

Совместное использование моделей и методов нейронных сетей и теории свидетельств в нечетких системах управления и диагностики *

В. К. Иванов, Б. В. Палюх

Тверской государственной технической университет, г. Тверь, Россия

Аннотация. В статье описываются результаты исследования совместного использования методов интеллектуальной обработки данных, таких как нейронные сети и алгоритмы теории свидетельств. Исследование включает анализ описаний современных разработок, опубликованных за последнее время. Рассмотрены описания состава, структуры и функционирования основных алгоритмов систем, разработанных для проектов в различных областях. Определены варианты совместного применения нейронных сетей и алгоритмов теории свидетельств, включая особенности их архитектур и реализации. Получено подтверждение эффективности совместного применения указанных методов в части уменьшения уровня неопределенности и увеличения уровня доверия к данным, используемым для принятия решений. Областью применения результатов настоящего исследования является проектирование архитектурных решений гибридной экспертной системы для диагностики состояния технологических процессов и обнаружения аномалий в них.

Ключевые слова: нейронная сеть, теория свидетельств Демпстера-Шафера, гибридная экспертная система, диагностика, технологический процесс, нечеткая система, обучение сети, функция доверия.

DOI

Введение

В принятии решений при управлении непрерывным многостадийным производством существенную положительную роль может играть динамическая экспертная система для диагностики состояния технологических процессов и обнаружения аномалий в них. Методологическая база для разработки такой системы должна учитывать объективные условия неопределенности при получении и анализе данных от сенсоров технологического оборудования, из технических регламентов, а также от специалистов-экспертов. Эта неопределенность в нечетких системах порождает проблему доверия к

данным, используемым для принятия решений, которые могут иметь критический характер для непрерывных производств.

В обзорных материалах, посвященных проблемам оценки доверия к данным в системах машинного обучения [1], мультиагентных системах [2], системах e-commerce [3], web-приложениях [4], отмечаются не до конца решенные в этой области задачи, а именно: разработка общих методик количественных дифференцированных оценок мер доверия к данным, исследование методов комбинирования различных алгоритмов для значимого повышения эффективности, детальное и полное объяснение результатов оценки данных. Одним из общих подходов снижения этой неопределенности в используемых данных и повыше-

* Исследование Работа выполнена при финансовой поддержке РФФИ (проект № 20-07-00199).

✉ Иванов Владимир Константинович. E-mail: mtivk@mail.ru

ния степени доверия к ним может являться гибридизация экспертной системы – совместное использование нескольких методов интеллектуальной обработки нечеткой информации. При этом ожидается более высокая синергетическая эффективность по сравнению с автономным использованием отдельных методов.

Цели исследования, результаты которого представлены в настоящей статье, следующие. Во-первых, на примерах современных практик разработки интеллектуальных систем определить варианты совместного применения методов нейронных сетей и теории свидетельств в гибридной экспертной системе для диагностики состояния технологических процессов. Во-вторых, получить подтверждения эффективности совместного применения указанных методов в части уменьшения уровня неопределенности и увеличения уровня доверия к данным, используемым для принятия решений.

Отметим, что потенциальной областью применения искусственных нейронных сетей является решение плохо формализованных задач, где традиционные вычисления трудоемки или неадекватны, а теория свидетельств является общей основой обработки данных с неопределенностью, позволяющая объединить свидетельства о некоторых событиях из разных источников и установить определенную степень уверенности в наличии того или иного события.

Результаты настоящего исследования использованы при реализации нечеткой нейронной сети для оценки состояния сложного многостадийного технологического процесса, работы над которой являются частью проекта РФФИ № 20-07-00199 «Методы и модели детектирования бифуркаций многомерных случайных процессов в динамических экспертных системах». Основные этапы работ: разработка алгоритмов совместной обработки первичных данных о состоянии технологического процесса на базе теории свидетельств, генерация базы нечетких продукционных правил на основе полученных вероятностных характеристик событий, реализация обучения нечеткой нейронной сети с использованием сгенерированной базы правил, разработка соответствующего программного обеспечения и технологической базы данных.

