеством нейронов и, как следствие, с меньшими требованиями к вычислительной мощности и оперативной памяти.

Кратко остановимся еще на методологии SFNN(OFN), также используемой в работе для сравнения. SFNN(OFN) представляет собой стохастическую прямосвязную сеть на базе OFN. Данная сеть представляет собой расширение FNN(OFN), в которое вводится элемент случайности на уровне скрытых нейронов. Сеть содержит стохастические скрытые нейроны, их выход – это не детерминированное OFN, а случайная выборка из вероятностного распределения, которое зависит от входного OFN-сигнала. Сеть моделирует распределение вероятностей над выходными OFN-числами. Один и тот же вход может порождать разные, но правдоподобные выходы. С точки зрения обучения, стандартный backpropagation напрямую не работает из-за стохастических узлов, используются специальные методы, такие как вариационные методы (например, градиентная оценка через репараметризацию), обобщенный EM-алгоритм или выборочные методы (importance sampling).

В рамках исследования будет также осуществляться сравнение с методом K-ближайших соседей KNN (K-Nearest Neighbors) и DecisionTree.

Результаты и обсуждение

Экспериментальная часть исследования осуществлялась на базе датасета VREED [6]. Датасет содержит записи окулографии 34 здоровых испытуемых (17 мужчин, 17 женщин, возраст 18–61 год) в 12 иммерсивных 360°-видеосредах VR-гарнитуры HTC Vive Pro Eye. Каждая среда сопоставлена с квадрантом двумерной модели аффекта по данным самооценки (шкала SAM). Из записей извлечены 20 числовых признаков:

– статистики амплитуды и направления саккад: μ_sacc, σ_sacc, max_sacc, min_sacc, μ_dir, σ_dir, skew_dir;

– параметры микросаккад: μ_micro_amp, σ_micro_amp, μ_micro_vel, σ_micro_vel, μ_micro_dir, σ_micro_dir;

– характеристики морганий: μ_blink (средняя длительность), rate_blink (частота), count_blink (количество);

– параметры фиксаций: μ_fix (средняя длительность), count_fix (количество).

В качестве предобработки данных использовалась нормализация по min-max:

$$\widehat{x_j} = \frac{x_j - \min_j}{(max_j - min_j)}, \widehat{x_j} \epsilon [0,1]. \quad (20)$$

Датасет содержит следующее распределение классов: HV/HA – 28 %, HV/LA – 22 %, LV/HA – 27 %, LV/LA – 23 %.

Разбиение на обучающую и тестовую выборки осуществляется в виде: 80 % обучающая, 20 % тестовая, стратифицированная по классам.

В эксперименте сравниваются пять подходов. Для всех нечетких моделей используется M = 3 терма, гиперпараметры подобраны пятикратной перекрестной проверкой.

Сравниваемые модели и гиперпараметры представлены в Таблице 1.

Таблица 1 – Сравниваемые модели и гиперпараметры
Table 1 – Compared models and hyperparameters

Модель	Ключевые гиперпараметры	Правил R
ANFIS	M=3, субтракт. кластеризация, λ=0,01, η=0,001, Adam, 100 эпох	≈30
FNN (OFN)	2 скрытых слоя, OFN-веса, M=3, 50 эпох	12
SFNN	3 скрытых слоя OFN, M=3, 50 эпох	8
KNN	k=100, метрика Евклида	–
DecisionTree	criterion='entropy', max_depth=30	–

В качестве метрик качества классификации в работе используются стандартные метрики: Accuracy, взвешенные Precision, Recall, F1-score; AUC ROC.

Результаты на тестовой выборке представлены в Таблице 2.

Таблица 2 – Метрики классификации
Table 2 – Classification metrics

Модель	Accuracy	Precision	Recall	F1-score	p-value vs ANFIS
ANFIS	0,77	0,78	0,76	0,77	–
FNN (OFN)	0,75	0,74	0,75	0,74	0,038
SFNN	0,69	0,60	0,68	0,69	0,004
KNN (k=100)	0,72	0,71	0,73	0,72	0,021
DecisionTree	0,74	0,73	0,74	0,74	0,041

ANFIS достигает Accuracy = 0,77 – результата, характерного для прототипных систем аффективных вычислений на данных здоровых испытуемых. Статистическая значимость попарных различий проверяется критерием МакНемара с поправкой Бонферрони на множественные сравнения. Различия между ANFIS и каждой из базовых моделей статистически значимы ($p < 0{,}05$). Вместе с тем абсолютный отрыв от FNN(OFN) невелик ($\Delta F1 = 0{,}03$), что объясняется ограниченным размером выборки ($N = 408$ наблюдений после разбивки). Для окончательного вывода о превосходстве ANFIS необходима проверка на более крупной выборке.

