

**НЕЙРОНЕЧЕТКАЯ АНСАМБЛЕВАЯ МОДЕЛЬ ОПРЕДЕЛЕНИЯ
ФУНКЦИОНАЛЬНОГО СОСТОЯНИЯ УТОМЛЕНИЯ ВОДИТЕЛЯ
ТРАНСПОРТНОГО СРЕДСТВА С ИСПОЛЬЗОВАНИЕМ
ПУПИЛЛОМЕТРИИ¹**

**Катасёв А.С. *, Новикова С.В. *, Катасёва Д.В. *, Дагаева М.В. **,
Кузенкова Г.В. *****

*Казанский национальный исследовательский технический университет имени
А.Н. Туполева – КАИ, г. Казань

**ГБУ «Безопасность дорожного движения», г. Казань

***Национальный исследовательский Нижегородский государственный
университет им. Н.И. Лобачевского, г. Нижний Новгород

Поступила в редакцию 13.03.2026, после переработки 01.04.2026.

В работе предложен метод автоматического определения состояния утомления водителя на основе данных пупиллометрии. Система включает носимое неинвазивное устройство для регистрации реакции зрачка на световой стимул и программный модуль с нейронечеткой моделью классификации. Для формирования обучающих данных разработана двухэтапная технология обработки видеозаписей зрачковой реакции с построением пупиллограмм. Сформирован набор из 1500 наблюдений: по 750 для состояний бодрствования и утомления. В качестве признаков используются амплитуда и время сужения, минимальный диаметр зрачка и скорость половинного сужения. Классификатор построен на ансамбле из 6 нейронечетких сетей, формирующих коллективную базу знаний. Для уменьшения избыточности правил предложен двухэтапный метод редукции, основанный на объединении лингвистически идентичных нечетких правил и модифицированном генетическом алгоритме. В результате число правил сокращено с 486 до 29, что соответствует уменьшению размерности базы знаний на 98,77%, при этом точность классификации увеличилась на 1,47%.

Ключевые слова: функциональное состояние человека, пупиллометрия, ансамбль нечетких нейронных сетей, лингвистически идентичные нечеткие правила, редукция нечетких правил, функция принадлежности, генетический алгоритм.

Вестник ТвГУ. Серия: Прикладная математика. 2026. № 2. С. 56–82.
<https://doi.org/10.26456/vtpmk775>

¹Работа выполнена в рамках государственного задания Министерства науки и высшего образования FZSU-2026-0007, рег. номер НИОКТР 126020516513-4.

© Катасёв А.С., Новикова С.В., Катасёва Д.В., Дагаева М.В., Кузенкова Г.В., 2026

Введение

Длительные когнитивные и физические нагрузки могут приводить к развитию состояния утомления, негативное влияние которого особенно заметно в критически важных областях, таких как авиация, транспорт, медицина, промышленное производство и др. В связи с этим разработка эффективных методов автоматизированного определения функционального состояния водителей транспортного средства является актуальной задачей, поскольку позволяет своевременно выявлять признаки утомления и предотвращать негативные последствия.

Для оценки функционального состояния утомления человека используются различные методы, однако пупиллометрия является одним из наиболее эффективных и заключается в исследовании реакции зрачка на различные стимулы [1-3]. В свою очередь, оценка состояния человека на основе пупиллометрии может выполняться с использованием различных методов классификации. Нечеткий вывод [4-6] или база нечетких знаний являются наиболее близкими к человеческому способу восприятия информации подходами. Кроме того, системы, основанные на нечеткой логике, позволяют обрабатывать данные, которые не являются полностью определенными, в том числе данные, получаемые в результате наблюдений за реакциями человеческого тела на различные раздражители.

При построении системы нечеткого вывода возникает вопрос формирования базы нечетких знаний: либо на основе экспертных знаний, либо автоматически с использованием, например, нейронечеткой сети [7-8]. В первом случае это требует значительных временных затрат и высокого уровня экспертного опыта, однако такая база данных будет относительно компактной и хорошо структурированной. Во втором случае база знаний формируется быстро, однако при этом возникает ряд проблем. Во-первых, система не является полностью автоматически генерируемой: необходимо задавать определенные параметры, такие как число градаций функций принадлежности и их тип. Данное обстоятельство вносит определенную субъективность в выбор параметров системы, в результате чего может быть получена не самая эффективная база знаний. Во-вторых, автоматически сформированная база знаний, как правило, содержит избыточное количество правил, которые сложно интерпретировать на естественном языке. В связи с этим возникает необходимость упрощения и сокращения базы знаний, для чего в настоящее время разрабатываются соответствующие методы [9-11]. Однако сравнение методов сокращения нечетких правил по различным критериям показывает, что ни один из них не обладает абсолютными преимуществами, что подчеркивает необходимость разработки новых методов упрощения и редукции баз знаний.

В данной работе предлагается следующий подход к формированию базы знаний при построении системы нечеткого вывода, классифицирующей функциональное состояние утомления человека. На первом этапе осуществляется сбор данных пупиллограмм с использованием легкого носимого устройства на базе маломощного микрокомпьютера. Затем данные проходят предварительную обработку для устранения различных аномалий, таких как шумы, выбросы и пропущенные значения [12-14]. На основе предварительно обработанных данных строятся несколько альтернативных нечетких нейронных сетей, каждая из которых формирует собственную базу знаний. Таким образом, формируется ансамбль нейронечетких сетей и соответствующих баз нечетких знаний, отражающий коллективную раз-

работку решения несколькими различными «экспертами», по аналогии с моделью случайного леса [15]. Использование ансамбля нейронечетких сетей позволяет в определенной степени устранить проблему субъективного выбора параметров базы нечетких знаний при ее автоматическом формировании.

Для сокращения числа правил и повышения интерпретируемости предлагается метод объединения и редукции индивидуальных баз нечетких знаний ансамбля в единую базу знаний, в которой число правил уменьшается в несколько раз. Такую базу знаний будем называть промежуточной. Затем предлагается повторно сократить промежуточную базу знаний для удаления избыточных правил и разработать второй метод редукции, основанный на модификации классического генетического алгоритма. В результате применения указанных процедур удается получить компактную базу нечетких знаний, точность которой не уступает точности ансамбля баз знаний, при этом число правил в ней значительно сокращается. Таким образом, в определенной степени решается проблема интерпретируемости результирующей базы нечетких знаний, а также обеспечивается возможность ее реализации на маломощных вычислительных устройствах.

1. Постановка задачи

Необходимо разработать систему для отслеживания функционального состояния утомления человека в реальном времени, например, водителя во время управления им транспортным средством. При появлении признаков утомления система должна классифицировать такое состояние и сигнализировать о необходимости прервать движение и отдохнуть.

Исходя из особенностей поставленной задачи, автоматическая система распознавания утомления должна удовлетворять следующим требованиям:

- 1) для сбора данных в реальном времени необходимо использовать легкое неинвазивное носимое устройство на основе микрокомпьютера по типу используемых в системах IoT;
- 2) система должна иметь возможность обрабатывать неточные и зашумленные данные, каковыми являются данные, полученные с человека «in vivo» [16];
- 3) система детектирования состояния утомления должна иметь высокую точность распознавания (не менее 90%) для минимизации ложных срабатываний;
- 4) для обеспечения функционирования системы на микрокомпьютере IoT она должна быть компактной, то есть нетребовательной к объему памяти, мало-затратной (нетребовательной к вычислительным ресурсам);
- 5) решение, принятое системой, должно допускать простую интерпретацию на естественном языке, чтобы человек не сомневался в адекватности принятого решения.

2. Материалы и методы

2.1. Сбор данных

В качестве исходных данных для определения состояния утомления человека предлагается использовать пупиллометрию, так как этот метод не требует инвазивных процедур, т.е. данные могут собираться бесконтактно. Согласно многим исследованиям [2, 17-18], зрачковая реакция на внешний раздражитель (например, вспышку света) неразрывно связана с физиологическими процессами в человеческом организме, в том числе с утомлением. Во время зрачковой реакции изменения диаметра зрачка, его колебания и латентное время реакции коррелируют с активностью центральной нервной системы человека [19]. Именно эти данные целесообразно извлекать из пупиллограмм для детектирования состояния утомления человека.