Подбор материалов для анализа, в основном, осуществлялся в следующих базах данных: ACM Digital Library (dlnext.acm.org) и IEEE

Xplore Digital Library (ieeexplore.ieee.org), Springer International Publishing (www.springer.com), а также материалах Научной электронной библиотеки (elibrary.ru) и Федерального института промышленной собственности (fips.ru). Принимались во внимание относительно недавние публикации (глубина поиска – около 6 лет). Всего было отобрано около 150 публикаций авторов из 19 стран, для детального анализа оставлена треть из них. Список включает в основном работы зарубежных авторов, но это не означает отсутствие вклада российских исследователей в проблематику данной статьи. Большое количество публикаций отечественных авторов посвящено нейронным сетям. Вопросы теории свидетельств также находят свое отражение в научных изданиях. Примеры обсуждений актуальных вопросов теоретических проблем, прикладных аспектов и применений решений теории свидетельств приведены в [5-10] и др. Однако совместное применение этих методов, по-видимому, является предметом дальнейших исследований.

В целом не ставилась задача поиска максимального количества материалов по теме. Важно было определить основные направления исследований и разработок по обсуждаемой тематике. В статье приводятся краткие сведения о применимости нейронных сетей и алгоритмов теории свидетельств, выделяются особенности их совместного использования в диагностических системах. Типы применения обсуждаемых методов иллюстрируются многочисленными примерами. По результатам исследования сформулированы выводы.

1. Основы нейронных сетей и теории свидетельств

1.1. Нейронные сети

Нейронные сети (НС) – искусственные, многослойные высокопараллельные логические структуры, составленные из формальных нейронов [11]. Формальный нейрон представляет собой логический элемент с N входами, $(N + 1)$ весовыми коэффициентами, сумматором и нелинейным преобразователем. Простейший формальный нейрон осуществляет логическое преобразование входных сигналов (которыми могут являться выходные сигналы других формальных нейронов) в выходной сигнал:

$$y = \text{sign} \sum_{i=0}^N a_i x_i, \quad (1)$$

где y – значение выхода формального нейрона; a_i – весовые коэффициенты; x_i – входные значения формального нейрона ($x_i \in \{0, 1\}$, $x_0 = 1$).

Процесс вычисления y представляет собой движение потока данных и их преобразование. Сначала данные поступают на блок входа формального нейрона, где происходит умножение исходных данных на соответствующие весовые коэффициенты, т.н. синоптические веса. Весовой коэффициент является мерой, которая определяет насколько соответствующее входное значение влияет на состояние формального нейрона. Весовые коэффициенты могут изменяться в соответствии с обучающими примерами, архитектурой НС, правилами обучения и др. Полученные значения преобразуются в сумматоре в одно числовое значение g . Затем для определения выхода формального нейрона в блоке нелинейного преобразования (реализующего передаточную функцию) g сравнивается с некоторым числом (порогом). Если сумма больше значения порога, формальный нейрон генерирует сигнал, в противном случае сигнал будет нулевым или тормозящим. Применяемое здесь нелинейное преобразование:

$$\text{sign}(g) = \begin{cases} 0, & g < 0 \\ 1, & g \geq 0 \end{cases}, \text{ где } g = \sum_{i=0}^N a_i x_i. \quad (2)$$

Нейросетевой алгоритм решения конкретной задачи есть вычислительная процедура, полностью или по большей части реализованная в виде НС той или иной структуры (например, многослойной НС с последовательными или перекрестными связями между слоями формальных нейронов) с соответствующим алгоритмом настройки весовых коэффициентов. Основой разработки нейросетевого алгоритма является представление процесса решения задачи как функционирование во времени некоторой динамической системы. Для ее построения необходимо определить: объект, выступающий в роли входного сигнала НС; объект, выступающий в роли выходного сигнала НС (например, непосредственно решение или некоторая его характеристика); желаемый (требуемый) выходной сигнал; структуру НС (число слоев, связи между слоями, объекты, служащие весовыми коэффициентами); функцию ошибки

системы (характеризующую отклонение желаемого выходного сигнала от реального); критерий качества системы и функционал ее оптимизации, зависящий от ошибки; значение весовых коэффициентов (например, определяемых аналитически непосредственно из постановки задачи, с помощью некоторых численных методов или процедуры настройки).