Из базы правил ($R \approx 30, ra = 0{,}5$) выделены шесть правил с нормированной активностью $\overline{\tau_r} > 0{,}05$ в среднем по тестовой выборке. Порог 0,05 выбран как минимальный уровень, при котором правило влияет на выход системы более чем в 5 % случаев. Суммарная активность шести правил: $\sum \overline{\tau_r} = 0{,}53$, то есть на них приходится более половины всех решений.

Наиболее активные правила ANFIS после обучения представлены в Таблице 3.

Таблица 3 – Наиболее активные правила ANFIS после обучения
Table 3 – The most active ANFIS rules after training

Условие (ЕСЛИ…)	Класс	$\overline{\tau_r}$ (среднее)	Доля, %
rate_blink высокий И μ_sacc низкое	LV/HA (тревога)	0,12	22,6
rate_blink низкий И count_micro мало	HV/LA (спокойствие)	0,11	20,8
μ_sacc высокое И rate_blink средний	HV/HA (радость)	0,09	17,0
count_micro высокий И μ_fix короткая	LV/HA (тревога)	0,08	15,1
μ_blink длинная И μ_micro_vel низкая	LV/LA (грусть)	0,07	13,2
μ_sacc среднее И μ_fix длинная	HV/LA (спокойствие)	0,06	11,3

Столбец «Доля» отражает процент вклада в суммарную активность топ-6 правил.

Выделенные паттерны согласуются с психофизиологической литературой: повышенная частота морганий при тревожности подтверждена в [5], увеличение числа микросаккад при когнитивном напряжении – в [4], длинные фиксации при спокойном просмотре – в [6].

ANFIS обладает встроенным механизмом оценки важности признаков, не требующим внешних инструментов. Нормированные активности правил $\overline{\tau_r}$, представленные в Таблице 3, позволяют определить вклад каждого признака в принятие решений системой. Важность j-го признака оценивается как среднее произведение нормированной активности правила на абсолютное значение соответствующего параметра заключения:

$$I_j = \left(\frac{1}{N}\right) \cdot \sum_i \sum_r \overline{\tau_r^{(i)}} \cdot \left|p_{jr}\right|, \tag{21}$$

где p_{jr} – коэффициент j-го признака в линейном заключении r-го правила, N – размер тестовой выборки. Анализ I_j по наиболее активным правилам (суммарная активность 53 %) показывает, что наибольший вклад вносят: rate_blink (частота морганий), присутствующая в двух из шести ведущих правилах с $\overline{\tau_r} = 0{,}12$ и $0{,}11$; μ_sacc (средняя амплитуда саккад) – в трех правилах; count_micro (число микросаккад) и μ_fix (длительность фиксаций) – по одному правилу каждый. Это согласуется с нейрофизиологическими данными о роли частоты морганий и саккадической активности как маркеров когнитивного и эмоционального напряжения [4, 5].

Таким образом, интерпретируемость ANFIS обеспечивает естественный механизм отбора признаков без привлечения внешних методов: признаки, не участвующие ни в одном активном правиле ($\overline{\tau_r} > 0{,}05$), могут быть исключены при необходимости уменьшения размерности без существенной потери точности.

Для оценки устойчивости системы проведен анализ чувствительности к двум ключевым гиперпараметрам: радиусу кластеризации ra и ширине скользящего окна T_w.

Зависимость Accuracy и Recall класса LV/HA от радиуса кластеризации представлена в Таблице 4.

Таблица 4 – Зависимость Accuracy и Recall класса LV/HA от радиуса кластеризации
Table 4 – Accuracy and Recall of LV/HA class as a function of clustering radius

ra	R (правил)	Accuracy	Recall (LV/HA)	Время обучения, с
0,30	68	0,76	0,74	142
0,50	30	0,77	0,76	61
0,70	14	0,74	0,71	28
0,90	7	0,71	0,67	14

Accuracy остается в диапазоне 0,74–0,77 при $ra \in [0{,}30;\ 0{,}70]$, что свидетельствует об устойчивости системы. При $ra > 0{,}70$ Recall класса LV/HA заметно снижается – критически для клинического применения (пропуск тревожного состояния опаснее ложного срабатывания). Значение $ra = 0{,}50$ обеспечивает оптимальный баланс точности и скорости обучения.

Компромисс «чувствительность – специфичность» при разных значениях T_w представлен в Таблице 5.