На Рис. 1 представлена схема использования носимого устройства на базе малоомощного микрокомпьютера для сбора исходных данных (пупиллограмм).




Рис. 1: *Схема использования носимого устройства для сбора пупиллограмм*

С помощью представленного на рисунке носимого устройства производился сбор видеофрагментов продолжительностью 3 секунды каждый для фиксации зрачковых реакций (скрининга). Далее видеофрагменты обрабатывались для получения пупиллограмм (рядов данных зрачковых реакций) – записываемых в текстовый файл характеристик каждого зрачка в виде пары «время»-«диаметр» $P = \{(t_0, D_0), \dots, (t_i, D_i), \dots, (t_n, D_n)\}$ с дискретизацией 25 кадров в секунду в течение 3 секунд (всего 76 пар). Здесь t_0 – начальный момент времени, D_0 – начальный нормированный диаметр зрачка, t_n – конечный момент времени, D_n – конечный нормированный диаметр зрачка, t_i и D_i – момент времени и нормированный диаметр зрачка на i -м интервале временного ряда.

2.2. Первичная обработка данных

При формировании пупиллограмм в них часто возникают искажения, приводящие к появлению в данных аномалий, выбросов, а также пропущенных значений.

Для устранения аномалий и повышения качества исходных данных использовались методы предварительной обработки, включающие пороговую фильтрацию выбросов и пропусков, линейную интерполяцию, а также сглаживание временных рядов фильтром Савицкого–Голея [20].

На Рис. 2 показаны примеры полученных после обработки пупиллограмм, соответствующих реакции зрачка человека в нормальном состоянии и при сильном утомлении.



Рис. 2: Графическое представление пупиллограмм: 1) в нормальном состоянии; 2) в состоянии сильного утомления

2.3. Выделение значимых характеристик пупиллограмм и формирование данных для анализа

На основе анализа релевантной литературы [21–22] были выявлены параметры пупиллограмм, достоверно характеризующие реакцию зрачков человека на изменение освещенности. Выделенные параметры и формулы их получения из временного ряда P представлены в Таблице 1.

Таблица 1: Значимые для детектирования состояния утомления параметры, выделяемые из временного ряда пупиллограммы

№	Параметр	Формула вычисления значения параметра
1	Амплитуда сужения зрачка	$A_c = D_0 - D_{\min}$
2	Время сужения зрачка	$t_c; c = \arg \min_{i=\overline{0,n}} D_i$
3	Минимальный диаметр зрачка	$D_{\min} = \min_{i=\overline{0,n}} D_i$
4	Скорость половинного сужения зрачка	$D_{hc} = \frac{(D_0 + D_{\min})}{2}$

Таким образом, состояние утомления будет определяться на основе четырех параметров: A_c , t_c , $D_{\min}$, D_{hc} . В результате исследования был сформирован на-

бор данных для анализа, включающий 1500 записей (бодрый и усталый – по 750 записей соответственно).

В Таблице 2 представлен фрагмент полученных данных.

ТАБЛИЦА 2: Фрагмент полученных данных для анализа

A_c	t_c	$D_{\min}$	D_{hc}	$Class$
0,5260	2,88	0,0192	0,2817	0
0,4504	0,52	0,0073	0,2325	0
0,1430	1,68	0,3059	0,3774	1
0,6297	1,48	0,0367	0,3511	0
0,1201	2,48	0,3172	0,3773	1
0,1544	1,4	0,3089	0,3861	1
0,1289	1,88	0,3129	0,3773	1
0,1562	2,16	0,3157	0,3938	1
0,1434	1,12	0,3174	0,3891	1
0,0188	0,84	0,0187	0,0144	0
0,1489	1,28	0,3087	0,3831	1

Здесь параметр Class характеризует функциональное состояние человека: 0 – нормальное состояние, 1 – состояние усталости.

2.4. Построение нейронечеткой ансамблевой модели и формирование базы знаний

Для формирования базы знаний целесообразно использовать нечеткую нейронную сеть (ННС) [23], которая обучается на имеющихся данных, после чего из нее экстрагируется база знаний в виде совокупности правил нечеткого вывода [24]. При этом настраиваемыми параметрами (аналогами синаптических весов классических нейронных сетей) в ННС являются параметры функций принадлежности (например, мода, левый и правый коэффициенты нечеткости для треугольной функции принадлежности), а также веса (достоверности) нечетких правил. Перед началом обучения, так же, как и при обучении классических нейронных сетей [25], эти параметры могут задаваться случайным образом либо вычисляться в результате преднастройки [26]. Следовательно, в каждой конкретной реализации базы знаний, извлеченной из нечеткой нейронной сети, будет присутствовать элемент случайности, и различные реализации будут несколько отличаться между собой. В связи с этим было принято решение сформировать ансамбль баз нечетких знаний на основе N независимо обученных нейронечетких сетей, каждая из которых обучается на случайно сформированной подвыборке данных по принципу создания такой популярной модели машинного обучения, как случайный лес [27].

На Рис. 3 представлена предложенная схема формирования базы знаний.

Представим систему нечетких правил S в виде (1):

$$S = \left\{ \begin{array}{l} \text{Rule}_l: \text{IF } x_1 = A_{1j_1} \dots x_i = A_{ij_i} \dots x_n = A_{nj_n} \text{ THEN } y = B_k [CF_{kl}], \\ i = \overline{1, n}, j_i = \overline{1, m_i}, k = \overline{1, K}, l = \overline{1, N_R}. \end{array} \right. \quad (1)$$




Рис. 3: Схема формирования базы знаний на основе нейронечеткой ансамблевой модели

Общее число правил в одной системе S коллектива $N_{full} = KN_R = K \prod_{i=1}^n m_i$, где n – число входных нейронов (соответствующее числу параметров пушпиллограмм), а m_i – число градаций для i -го входного нейрона.

Коэффициент достоверности (вес правила) CF_{kl} рассчитывается по следующей формуле:

$$CF_{kl} = \begin{cases} \frac{\sum_{v=1}^{R_k} \min_i (\mu_{A_{ij_i}}(x_i)|_v)}{Ex_S^k}, & \text{if } Ex_S^k > 0, \\ 0, & \text{if } Ex_S^k = 0, \end{cases} \quad (2)$$

где Ex_S^k – количество примеров в обучающей выборке, имеющих метку состояния B_k ; R_k – количество нечетких правил в базе S с выходом в виде заданного состояния B_k . Обозначение $(\bullet)|_v$ говорит о том, что минимум берется только по тем правилам, выход которых равен B_k .

Таким образом происходит формирование модели нечеткого логического вывода на основе построения и обучения нейронечеткой ансамблевой модели.

2.5. Формирование компактной нейронечеткой модели

Сформированная нейронечеткая ансамблевая модель способна классифицировать состояние объекта с высокой точностью за счет присутствия в ней нескольких альтернативных систем-решателей. Однако обратной стороной такого подхода является большой объем нечетких правил в базе знаний и, как следствие, завышенные требования к вычислительным ресурсам при ее использовании в системе поддержки принятия решений. С другой стороны, так как каждая из N систем нечетких правил формируется на основе ННС независимо, в коллективной модели могут присутствовать похожие правила с одинаковым набором antecedентов и

консеквентов. Такие правила будем называть лингвистически-идентичными нечеткими правилами (ЛИНП) [28].

Определение 1. *Правило j из системы нечеткого вывода a коллектива:*

$$Rule_l^a: IF x_1 = A_{1j_1}^a \& \dots \& x_n = A_{nj_n}^a THEN y = B_{k^a} [CF_{kl}^a]$$

и правило s из системы нечеткого вывода b коллектива:

$$Rule_s^b: IF x_1 = A_{1s_1}^b \& \dots \& x_n = A_{ns_n}^b THEN y = B_{k^b} [CF_{ks}^b]$$

будем называть лингвистически-идентичными: $Rule_l^a \Leftrightarrow Rule_s^b$, если:

$$[A_{ij_i}^a = A_{is_i}^b; i = \overline{1, n}] \& [B_{k^a} = B_{k^b}], \quad a \in [1, N], b \in [1, N], a \neq b.$$

При этом $\mu_{A_{ij_i}}^a(x_i) \neq \mu_{A_{is_i}}^b(x_i)$, $CF_{kl}^a \neq CF_{ks}^b$.