Для выбранной структуры НС, отвечающей определенной задаче, необходимо найти оптимальные значения всех весовых коэффициентов a_i . Эта процедура называется обучением НС, от нее существенно зависит способность НС во время эксплуатации решать поставленные перед ней задачи. Важнейшими параметрами обучения являются: качество подбора весовых коэффициентов и время, которое необходимо затратить на обучение. Отметим, что главный вопрос – как выбрать структуру многослойной НС для решения выбранной конкретной задачи – до сих пор в значительной степени не решен.

1.2. Теория свидетельств

Теория свидетельств (ТС) или теория Демпстера-Шафера [12-14] является общей основой для рассуждений с неопределенностью и позволяет объединить свидетельства из разных источников и прийти к определенной степени уверенности в наличии того или иного события.

Рассмотрим кратко концептуальные основы и базовые положения ТС. Пусть имеется множество *объектов* и всех возможных *свойств*, которыми они могут обладать. Необходимо по известному набору признаков определить объекты, обладающие заданными свойствами. Наличие заданного свойства у объекта или некоторого множества объектов будем считать *событием*. Основная идея ТС заключается в том, что некоторая мера вероятности может быть отнесена не только к отдельным событиям, но и к некоторому подмножеству событий, включая их полное множество. Распределение этой частичной меры вероятности по подмножествам событий неизвестно; также могут быть неизвестны меры вероятности, относящиеся к элементам множества событий. Закрепление меры вероятности за событиями может происходить по следующим причинам. Во-первых, из-за неоднозначности решения задачи экспертной классификации, когда эксперт не может точно определить степень характерности

признака для одного, отдельно взятого объекта. Во-вторых, в случае неточности результатов определения самого признака. В-третьих, при назначении общего уровня доверия для всех признаков.

Степень уверенности в наличии заданного свойства у объектов выражается *функцией доверия*:

$$Bel(A_i) = \sum_{A_j \subseteq A_i} m(A_j), \quad (3)$$

где A_i – событие, соответствующее наличию заданного свойства у объекта или некоторого множества объектов; $A_j \subseteq C$; C – показательное множество событий, которое является результатом решения задачи; $m(A_j)$ – мера доверия к событию $A_j \subseteq A_i$ (иногда называется массой A_j), которая выражает соотношение всех доступных субъективных свидетельств, поддерживающих утверждение, что имеет место событие A_j , но не создает никаких дополнительных утверждений о других подмножествах множества C ; $m(A_j) \in [0, 1]$. $Bel(A_i)$ обладает следующими свойствами: $Bel(\emptyset) = 0$, $Bel(A_i) \in [0, 1]$ и $Bel(C) = 1$.

Степень правдоподобия наличия заданного свойства у объектов выражается *функцией правдоподобия*:

$$Pl(A_i) = 1 - Bel(\bar{A}_i) = 1 - \sum_{A_j \cap A_i = \emptyset} m(A_j) \quad (4)$$

По аналогии с теорией вероятности величины $Bel(A_i)$ и $Pl(A_i)$ можно рассматривать как нижнюю и верхнюю границы вероятности наличия заданного свойства объектов, принадлежащих подмножеству $A_j \subseteq C$, предполагая существование некоторой истинной вероятности $p(A_i)$:

$$Bel(A_i) \leq p(A_i) \leq Pl(A_i). \quad (5)$$

Переход от точечных вероятностей к интервальным позволяет получить прямую количественную оценку неопределенности результатов расчета меры доверия и характеризовать ее параметрическую чувствительность.

В соответствии с *правилом Демпстера* объединение различных свидетельств (событий)

с распределениями вероятностей m_1 и m_2 выполняется следующим образом:

$$m(C_N) = \frac{1}{1 - m(\emptyset)} \sum_{A_i \cap A_j \neq \emptyset} m_1(A_i) m_2(A_j), \quad (6)$$

где $m(C_N)$ – функция объединения событий A_i и A_j , соответствующих наличию у объекта свойств C_N ; $m(\emptyset) = \sum_{A_i \cap A_j = \emptyset} m_1(A_i) m_2(A_j)$.