Таблица 5 – Компромисс «чувствительность – специфичность» при разных значениях T_w
Table 5 – Sensitivity-specificity trade-off for different T_w values

T_w, с	Recall (LV/HA)	Ложных тревог / сессию	Задержка реакции, с
5	0,79	3,2	≈3
10	0,76	1,4	≈8
20	0,71	0,7	≈16
30	0,67	0,3	≈24

При уменьшении T_w растет Recall (меньше пропусков тревоги), но увеличивается число ложных срабатываний; при увеличении T_w – обратная картина. Значение $T_w = 10$ с рекомендуется как базовое; для пациентов с высоким уровнем тревожности целесообразно $T_w = 5$ с.

В работе представлен алгоритм персонализированной калибровки порогов FDI. Пороги θ_1 и θ_2 могут быть скорректированы по результатам вводной калибровочной сессии.

Алгоритм персонализации:

– Шаг 1. Провести калибровочную VR-сессию (5 мин): 2,5 мин – нейтральный контент (ожидаемый класс HV/LA), 2,5 мин – умеренно неприятный контент (ожидаемый класс LV/HA).

– Шаг 2. Вычислить базовые уровни: $\overline{FDI_{neutral}}$ – медианное значение $\overline{FDI}$ в нейтральном сегменте; $\overline{FDI_{stress}}$ – медианное значение в стрессовом сегменте.

– Шаг 3. Установить пороги: $\theta_1 = \overline{FDI_{neutral}} + 0{,}5 \cdot (\overline{FDI_{stress}} - \overline{FDI_{neutral}})$; $\theta_2 = = \overline{FDI_{neutral}} + 0{,}8 \cdot (\overline{FDI_{stress}} - \overline{FDI_{neutral}})$.

– Шаг 4. Если $\overline{FDI_{stress}} - \overline{FDI_{neutral}} < 0{,}15$ (низкая различимость), использовать глобальные пороги $\theta_1 = 0{,}50$, $\theta_2 = 0{,}75$ и зафиксировать предупреждение в протоколе сессии.

Данный алгоритм учитывает межиндивидуальную вариабельность окулографических паттернов и снижает риск систематических ложных срабатываний. Эмпирическая верификация алгоритма на клинической выборке является задачей будущих исследований.

Теоретическое применение FDI в клинической практике. Предложенная система на основе ANFIS и FDI предназначена для работы в режиме реального времени в ходе VR-экспозиционной сессии. Теоретическая схема применения выглядит следующим образом. Встроенный трекер взгляда VR-гарнитуры (HTC Vive Pro Eye, Meta Quest Pro и др.) с частотой 90–120 Гц непрерывно регистрирует параметры движений глаз. Каждые $T_s = 1$ с из буфера вычисляется вектор признаков $x(t) \in \mathbb{R}^{20}$, который передается в обученную модель ANFIS.

На выходе модели формируется распределение вероятностей по четырем классам аффекта, из которого вычисляется $FDI(t)$. Сглаженное значение $\overline{FDI(t)}$ сравнивается с порогами θ_1 и θ_2: при превышении θ_1 система передает команду снижения

интенсивности сцены в игровой движок (Unity/Unreal Engine) через событийный API; при превышении θ_2 – формирует сигнал останова экспозиции и уведомляет терапевта. Такой механизм позволяет реагировать на нарастание дистресса объективно, без прерывания иммерсии пациентом.

Предложенный подход сочетает три важных свойства для клинического применения. Во-первых, интерпретируемость: нечеткие правила описывают эмоциональные паттерны на естественном языке, что облегчает взаимодействие системы с терапевтом. Во-вторых, адаптивность: гибридное обучение ANFIS обеспечивает подгонку как нелинейных функций принадлежности, так и линейных заключений, что дает преимущество перед фиксированными правилами [8]. В-третьих, механизм управления через FDI непосредственно связывает вероятностный выход классификатора с клиническим решением.

Техническая интеграция в VR-платформу возможна через стандартный API трекера взгляда (Tobii XR SDK): каждую секунду должен будет формироваться вектор признаков $x(i)$, передаваться в ANFIS-модель, а результат использоваться для обновления $\overline{\text{FDI}}$ и корректировки параметров сцены в Unity/Unreal Engine через событийную модель.

Заключение

В настоящей работе предложена и верифицирована система мониторинга эмоциональных состояний на основе ANFIS для задач VR-экспозиционной терапии. Основные результаты:

– разработан математически обоснованный классификатор на базе ANFIS с гибридным обучением (МНК + Adam), достигающий Accuracy = 0,77 и F1 = 0,77 по данным окулографии из датасета VREED; различия с базовыми моделями статистически значимы (критерий МакНемара, $p < 0{,}05$).

– предложен и формализован нечеткий индекс дистресса (FDI) с трехпороговой логикой управления VR-сессией; описана возможная схема его интеграции с игровым движком для адаптивного управления экспозицией в реальном времени.