Сформированная модель является избыточной и может быть редуцирована за счет сокращения числа ЛИНП. Для этого предлагается метод редукции, основанный на объединении нескольких ЛИНП в одно нечеткое правило, а затем минимизации количества уникальных правил в результате решения оптимизационной двухкритериальной задачи.

Метод состоит из трех этапов:

1. объединение ЛИНП в N_{full} подмножеств $\Omega_p = \left\{ \bigwedge_{l=\overline{1, N}} Rule_p^l \right\}$, $p = \overline{1, N_{full}}$;
2. формирование новых правил $Rule_p^{TR}$, $p = \overline{1, N_{full}}$ (по одному для каждого Ω_p) из условия максимизации точности на основе правил и объединение их в промежуточную базу знаний S^{In} ;
3. редукция промежуточной базы знаний за счет исключения «пустых» правил и минимизации количества оставшихся правил при условии максимизации точности оценки состояния объекта (формирование компактной базы знаний S^*).

2.5.1. Формирование промежуточной базы знаний S^{In}

Пусть Ω_p , $p = \overline{1, N_{full}}$ — совокупность подмножеств ЛИНП $Rule_p^l$, $l = \overline{1, N}$ с функциями принадлежности левых частей правил $\mu_{A_{ij_i}}^p$, $i = \overline{1, n}$, $j_i = \overline{1, m_i}$. Тогда задача формирования базы знаний S^{In} , состоящей из правил $Rule_p^{TR}$ — типичных представителей подмножеств Ω_p с функциями принадлежности левых частей правил $\mu_{A_{ij_i}}^{Tr}$, $i = \overline{1, n}$, $j_i = \overline{1, m_i}$ формулируется следующим образом:

$$F(S^{In}) = \frac{N_{train_t}}{N_{train}} \rightarrow \max, \quad (3)$$

$$S^{In} \left(\mu_{A_{ij_i}}^{Tr} \right) = \left\{ Rule_p^{TR}: IF x_1 = A_{1j_1} \dots x_n = A_{nj_n} THEN y = B_k [CF_{kp}], \right. \\ \left. i = \overline{1, n}, j_i = \overline{1, m_i}, k = \overline{1, K}, p = \overline{1, N_{full}}, \right. \quad (4)$$

$$\mu_{A_{ij_i}}^{Tr} = f\left(\mu_{A_{ij_i}}^1, \mu_{A_{ij_i}}^2, \dots, \mu_{A_{ij_i}}^{N_{full}}\right),$$

$$i = \overline{1, n}, j_i = \overline{1, m_i}.$$

Здесь N_{train} — число примеров в обучающей выборке; N_{train_t} — число правильно классифицированных обучающих примеров.

Заметим, что шаблоны правил промежуточной базы знаний S^{In} полностью идентичны шаблонам подмножеств Ω_p и не изменяются в процессе решения задачи (3)-(4). Свойства базы знаний S^{In} , влияющие на ее точность в смысле целевой функции (3), определяются параметрами функций принадлежности $\mu_{A_{ij_i}}^{Tr}$, которые, в свою очередь, должны вычисляться на основе параметров функций принадлежности $\mu_{A_{ij_i}}^p$ подмножества Ω_p .

Для определения значений параметров функций принадлежности $\mu_{A_{ij_i}}^{Tr}$, исходя из оптимизационной задачи (3)-(4), разработан специальный генетический алгоритм. Генетические алгоритмы применимы для задач большой размерности, не требуют никакой априорной информации об оптимизируемом критерии, а также обладают возможностями распараллеливания вычислений [27], что соответствует принципам обработки информации при обучении нейронных сетей, в том числе нечетких.

Предложенный генетический алгоритм использует оригинальную схему кодирования функций принадлежности $\mu_{A_{ij_i}}^{Tr}$ в виде двоичных хромосом, которые формируются посредством конкатенации двоичных представлений параметров, определяемых на основе исходных функций принадлежности $\mu_{A_{ij_i}}^p$. Нечеткое правило в свою очередь кодируется как склейка закодированных функций принадлежности, входящих в правило, а база знаний — как склейка закодированных представлений правил.

Далее приведен алгоритм кодирования всевозможных значений параметров $\mu_{A_{ij_i}}^{Tr}$ для случая треугольных функций принадлежности, где каждая исходная функция $\mu_{A_{ij_i}}^p$ задается тройкой параметров l (левый коэффициент нечеткости), c (мода) и r (правый коэффициент нечеткости).

Алгоритм 1. Алгоритм кодирования функций принадлежности нечетких правил.

Шаг 1. Инициализация диапазонов изменения параметров функций принадлежности.

Для каждой функции принадлежности и для каждого ее параметра определяется допустимый диапазон значений.

Для этого выполняются следующие действия:

- последовательно перебираются все входные переменные;
- для каждой переменной рассматриваются все исходные функции принадлежности;
- для каждой функции задаются диапазоны изменения трех параметров треугольной функции принадлежности:
 - l : левый коэффициент нечеткости,
 - c : мода (центр),

– r : правый коэффициент нечеткости.

Границы диапазонов вычисляются на основе параметров исходных функций принадлежности.

Шаг 2. Формирование наборов возможных значений параметров функций принадлежности.

Для каждой переменной и каждой функции принадлежности выполняется кодирование возможных значений параметров:

1. формируется множество пар «значение - двоичный код» для параметра l ;
2. формируется множество аналогичных пар для параметра c ;
3. формируется множество аналогичных пар для параметра r .

Шаг 3. Дискретизация диапазонов параметров.

Для каждого параметра диапазон значений разбивается на несколько значений с заданным шагом (определяемым параметром разбиения).

Для каждого полученного значения выполняется:

- вычисление числового значения параметра;
- преобразование этого значения в двоичный код;
- сохранение пары «значение – двоичный код» в соответствующее множество.

Шаг 4. Повторение процедуры кодирования.

Описанные операции выполняются для всех:

- входных переменных,
- функций принадлежности,
- параметров l , c и r .

Шаг 5. Формирование результирующих наборов.

После завершения кодирования формируются три итоговых множества:

- множество возможных значений параметра l с двоичными кодами;
- множество возможных значений параметра c с двоичными кодами;
- множество возможных значений параметра r с двоичными кодами.

Шаг 6. Возврат результатов работы алгоритма.

Алгоритм возвращает сформированные множества пар «значение параметра – двоичный код», которые далее используются при кодировании функций принадлежности, правил и всей базы знаний в генетическом алгоритме.

Основываясь на способе кодирования параметров функций принадлежности Алгоритма 1, предложен алгоритм формирования базы знаний S^{In} , состоящей из правил $Rule_p^{TR}$ – типичных представителей подмножеств Ω_p с функциями принадлежности $\mu_{A_{ij_i}}^{Tr}$.

Алгоритм 2. Алгоритм формирования промежуточной базы знаний на основе коллективной базы знаний с помощью генетической оптимизации.

Шаг 1. Инициализация начальных параметров алгоритма: размер популяции W , вероятность мутации генов в хромосомах P_{mut} , количество точек скрещивания g , максимальное число «пустых» итераций, то есть итераций алгоритма, не приводящих к увеличению фитнес-функции вида (3).

Шаг 2. Случайным образом формируется начальная популяция, состоящая из W хромосом, каждая из которых кодирует соответствующую базу знаний.

Шаг 3. Для всех хромосом текущей популяции вычисляется значение фитнес-функции (3); хромосома, имеющая наибольшее значение фитнеса, рассматривается как текущий кандидат на промежуточную базу знаний.

Шаг 4. Из популяции отбираются две родительские хромосомы, предназначенные для последующей операции скрещивания.

Шаг 5. Выполняется операция скрещивания выбранных родительских хромосом, в результате которой формируются две дочерние хромосомы.

Шаг 6. К генам дочерних хромосом применяется операция мутации с заданной вероятностью P_{mut} .

Шаг 7. Для полученных дочерних хромосом вычисляются значения фитнес-функции, после чего они добавляются в текущую популяцию.

Шаг 8. В обновленной популяции выявляются две хромосомы с наименьшими значениями фитнес-функции, которые затем исключаются из популяции.