Правило Демпстера ассоциативно и коммутативно, что позволяет объединять аналогичным образом и большее число свидетельств.

Решение, найденное с помощью ТС, представляет собой полную группу событий, что, с одной стороны, позволяет лучше оценить реальную обстановку, с другой стороны, дает возможность дальнейшего уточнения решения задачи при появлении дополнительных признаков.

2. Особенности совместного использования нейронных сетей и алгоритмов теории свидетельств

2.1. Краткий обзор

При анализе публикаций рассматривались основные результаты, которые, по-видимому, формируют тренды совместного применения НС и ТС. Работы, включенные в перечень анализируемых источников, в основном, представляют собой примеры направлений исследований и прикладных разработок с авторской оценкой полученных результатов. Более полную информацию для каждого рассмотренного приложения НС и ТС можно найти в текстах материалов, включенных в список использованных публикаций.

Проведенный анализ источников позволил выделить следующие основные направления исследований по рассматриваемой тематике:

1. Использование ТС при подготовке данных для создания и настройки НС. Суть этого подхода такова. Данные, полученные из нескольких источников, объединяются с помощью алгоритмов комбинирования свидетельств ТС. Затем эти объединенные данные подаются на вход НС для извлечения характеристик, требуемых для решения конкретной задачи.

Этот подход используется как для обучения НС, так и для ее использования в рабочем режи-

ме. Применяется, например, в диагностике и системах автономного управления транспортными средствами. Более детальное описание указанного направления исследований дано ниже.

2. Использование НС при подготовке исходных данных для ТС. Здесь НС используется для генерации данных, представляющих базовое распределение вероятностей (или первоначальные меры доверия для элементов показательного множества). Это распределение субъективных вероятностей является ключевым элементом в работе основных алгоритмов ТС: вычисление значений функций доверия и правдоподобия, а также слияние данных, полученных от нескольких источников. В данном случае результат работы НС служит альтернативой экспертным оценкам.

Этот подход применяется, как правило, при разработке различных классификаторов, а также в прогнозирующих системах. Более детальное описание указанного направления исследований дано ниже.

3. Объединение результатов работы НС и других методов машинного обучения с помощью методов ТС. Идея подхода заключается в следующем. Решение конкретной задачи (например, диагностика неисправностей в устройстве или классификация объектов) осуществляется различными методами или различными вариациями одного метода (например, разнотипными НС или НС и каким-либо алгоритмом нечеткого вывода). В предположении, что каждый из используемых методов имеет свои ограничения, выполняется взаимодополняющее слияние результатов используемых методов. При этом предполагается получить улучшенные характеристики точности и надежности принимаемых решений.

Подход является достаточно универсальным и применяется в различных системах принятия решений. Более детальное описание указанного направления исследований дано ниже.

2.2. Примеры использования алгоритмов теории свидетельств при подготовке данных для создания и настройки нейронных сетей

В [15] предлагается метод диагностики неисправностей подшипников, использующихся в ротационных машинах. Авторы отмечают широкое применение в диагностических процеду-

рах алгоритмов глубокого обучения, благодаря возможности с их помощью автоматически извлекать признаки неисправностей из сигналов, поступающих от датчиков. Однако разработка модели глубокого обучения для решения проблем диагностики неисправностей не является тривиальной задачей, поскольку каждая модель потенциально имеет сложную структуру, большое количество диагностических переменных для обучения, а также заданные ненастраиваемые параметры (гиперпараметры). Выбор гиперпараметров, которые могут оказывать большое влияние на производительность, часто осуществляется вручную на основе метода проб и ошибок и опыта конструктора. В статье предложен метод трансфертного обучения, при котором в технологию диагностики вовлекаются уже разработанные модели. Так, в рассматриваемом случае измерения, полученные от нескольких вибродатчиков, объединяются алгоритмами комбинирования ТС. Предварительно обученная в области классификации изображений глубокая НС модифицируется для извлечения диагностических характеристик из сигналов датчиков. Приводятся сведения об эффективности предложенного метода, полученные в экспериментах с фактическим набором данных.