– извлечены шесть интерпретируемых правил нечеткого вывода, согласующихся с данными психофизиологической литературы и пригодных для клинической валидации.

– показано преимущество ANFIS над FNN(OFN), SFNN, KNN и деревом решений.

Перспективами развития являются: расширение модального пространства (ЭДА, ЧСС, мимика), персонализированная калибровка порогов FDI, а также клинические испытания системы в условиях реальной экспозиционной VR терапии с пациентами.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Parsons Th.D., Rizzo A.A. Affective outcomes of virtual reality exposure therapy for anxiety and specific phobias: A meta-analysis. *Journal of Behavior Therapy and Experimental Psychiatry.* 2008;39(3):250–261. https://doi.org/10.1016/j.jbtep.2007.07.007
2. Opriş D., Pintea S., Garcia-Palacios A., Botella C., Szamosközi Ş., David D. Virtual reality exposure therapy in anxiety disorders: a quantitative meta-analysis. *Depression and Anxiety.* 2012;29(2):85–93. https://doi.org/10.1002/da.20910
3. Mevlevioğlu D., Tabirca S., Murphy D. Real-Time Classification of Anxiety in Virtual Reality Therapy Using Biosensors and a Convolutional Neural Network. *Biosensors.* 2024;14(3):131. https://doi.org/10.3390/bios14030131

4. Bekler M., Yilmaz M., Ilgın H.E. Assessing Feature Importance in Eye-Tracking Data within Virtual Reality Using Explainable Artificial Intelligence Techniques. *Applied Sciences.* 2024;14(14):6042. https://doi.org/10.3390/app14146042
5. Alharbi H. Explainable feature selection and deep learning based emotion recognition in virtual reality using eye tracker and physiological data. *Frontiers in Medicine.* 2024;11:1438720. https://doi.org/10.3389/fmed.2024.1438720
6. Tabbaa L., Searle R., Bafti S.M., et al. VREED: Virtual Reality Emotion Recognition Dataset Using Eye Tracking and Physiological Measures. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies.* 2021;5(4):178. https://doi.org/10.1145/3495002
7. Apiecionek L. Fuzzy Neural Networks – A Review with Case Study. *Applied Sciences.* 2025;15(13):6980. https://doi.org/10.3390/app15136980
8. Jang J.-S.R. ANFIS: Adaptive-Network-based Fuzzy Inference System. *IEEE Transactions on Systems, Man, and Cybernetics.* 1993;23(3):665–685. https://doi.org/10.1109/21.256541
9. Rahman M.A., Brown D.J., Mahmud M., et al. Enhancing biofeedback-driven self-guided virtual reality exposure therapy through arousal detection from multimodal data using machine learning. *Brain Informatics.* 2023;10(1):14. https://doi.org/10.1186/s40708-023-00193-9
10. Apiecionek Ł., Moś R., Ewald D. Fuzzy Neural Network with Ordered Fuzzy Numbers for Life Quality Technologies. *Applied Sciences.* 2023;13(6):3487. https://doi.org/10.3390/app13063487
11. Małolepsza O., Mikołajewski D., Prokopowicz P. Adaptation of fuzzy systems based on ordered fuzzy numbers: a review of applications and development prospects. *Electronics.* 2025;14(12):2341. https://doi.org/10.3390/electronics14122341
12. Tan J.Ch.M., Cao Q., Quek Ch. FE-RNN: A fuzzy embedded recurrent neural network for improving interpretability of underlying neural network. *Information Sciences.* 2024;663:20276. https://doi.org/10.1016/j.ins.2024.120276

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Поздняков Даниил Александрович, аспирант кафедры математических методов исследования операций, Воронежский государственный университет, Воронеж, Российская Федерация.
e-mail: daniil.pozdnyakov.00@mail.ru
ORCID: 0009-0002-5601-9651

Daniil A. Pozdnyakov, Postgraduate at the Department of Mathematical Methods of Operations Research, Voronezh State University, Voronezh, the Russian Federation.

Азарнова Татьяна Васильевна, доктор технических наук, профессор кафедры математических методов исследования операций, Воронежский государственный университет, Воронеж, Российская Федерация.
e-mail: ivdas92@mail.ru
ORCID: 0000-0001-6342-9355

Tatiana V. Azarnova, Doctor of Engineering Sciences, Professor at the Department of Mathematical Methods of Operations Research, Voronezh State University, Voronezh, the Russian Federation.

Статья поступила в редакцию 14.09.2026; одобрена после рецензирования 03.11.2026; принята к публикации 12.11.2026.

The article was submitted 14.09.2026; approved after reviewing 03.11.2026; accepted for publication 12.11.2026.