Шаг 9. Определение сильнейшей хромосомы в обновленной популяции как хромосомы с максимальным фитнесом. Если значение фитнес-функции увеличилось по сравнению с фитнесом хромосомы промежуточной базы знаний, принять сильнейшую хромосому в качестве промежуточной базы знаний и перейти к шагу 4 на следующей итерации. В противном случае увеличить счетчик «пустых» итераций и проверить условие останова: если число пустых итераций не превысило заданное максимальное значение, перейти к шагу 4 на следующей итерации без изменения хромосомы промежуточной базы знаний. Иначе – переход к Шагу 10.

Шаг 10. Экстрагирование нечетких правил, функций принадлежности и их параметров из полученной промежуточной базы знаний.

2.5.2. Формирование компактной базы знаний S^*

После выполнения предварительной редукции исходной базы знаний формируется промежуточная база, размер которой уменьшается приблизительно в N раз. Однако даже в этом случае она может содержать избыточные или малоинформативные правила. Для дальнейшего сокращения их числа был разработан метод [29], включающий два последовательных этапа редукции:

1. Из промежуточной базы знаний S^{In} исключить все правила, коэффициент достоверности CF_{kl} которых равен нулю (пустые правила, которые не выполняются никогда):

$$S^{\varnothing} = S^{In} \setminus \{Rule_i^{TR} : CF_{kl} = 0\};$$

2. Отобрать только значимые правила $Rule_p^*$ из базы знаний $S^{\varnothing} = \{Rule_1, \dots, Rule_{N^{\varnothing}}\}$, где $N^{\varnothing}$ – количество непустых правил в базе,

сформировав итоговую компактную базу знаний $S^* = \{Rule_1^*, \dots, Rule_{N^*}^*\}$, где N^* – количество значимых правил, как решение следующей двухкритериальной оптимизационной задачи:

$$F_1(S^*) = \frac{N_{train_t}}{N_{train}} \rightarrow \max, \quad (5)$$

$$F_2(S^*) = \sum_{l=1}^{N^\varnothing} x_l \rightarrow \min, \quad (6)$$

$$S^* = \left\{ \bigcup_{l=1}^{N^\varnothing} (x_l \bullet Rule_l) \right\}, \quad (7)$$

$$x_l = \begin{cases} 1, & \text{если правило } Rule_l \text{ включено в БЗ,} \\ 0, & \text{если правило } Rule_l \text{ не включено в БЗ,} \end{cases} \quad l = \overline{1, N^\varnothing}. \quad (8)$$

Первый этап тривиален. Для реализации второго этапа применен метод преобразования многокритериальной оптимизационной задачи в однокритериальную на основе метода лексикографической оптимизации. Для этого критерии упорядочиваются по степени важности: критерий F_1 считается более важным, и ради его увеличения можно идти на любые потери по критерию F_2 . Тогда решение задачи (5)-(8) преобразуется в последовательность решения двух однокритериальных задач:

Задача 1. Решается задача вида (5), (7), (8) без учета значения целевой функции F_2 . Пусть S^* со значением $F_1^* = F_1(S^*)$ – решение задачи (5), (7), (8). Если оно единственное, то принимается за решение всей задачи векторной оптимизации (5)-(8). В противном случае переходят к решению второй задачи.

Задача 2. Решается задача вида:

$$F_1(S^*) = F_1^*,$$

$$F_2(S^*) = \sum_{l=1}^{N^\varnothing} x_l \rightarrow \min,$$

$$S^* = \left\{ \bigcup_{l=1}^{N^\varnothing} (x_l \bullet Rule_l) \right\},$$

$$x_l = \begin{cases} 1, & \text{если правило } Rule_l \text{ включено в БЗ,} \\ 0, & \text{если правило } Rule_l \text{ не включено в БЗ,} \end{cases} \quad l = \overline{1, N^\varnothing},$$

т.е. на множество решений задачи (5), (7), (8) ищется то решение S^* со значением $F_2^* = F_2(S^*)$, которое минимизирует значение целевой функции F_2 .

Для решения задачи (5)-(8) разработана модификация генетического алгоритма, где в качестве хромосом выступают вектора булевых значений $X^q = (x_1^q, \dots, x_{N^\varnothing}^q)$, $x_l^q \in \{0; 1\}$, $l = \overline{1, N^\varnothing}$, $q = \overline{1, W}$, где W – заданный объем

популяции. Шаги 1-9 алгоритма повторяют шаги Алгоритма 2. Завершающие шаги отражают лексикографический подход к решению двухкритериальной задачи (5)-(8):

Алгоритм 3. Алгоритм построения компактной базы знаний из промежуточной базы знаний с помощью лексикографической генетической оптимизации.

Шаг 1-9. Повторение шагов Алгоритма 2.

Шаг 10. Ранжирование оставшихся хромосом терминальной популяции по убыванию значения фитнес-функции (5). Пусть F_1^* – максимальное значение фитнес-функции для популяции.

Шаг 11. Отбор из терминальной популяции всех хромосом (базы знаний), на которых функция (5) достигает значения F_1^* . Пусть Q – число таких хромосом.

Шаг 12. Если $Q = 1$ принятие хромосомы $X^1 = (x_1^1, \dots, x_{N\varnothing}^1)$ в качестве решения задачи (5)-(8). При этом единичные значения x_l^1 будут соответствовать правилам, входящим в итоговую компактную базу знаний S^* . В противном случае переход к шагу 13.

Шаг 13. Среди хромосом $X^q = (x_1^q, \dots, x_{N\varnothing}^q)$, $q = \overline{1, Q}$ выбор единственной хромосомы X^{q^*} по критерию (6). При этом единичные значения $x_l^{q^*}$ будут соответствовать правилам, входящим в итоговую компактную базу знаний S^* .

2.6. Процесс лексической интерпретации ответа компактной нечеткой системы

Для лексической интерпретации ответа системы на естественном языке предложена следующая процедура:

- 1) на вход компактной нечеткой системы логического вывода, соответствующей полученной согласно Алгоритмам 1-2-3 компактной базе знаний S^* , подается вектор для классификации;
- 2) в процессе логического вывода рассчитываются коэффициенты отсечения (пороги) α_l всех логических правил системы, а также их результирующие выходы;
- 3) после окончания вычислений (классификации) правило $Rule_l^*$ с максимальным значением произведения критерия достоверности CF_{kl} для этого правила, найденного по формуле (2), и порога отсечения α_l интерпретируется на естественном языке в качестве объяснения принятого решения:

$$Rule_l^* = \arg \max_{l=1, N^*} (\alpha_l \cdot CF_{kl}).$$

Таким образом, хотя в процессе расчета нечеткая система может задействовать несколько правил с ненулевым выходом одновременно, для выражения причин выбора одного из классов на естественном языке используется интерпретация единственного правила $Rule_l^*$ с максимальным значением произведения $\alpha_l \bullet CF_{kl}$ для заданного входного вектора. Это правило гарантированно будет входить в число правил с ненулевым выходом системы и иметь максимальное влияние в процессе логического вывода.

3. Результаты

3.1. Решение задачи оценки функционального состояния человека

Разработанная компактная модель была применена для оценки состояния водителей транспортных средств на основе пупиллометрии в реальном времени. В качестве исходных выступали данные, полученные с разработанного носимого устройства. Фрагмент данных был представлен в Таблице 2. Исходная (коллективная) база знаний формировалась, исходя из следующих начальных условий [30]:

- число обучающих примеров: $N_{train} = 1200$;
- число тестовых примеров: $N_{test} = 300$;
- число баз знаний в коллективе: $N = 3$;
- число входных параметров: $n = 4$: $x_1 = A_c$, $x_2 = t_c$, $x_3 = D_{min}$, $x_4 = D_{hc}$;
- число классов оценки состояния водителей: $K = 2$ ($B_1 = 0$ – бодрый или нормальный, $B_2 = 1$ – усталый);
- число градаций антецедентов: $m_i = 3$ (соответствуют вербальным градациям $A_{i1} = \text{«малый»}$, $A_{i2} = \text{«средний»}$, $A_{i3} = \text{«большой»}$), $i = \overline{1, 4}$;
- число правил в каждой базе коллектива: $N_{full} = K \prod_{i=1}^4 m_i = 2 \cdot 81 = 162$;
- вид функций принадлежности антецедентов: треугольная с параметрами (l, c, r) .

На первом этапе была сформирована коллективная исходная база знаний, состоящая из 486 правил, фрагмент которой представлен в Таблице 3.

ТАБЛИЦА 3: Правила исходной базы знаний для оценки функционального состояния водителей (фрагмент)

	A_c	t_c	D_{min}	D_{hc}	Состояние водителя	CF	Note
Rule ₁	IF малый	& малый	& средний	& средний	THEN утомление	0,2361	
Rule ₂	IF большой	& средний	& малый	& средний	THEN норма	0,0851	
Rule ₃	IF средний	& средний	& средний	& малый	THEN норма	0,0000	Незначашее правило
Rule ₄	IF малый	& малый	& средний	& большой	THEN утомление	0,0460	
Rule ₅	IF большой	& малый	& малый	& средний	THEN норма	0,0389	
Rule ₆	IF средний	& средний	& малый	& средний	THEN норма	0,0234	
...	...	...	...	...	...	...	...
Rule ₄₈₅	IF малый	& малый	& средний	& средний	THEN утомление	0,0000	Незначашее правило
Rule ₄₈₆	IF малый	& малый	& средний	& средний	THEN норма	0,0096	

После исключения незначущих (пустых) правил в системе осталось 116 правил. В результате применения Алгоритмов 1 и 2, база знаний была сокращена

до 62 значимых правил. Дальнейшее применение Алгоритма 3 позволило сократить промежуточную базу знаний до 29 правил, которые и представляют собой результирующую компактную модель оценки состояния водителя.

Правила компактной нечеткой классифицирующей системы представлены в Таблице 4.

ТАБЛИЦА 4: Правила компактной базы знаний для оценки функционального состояния водителей

	A_c	t_c	D_{min}	D_{hc}	Состояние водителя		CF
Rule ₁	IF малый & малый & средний & средний THEN	утомление	0.3905				
Rule ₂	IF малый & средний & средний & средний THEN	утомление	0.2729				
Rule ₃	IF средний & средний & малый & средний THEN	норма	0.1318				
Rule ₄	IF большой & малый & малый & средний THEN	норма	0.0848				
Rule ₅	IF малый & большой & малый & малый THEN	норма	0.0388				
Rule ₆	IF малый & средний & малый & средний THEN	норма	0.0338				
Rule ₇	IF средний & большой & малый & средний THEN	норма	0.0298				
Rule ₈	IF малый & малый & малый & средний THEN	норма	0.0265				
Rule ₉	IF малый & малый & средний & большой THEN	утомление	0.021				
Rule ₁₀	IF малый & малый & малый & средний THEN	утомление	0.0179				
Rule ₁₁	IF малый & средний & малый & средний THEN	утомление	0.0144				
Rule ₁₂	IF малый & большой & малый & средний THEN	норма	0.0135				
Rule ₁₃	IF большой & большой & малый & средний THEN	норма	0.0132				
Rule ₁₄	IF малый & средний & средний & средний THEN	норма	0.0128				
Rule ₁₅	IF большой & большой & малый & малый THEN	норма	0.0079				
Rule ₁₆	IF средний & малый & малый & большой THEN	норма	0.0077				
Rule ₁₇	IF большой & большой & малый & средний THEN	утомление	0.0076				
Rule ₁₈	IF средний & малый & большой & малый THEN	норма	0.0063				
Rule ₁₉	IF малый & большой & средний & средний THEN	утомление	0.0057				
Rule ₂₀	IF малый & малый & средний & малый THEN	утомление	0.0048				
Rule ₂₁	IF малый & средний & средний & малый THEN	утомление	0.0034				
Rule ₂₂	IF большой & малый & средний & малый THEN	норма	0.0032				
Rule ₂₃	IF средний & малый & большой & средний THEN	норма	0.0026				
Rule ₂₄	IF большой & малый & средний & средний THEN	норма	0.0022				
Rule ₂₅	IF малый & малый & малый & большой THEN	норма	0.0018				
Rule ₂₆	IF малый & малый & большой & малый THEN	норма	0.0015				
Rule ₂₇	IF малый & малый & большой & средний THEN	норма	0.0015				
Rule ₂₈	IF большой & малый & малый & большой THEN	норма	0.0014				
Rule ₂₉	IF большой & средний & малый & большой THEN	норма	0.0014				

Исследованы такие характеристики эффективности нейронечетких моделей на основе построенных баз знаний, как Accuracy, Precision, Recall и F1-Score на тестовой выборке данных (см. Рис. 4).

Соотношение объемов баз знаний в процессе редукции представлено на Рис. 5.

Из рисунков видно, что эффективность промежуточной базы знаний после редукции повысилась по всем четырем метрикам, при этом число правил сократилось почти вдвое. Дальнейшая редукция позволила сократить число правил в компактной базе еще более чем в два раза, при этом точность модели оценки состояния водителей осталась на прежнем высоком уровне.




Рис. 4: Характеристики точности классификации начальной (коллективной), промежуточной и итоговой (компактной) баз знаний

3.2. Пример интерпретации принятого предложенного компактной нечеткой системой решения на естественном языке

Пусть для определения состояния водителя транспортного средства в нечеткую компактную систему поступил следующий набор значений:

- амплитуда сужения зрачка $A_c = 0,1414$;
- время сужения зрачка $t_c = 0.28$;
- минимальный диаметр зрачка $D_{\min} = 0.3087$;
- скорость половинного сужения зрачка $D_{hc} = 0.3831$.

В процессе принятия решения системой и прохождения входных данных через компактный нечеткий классификатор, состоящий из 29 правил, для каждого правила вычислено значение порога отсечения α_l , $l = \overline{1, 29}$. В качестве ответа система приняла решение 1 – «водитель утомлен».

Далее, в результате применения процедуры логического вывода в качестве правила для лексической интерпретации отобрано $Rule_1$:

IF $A_c = \text{малый} \ \& \ t_c = \text{малый} \ \& \ D_{\min} = \text{средний} \ \& \ D_{hc} = \text{средний}$ THEN «**утомлен**»

с порогом отсечения $\alpha_9 = 0.89$ и коэффициентом доверия $CF_{19} = 0.3905$, так как произведение $0.89 \cdot 0.3905 = 0.347545$ является максимальным среди всех 29-ти правил для представленного набора входных данных.




Рис. 5: Сравнительные размеры начальной (коллективной), промежуточной и итоговой (компактной) баз знаний

Тогда ответ системы можно лексически представить следующим образом: «Система считает, что водитель устал (находится в состоянии утомления), так как амплитуда и время сужения его зрачка малые, а минимальный диаметр зрачка и скорость половинного сужения находятся в среднем диапазоне».

Заключение

В работе предложен подход к автоматическому определению функционального состояния утомления человека на основе анализа пупиллометрических данных с использованием нейронечеткой модели. Разработанная система ориентирована на применение в задачах мониторинга состояния человека в реальном времени и может использоваться, в частности, для контроля состояния водителей транспортных средств и операторов ответственных систем.

Для получения исходных данных была разработана двухэтапная технология сбора и обработки пупиллометрической информации. На первом этапе выполняется регистрация коротких видеозаписей зрачковой реакции с использованием носимого устройства на базе микрокомпьютера, а на втором этапе производится обработка видеоданных и формирование пупиллограмм. На основе анализа полученных временных рядов были выделены информативные параметры, характеризующие реакцию зрачка на изменение освещенности, включая амплитуду и время сужения зрачка, минимальный диаметр и скорость половинного сужения.

Для построения модели классификации предложено использовать ансамбль нейронечетких сетей, каждая из которых формирует собственную систему нечетких правил. Такой подход позволяет снизить влияние случайности при автоматическом формировании баз знаний и повысить устойчивость модели. В то же время коллективная база знаний содержит значительное число правил, что затрудняет

интерпретацию результатов и увеличивает вычислительные затраты. Для решения этой проблемы разработан двухэтапный метод редукции нечетких правил. На первом этапе выполняется объединение лингвистически идентичных правил и формирование промежуточной базы знаний с использованием модифицированного генетического алгоритма. На втором этапе проводится дальнейшее сокращение числа правил на основе лексикографической оптимизации, позволяющей одновременно учитывать точность классификации и компактность модели. В результате применения предложенных алгоритмов удалось существенно уменьшить размер базы знаний при сохранении и даже небольшом улучшении качества классификации.

Экспериментальные исследования показали, что предложенный метод позволяет значительно сократить число нечетких правил и повысить эффективность модели, сохранив высокую точность распознавания состояния человека. Полученная компактная база знаний обеспечивает возможность однозначной лингвистической интерпретации результатов, что повышает доверие пользователей к принимаемым системой решениям и облегчает её использование в практических интеллектуальных системах.

Предложенные методы формирования и редукции нечетких баз знаний могут применяться не только для оценки функционального состояния человека, но и в других задачах классификации дискретных состояний объектов. Дальнейшие исследования могут быть направлены на расширение набора анализируемых физиологических параметров, совершенствование методов обучения нейронечетких моделей и адаптацию предложенного подхода для работы в различных прикладных областях.

Список литературы

- [1] Цимбал М.В., Куцало А.Л., Штейнберг Н.В., Хомич Д.С. О референтных нормах показателей пупиллометрии при использовании компьютерного комплекса для регистрации и оценки зрачковой реакции // Вестник Волгоградского государственного медицинского университета. 2020. № 1 (73). С. 124–128.
- [2] Кутлубаев М.А., Шагиева Д.Р., Каримова Г.И. Пупиллометрия в оценке психоэмоционального состояния и когнитивных функций человека // Журнал высшей нервной деятельности им. И.П. Павлова. 2023. Т. 73, № 5. С. 651–665. <https://doi.org/10.31857/S0044467723050064>
- [3] Alshanskaia E.I., Portnova G.V., Liaukovich K., Martynova O.V. Pupillometry and autonomic nervous system responses to cognitive load and false feedback: an unsupervised machine learning approach // Frontiers in Neuroscience. 2024. Vol. 18. ID 1445697. <https://doi.org/10.3389/fnins.2024.1445697>
- [4] Sugeno M. A note on derivatives of functions with respect to fuzzy measures // Fuzzy Sets and Systems. 2013. Vol. 222. Pp. 1–17. <https://doi.org/10.1016/j.fss.2012.11.003>
- [5] Кремлева Э.Ш., Снегуренко А.П., Новикова С.В., Валитова Н.Л. Автоматическая генерация рекомендующих систем на основе качественной интерпре-

- тации мониторинговой информации // Вестник ТвГУ. Серия: Прикладная математика. 2020. № 3. С. 50–67. <https://doi.org/10.26456/vtpmk599>
- [6] Нгуен Т.Т.З. Новая гауссовская система нечёткого логического вывода типа Такаги-Сугено-Канга с весом главного компонента // International Journal of Open Information Technologies. 2024. Т. 12, № 5. С. 116–124.
- [7] Солдатова О.П., Лезин И.А., Лезина И.В. Исследование эффективности алгоритмов генерации базы нечетких продукционных правил для нейронной сети Ванга - Менделя // Известия высших учебных заведений. Поволжский регион. Технические науки. 2023. № 1 (65). С. 86–100. <https://doi.org/10.21685/2072-3059-2023-1-7>
- [8] Obratsov R.A., Sharov V.D. On the use of fuzzy neural networks in the framework of a risk-based approach in control and supervisory activities in civil aviation // Civil Aviation High Technologies. 2026. Vol. 26, № 1. Pp. 58–71. <https://doi.org/10.26467/2079-0619-2023-26-1-58-71>
- [9] Dagaeva M., Katasev A. Fuzzy Rules Reduction in Knowledge Bases of Decision Support Systems by Objects State Evaluation // Cyber-Physical Systems: Modelling and Intelligent Control. Series: Studies in Systems, Decision and Control. Cham: Springer, 2021. https://doi.org/10.1007/978-3-030-66077-2_9
- [10] Сидняев Н.И., Синева Е.Е. Построение составных критериев для оптимизации термов и обобщенного показателя баз знаний интеллектуальных систем // Вопросы кибербезопасности. 2023. № 2(54). С. 23–35.
- [11] Camastra F., Ciarabella A., Salvi G., Sposato S., Staiano A. On the interpretability of fuzzy knowledge base systems // PeerJ Computer Science. 2024. Vol. 10. ID e2558. <https://doi.org/10.7717/peerj-cs.2558>
- [12] Agranovich Y.Y., Kontsevaya N.V., Podvalny S.L. A synthesis of statistical and deterministic methods in problem of smoothing for time series // Automation and Remote Control. 2014. Vol. 75. Pp. 971–976. <https://doi.org/10.1134/S0005117914050154>
- [13] Макаров А.В., Намиот Д.Е. Обзор методов очистки данных для машинного обучения // International Journal of Open Information Technologies. 2023. Т. 11, № 10. С. 70–78.
- [14] Гатин Р.Р., Новикова С.В. Модель оценки степени уникальности и восстановления слабо-определенных данных на основе модификации нейронной сети АРТ-2 // Вестник ТвГУ. Серия: Прикладная математика. 2024. № 2. С. 39–59. <https://doi.org/10.26456/vtpmk709>
- [15] O'Connell N.S., Jaeger B.C., Bullock G.S., Speiser J.L. A comparison of random forest variable selection methods for regression modeling of continuous outcomes // Briefings in Bioinformatics. 2025. Vol. 26, № 2. ID bbaf096. <https://doi.org/10.1093/bib/bbaf096>
- [16] Хомидов М.Э., Гоипов Э.А. Методы обработки биомедицинских сигналов и изображений // Universum: технические науки. 2020. № 8-1(77). С. 32–34.

- [17] Dai J., Wang X., Hang C. Evaluating the effectiveness of quantitative pupillometry in assessing dynamic aerobic training intensity // Scientific Reports. 2024. Vol. 14. ID 26071. <https://doi.org/10.1038/s41598-024-77588-z>
- [18] Мельников А.А., Громова А.В., Бойков В.Л. Изменение зрачкового светового рефлекса после легкой нагрузки у спортсменов // Современные вопросы биомедицины. 2025. № 2. С. 129–132.
- [19] Reimer J., McGinley M.J., Liu Y., Rodenkirch C., Wang Q., McCormick D.A., Tolias A.S. Pupil fluctuations track rapid changes in adrenergic and cholinergic activity in cortex // Nature Communications. 2016. Vol. 7. ID 13289. <https://doi.org/10.1038/ncomms13289>
- [20] Волосников А.С. Применение дифференцирующего фильтра Савицкого-Голея при восстановлении входного сигнала датчика // Измерительная техника. 2025. Т. 74, № 6. С. 13–22. <https://doi.org/10.32446/0368-1025it.2025-6-13-22>
- [21] Dawidziuk A., Butters E., Lindegger D.J., Foubister C., Chrost H., Wlodarski M., Grogan J., Rowicka P.A., Bremner F., Manohar S.G. Can the Pupillary Light Reflex and Pupillary Unrest Be Used as Biomarkers of Parkinson's Disease? A Systematic Review and Meta-Analysis // Diagnostics. 2025. Vol. 15, № 9. ID 1167. <https://doi.org/10.3390/diagnostics15091167>
- [22] Исанбаева А.Р., Кутлубаев М.А., Шагиева Д.Р., Лютов О.В. Пупиллометрия в нейропедиатрической практике: теоретические и клинические аспекты // Медицинский вестник Башкортостана. 2024. Т. 19, № 5(113). С. 95–100.
- [23] Круглов В.В., Дли М.И., Голунов Р.Ю. Нечеткая логика и искусственные нейронные сети. М.: Физматлит, 2001. 198 с.
- [24] Wettayaprasit W., Lursinsap C., Chu C.H. Rule extraction from neural networks using fuzzy sets // Proceedings of the 9th International Conference on Neural Information Processing. 2002. Pp. 2582–2586. <https://doi.org/10.1109/ICONIP.2002.1201962>
- [25] Торкунова Ю.В., Милованов Д.В. Оптимизация нейронных сетей: методы и их сравнение на примере интеллектуального анализа текста // International Journal of Advanced Studies. 2023. Т. 13, № 4. С. 142–158. <https://doi.org/10.12731/2227-930X-2023-13-4-142-158>
- [26] Zhang H., Dauphin Y., Ma T. Fixup Initialization: Residual Learning Without Normalization. arXiv preprint arXiv:1901.09321. 2019.
- [27] Ho T.K. Random Decision Forests // Proceedings of the 3rd International Conference on Document Analysis and Recognition. 1995. Pp. 278–282.
- [28] Катасев А.С., Дагаева М.В., Хасбиуллин М.Ф. Нейронечеткая система формирования нечетких моделей оценки дискретного состояния объектов // Научно-технический вестник Поволжья. 2023. № 7. С. 60–63.

- [29] Дагаева М.В., Катасев А.С. Методы и алгоритмы редукции нечётких правил в моделях оценки дискретного состояния объектов // Прикаспийский журнал: управление и высокие технологии. 2023. № 3(63). С. 20–27.
- [30] Дагаева М.В., Катасев А.С., Хасбиуллин М.Ф. Программный комплекс редукции нечетких правил в моделях оценки дискретного состояния объектов // Научно-технический вестник Поволжья. 2023. № 7. С. 34–37.

Образец цитирования

Катасёв А.С., Новикова С.В., Катасёва Д.В., Дагаева М.В., Кузенкова Г.В. Нейронечеткая ансамблевая модель определения функционального состояния утомления водителя транспортного средства с использованием пупиллометрии // Вестник ТвГУ. Серия: Прикладная математика. 2026. №2. С. 56–82. <https://doi.org/10.26456/vtpmk775>

Сведения об авторах

1. Катасёв Алексей Сергеевич

профессор кафедры систем информационной безопасности ФГБОУ ВО «Казанский национальный исследовательский технический университет им. А.Н. Туполева – КАИ».

*Россия, 420015, г. Казань, ул. Большая Красная, д. 55, КНИТУ-КАИ.
E-mail: ASKatasev@kai.ru*

2. Новикова Светлана Владимировна

профессор кафедры прикладной математики и информатики Казанского национального исследовательского технического университета им. А.Н. Туполева – КАИ.

*Россия, 420015, г. Казань, ул. Большая Красная, д. 55, КНИТУ-КАИ.
E-mail: SVNovikova@kai.ru*

3. Катасёва Дина Владимировна

доцент кафедры систем информационной безопасности ФГБОУ ВО «Казанский национальный исследовательский технический университет им. А.Н. Туполева – КАИ».

*Россия, 420015, г. Казань, ул. Большая Красная, д. 55, КНИТУ-КАИ.
E-mail: DVKataseva@kai.ru*

4. Дагаева Мария Витальевна

начальник центра разработки и сопровождения информационных систем ГБУ «Безопасность дорожного движения».

*Россия, 420059, г. Казань, Оренбургский тракт, 5, ГБУ БДД.
E-mail: MVDagaeva@kai.ru*

5. Кузенкова Галина Владимировна

доцент кафедры математического обеспечения и суперкомпьютерных технологий Национального исследовательского Нижегородского государственного университета им. Н.И. Лобачевского.

Россия, 603022, г. Нижний Новгород, проспект Гагарина, 23, ННГУ им. Лобачевского. E-mail: galina.kuzenkova@itmm.unn.ru

NEURO-FUZZY ENSEMBLE MODEL FOR DETERMINING THE DRIVER'S FATIGUE FUNCTIONAL STATE USING PUPILLOMETRY

Katasev A.S.* , Novikova S.V.* , Kataseva D.V.* , Dagaeva M.V.** ,
Kuzenkova G.V.***

*Kazan National Research Technical University – KAI, Kazan

**GBU “Road Safety”, Kazan

***Lobachevsky National Research Nizhny Novgorod State University, Nizhny
Novgorod

Received 13.03.2026, revised 01.04.2026.

This paper proposes a method for the automatic determination of a driver's fatigue functional state based on the analysis of pupillometry data. The system includes a wearable non-invasive device for recording the pupil response to a light stimulus and a software module implementing a neuro-fuzzy classification model. To form the training dataset, a two-stage technology for collecting and processing video recordings of pupil reactions was developed, followed by the construction of pupillograms. A dataset containing 1500 observations was formed (750 for the alert state and 750 for the fatigue state). The following features were used as input parameters: constriction amplitude, constriction time, minimum pupil diameter, and half-constriction velocity. An ensemble of six neuro-fuzzy networks was used to build the classifier, forming a collective knowledge base. To reduce rule redundancy, a two-stage rule reduction method was proposed based on merging linguistically identical fuzzy rules and applying a modified genetic algorithm. As a result, the number of rules was reduced from 486 to 29, which corresponds to a 98.77% reduction in the knowledge base size, while the classification accuracy increased by 1.47%. The resulting compact model ensures high recognition accuracy and provides the possibility of interpreting the results in natural language.

Keywords: human functional state, pupillometry, neuro-fuzzy ensemble networks, linguistically identical fuzzy rules, fuzzy rule reduction, membership function, genetic algorithm.

Citation

Katasev A.S., Novikova S.V., Kataseva D.V., Dagaeva M.V., Kuzenkova G.V., “Neuro-Fuzzy Ensemble Model for Determining the Driver's Fatigue Functional State Using Pupillometry”, *Vestnik TvGU. Seriya: Prikladnaya Matematika [Herald of Tver State University. Series: Applied Mathematics]*, 2026, № 2, 56–82 (in Russian). <https://doi.org/10.26456/vtpmk775>

References

- [1] Tsimbal M.V., Kutsalo A.L., Shtejnberg N.V., Khomich D.S., “On Reference Norms of Pupillometry Indicators When Using a Computer Complex for Recording and Assessing Pupillary Reaction”, *Vestnik Volgogradskogo gosudarstvennogo meditsinskogo universiteta [Bulletin of Volgograd State Medical University]*, 2020, №1 (73), 124–128 (in Russian).
- [2] Kutlubaev M.A., Shagieva D.R., Karimova G.I., “Pupillometry in Assessing the Psychoemotional State and Cognitive Functions of a Person”, *Zhurnal vysshej nervnoj deyatel'nosti im. I.P. Pavlova [I.P. Pavlov Journal of Higher Nervous Activity]*, **73**:5 (2023), 651–665 (in Russian), <https://doi.org/10.31857/S0044467723050064>.
- [3] Alshanskaia E.I., Portnova G.V., Liaukovich K., Martynova O.V., “Pupillometry and autonomic nervous system responses to cognitive load and false feedback: an unsupervised machine learning approach”, *Frontiers in Neuroscience*, **18** (2024), 1445697, <https://doi.org/10.3389/fnins.2024.1445697>.
- [4] Sugeno M., “A note on derivatives of functions with respect to fuzzy measures”, *Fuzzy Sets and Systems*, **222** (2013), 1–17, <https://doi.org/10.1016/j.fss.2012.11.003>.
- [5] Kremleva E.Sh., Snegurenko A.P., Novikova S.V., Valitova N.L., “Automatic Generation of Recommender Systems Based on Qualitative Interpretation of Monitoring Information”, *Vestnik TvGU. Seriya: Prikladnaya Matematika [Herald of Tver State University. Series: Applied Mathematics]*, 2020, №3, 50–67 (in Russian), <https://doi.org/10.26456/vtpmk599>.
- [6] Nguen T.T.Z., “A New Gaussian Fuzzy Inference System of Takagi-Sugeno-Kang Type with Principal Component Weight”, *International Journal of Open Information Technologies*, **12**:5 (2024), 116–124 (in Russian).
- [7] Soldatova O.P., Lezin I.A., Lezina I.V., “Study of the Efficiency of Algorithms for Generating a Fuzzy Production Rule Base for the Wang-Mendel Neural Network”, *Izvestiya vysshikh uchebnykh zavedenij. Povolzhskij region. Tekhnicheskie nauki [University Proceedings. Volga Region. Technical Sciences]*, 2023, №1 (65), 86–100 (in Russian), <https://doi.org/10.21685/2072-3059-2023-1-7>.
- [8] Obraztsov R.A., Sharov V.D., “On the use of fuzzy neural networks in the framework of a risk-based approach in control and supervisory activities in civil aviation”, *Civil Aviation High Technologies*, **26**:1 (2026), 58–71, <https://doi.org/10.26467/2079-0619-2023-26-1-58-71>.
- [9] Dagaeva M., Katasev A., “Fuzzy Rules Reduction in Knowledge Bases of Decision Support Systems by Objects State Evaluation”, *Cyber-Physical Systems: Modelling and Intelligent Control*, Studies in Systems, Decision and Control, Springer, Cham, 2021, https://doi.org/10.1007/978-3-030-66077-2_9.
- [10] Sidnyaev N.I., Sineva E.E., “Construction of Composite Criteria for Optimizing Terms and a Generalized Indicator of Knowledge Bases of Intelligent Systems”,

- Voprosy kiberbezopasnosti [Cybersecurity Issues]*, 2023, № 2(54), 23–35 (in Russian).
- [11] Camastra F., Ciaramella A., Salvi G., Sposato S., Staiano A., “On the interpretability of fuzzy knowledge base systems”, *PeerJ Computer Science*, **10** (2024), e2558, <https://doi.org/10.7717/peerj-cs.2558>.
 - [12] Agranovich Y.Y., Kontsevaya N.V., Podvalny S.L., “A synthesis of statistical and deterministic methods in problem of smoothing for time series”, *Automation and Remote Control*, **75** (2014), 971–976, <https://doi.org/10.1134/S0005117914050154>.
 - [13] Makarov A.V., Namiot D.E., “Review of Data Cleaning Methods for Machine Learning”, *International Journal of Open Information Technologies*, **11**:10 (2023), 70–78 (in Russian).
 - [14] Gatin R.R., Novikova S.V., “Model for Assessing the Degree of Uniqueness and Recovery of Weakly Defined Data Based on a Modification of the APT-2 Neural Network”, *Vestnik TvGU. Seriya: Prikladnaya Matematika [Herald of Tver State University. Series: Applied Mathematics]*, 2024, № 2, 39–59 (in Russian), <https://doi.org/10.26456/vtpmk709>.
 - [15] O’Connell N.S., Jaeger B.C., Bullock G.S., Speiser J.L., “A comparison of random forest variable selection methods for regression modeling of continuous outcomes”, *Briefings in Bioinformatics*, **26**:2 (2025), bbaf096, <https://doi.org/10.1093/bib/bbaf096>.
 - [16] Khomidov M.E., Goipov E.A., “Methods for Processing Biomedical Signals and Images”, *Universum: tekhnicheskie nauki [Universum: Technical Sciences]*, 2020, № 8-1(77), 32–34 (in Russian).
 - [17] Dai J., Wang X., Hang C., “Evaluating the effectiveness of quantitative pupillometry in assessing dynamic aerobic training intensity”, *Scientific Reports*, **14** (2024), 26071, <https://doi.org/10.1038/s41598-024-77588-z>.
 - [18] Melnikov A.A., Gromova A.V., Bojkov V.L., “Change in the Pupillary Light Reflex After Light Exercise in Athletes”, *Sovremennye voprosy biomeditsiny [Modern Issues of Biomedicine]*, 2025, № 2, 129–132 (in Russian).
 - [19] Reimer J., McGinley M.J., Liu Y., Rodenkirch C., Wang Q., McCormick D.A., Tolia A.S., “Pupil fluctuations track rapid changes in adrenergic and cholinergic activity in cortex”, *Nature Communications*, **7** (2016), 13289, <https://doi.org/10.1038/ncomms13289>.
 - [20] Volosnikov A.S., “Application of the Savitzky-Golay Differentiating Filter in Recovering the Sensor Input Signal”, *Izmeritelnaya tekhnika [Measurement Techniques]*, **74**:6 (2025), 13–22 (in Russian), <https://doi.org/10.32446/0368-1025it.2025-6-13-22>.
 - [21] Dawidziuk A., Butters E., Lindegger D.J., Foubister C., Chrost H., Wlodarski M., Grogan J., Rowicka P.A., Bremner F., Manohar S.G., “Can the Pupillary

- Light Reflex and Pupillary Unrest Be Used as Biomarkers of Parkinson's Disease? A Systematic Review and Meta-Analysis", *Diagnostics*, **15**:9 (2025), 1167, <https://doi.org/10.3390/diagnostics15091167>.
- [22] Isanbaeva A.R., Kutlubaev M.A., Shagieva D.R., Lyutov O.V., "Pupillometry in Neuropediatric Practice: Theoretical and Clinical Aspects", *Meditinskij vestnik Bashkortostana [Medical Bulletin of Bashkortostan]*, **19**:5(113) (2024), 95–100 (in Russian).
- [23] Kruglov V.V., Dli M.I., Golunov R.Yu., *Nechetkaya logika i iskusstvennye neyronnye seti [Fuzzy Logic and Artificial Neural Networks]*, Fizmatlit Publ., Moscow, 2001 (in Russian), 198 pp.
- [24] Wettayaprasit W., Lursinsap C., Chu C.H., "Rule extraction from neural networks using fuzzy sets", *Proceedings of the 9th International Conference on Neural Information Processing*, 2002, 2582–2586, <https://doi.org/10.1109/ICONIP.2002.1201962>.
- [25] Torkunova Yu.V., Milovanov D.V., "Optimization of Neural Networks: Methods and Their Comparison on the Example of Text Mining", *International Journal of Advanced Studies*, **13**:4 (2023), 142–158 (in Russian), <https://doi.org/10.12731/2227-930X-2023-13-4-142-158>.
- [26] Zhang H., Dauphin Y., Ma T., *Fixup Initialization: Residual Learning Without Normalization*, arXiv preprint arXiv:1901.09321, 2019.
- [27] Ho T.K., "Random Decision Forests", *Proceedings of the 3rd International Conference on Document Analysis and Recognition*, 1995, 278–282.
- [28] Katasev A.S., Dagaeva M.V., Khasbiullin M.F., "Neuro-Fuzzy System for Forming Fuzzy Models for Assessing the Discrete State of Objects", *Nauchno-tekhnicheskij vestnik Povolzhya [Scientific and Technical Bulletin of the Volga Region]*, 2023, № 7, 60–63 (in Russian).
- [29] Dagaeva M.V., Katasev A.S., "Methods and Algorithms for Reducing Fuzzy Rules in Models for Assessing the Discrete State of Objects", *Prikaspijskij zhurnal: upravlenie i vysokie tekhnologii [Caspian Journal: Management and High Technologies]*, 2023, № 3(63), 20–27 (in Russian).
- [30] Dagaeva M.V., Katasev A.S., Khasbiullin M.F., "Software Package for Reducing Fuzzy Rules in Models for Assessing the Discrete State of Objects", *Nauchno-tekhnicheskij vestnik Povolzhya [Scientific and Technical Bulletin of the Volga Region]*, 2023, № 7, 34–37 (in Russian).

Author Info

1. Katasev Alexey Sergeyevich

Professor of the Department of Information Security Systems, Kazan National Research Technical University named after A.N. Tupolev – KAI.

Russia, 420015, Kazan, 55 Bolshaya Krasnaya str., KNRTU-KAI.

E-mail: ASKatasev@kai.ru

2. Novikova Svetlana Vladimirovna

Professor at the Department of Applied Mathematics and Computer Science, Kazan National Research Technical University named after A.N. Tupolev – KAI.

Russia, 420015, Kazan, 55 Bolshaya Krasnaya str., KNRTU-KAI.

E-mail: SVNovikova@kai.ru

3. Kataseva Dina Vladimirovna

Associate Professor of the Department of Information Security Systems, Kazan National Research Technical University named after A.N. Tupolev – KAI.

Russia, 420015, Kazan, 55 Bolshaya Krasnaya str., KNRTU-KAI.

E-mail: DVKataseva@kai.ru

4. Dagaeva Mariya Vitalyevna

Head of the Center for Development and maintenance of information systems of GBU "Road Safety".

Russia, 420059, Kazan, Orenburg tract, 5, GBU BDD. E-mail: MVDagaeva@kai.ru

5. Kuzenkova Galina Vladimirovna

Associate Professor, Department of Mathematical Support and Supercomputing Technologies, N.I. Lobachevsky National Research Nizhny Novgorod State University.

Russia, 603022, Nizhny Novgorod, Gagarin Avenue, 23, Lobachevsky NNSU.

E-mail: galina.kuzenkova@itmm.unn.ru