В [16] рассмотрена сложная задача поиска эффективной стратегии обнаружения объектов в трехмерной подводной среде с помощью нескольких автономных подводных аппаратов (АПА). ТС применяется при извлечении информации об окружающей среде из нечетких данных сонара и дальнейшего построения карты подводной среды с координатной сеткой. Далее на основе этой карты строится топологическая нейродинамическая модель, которая представляет динамику среды. При этом целевой объект играет роль аттрактора, определяемого через динамический ландшафт нейронной активности модели; одновременно определяются препятствия для предотвращения столкновений. Маршрут АПА к целевому объекту формируется автономно по правилу наискорейшего градиентного спуска. Предлагаемый алгоритм работает в ситуациях статических и динамических целевых объектов, а также в случае выхода из строя одного или нескольких АПА. Результаты моделирования, представленные авторами, показывают, что предложенный алгоритм способен управлять

несколькими АПА для решения задачи обнаружения целевых объектов с более высокой эффективностью и адаптируемостью по сравнению с другими алгоритмами.

Похожий подход использован в [17,18] для решения задачи безопасного планирования траектории автономного движения в городских условиях с динамическими препятствиями, такими как пешеходы, велосипедисты и др. Надежное предсказание состояния этой быстро меняющейся среды, поведения ее агентов, позволило бы алгоритмам планирования движения активно генерировать траекторию. В рассматриваемых работах представлена реализация метода такого предсказания путем построения модели движения по данным сетки занятости с использованием сверточной НС (СНС). Входными данными для СНС является набор так называемых «вероятностных сеток восприятия», сгенерированных базовым алгоритмом слияния информации ТС. Входными данными для базового алгоритма ТС являются показатели лидарных датчиков, карта с координатной сеткой геоинформационной системы и вероятностные сетки занятости, выведенные базовым алгоритмом ТС на предыдущих временных шагах. ТС может комбинировать частично неопределенную информацию датчиков с информацией о конкретных областях, полученной с цифровой карты. Это позволяет определить ячейки сетки, содержащие потенциальные помехи (статические и динамические), и ячейки, которые доступны для навигации. В итоге СНС выводит сетку восприятия для текущего временного шага, что позволяет системе предвидеть области, в которых могут возникнуть скрытые опасности. Авторы показывают на проверочном наборе данных KITTI более высокую точность и лучшую прогностическую способность предлагаемого метода в сравнении с базовыми подходами.

Также в этом направлении имеются исследования и разработки в областях контроля работы сельскохозяйственных теплиц [19], диагностики неисправностей оборудования [20] и др.

2.3. Примеры использования нейронных сетей при подготовке исходных данных для алгоритмов теории свидетельств

В статье [21] автор рассматривает группу классификаторов, основанную на использова-

нии логистической регрессии и ее нелинейных обобщениях: многослойной НС прямой связи, обобщенной аддитивной модели, машины опорных векторов. Показано, что вероятности выходных классов целесообразно нормализовать вероятностями в соответствии с некоторыми базовыми массовыми функциями ТС. Это обеспечивает более информативное описание выходных данных классификатора, которое может быть использовано для принятия решений. Кроме того, индивидуальные массовые функции дают представление о внутренней работе классификатора и могут помочь интерпретировать его решения. Автор заключает, что ТС является гораздо более общей основой для анализа и построения классификаторов, чем считалось изначально, и открывает новые перспективы для изучения и практического применения широкого спектра алгоритмов машинного обучения.

Примером такого подхода является случай совместного использования НС и ТС при расчете базовой вероятности в предложенном в [22] методе обнаружения DDoS-атак¹.

Этот метод реализован с применением НС при организации нечеткого вывода в соответствии с ТС. Одной из фундаментальных концепций ТС является базовое распределение вероятностей или субъективных предположений, касающихся фактического состояния некоторой системы. Значение базового распределения вероятностей (БРВ) различных атак формируется с помощью НС, а окончательный результат – с помощью ТС. Правила комбинации распределений вероятностей БРВ корректируются с помощью нечеткого взвешивания масс фокальных элементов, чтобы избежать необоснованного результата слияния при серьезном или полном конфликте между различными источниками. Тем самым уменьшается ошибка метода слияния данных. В статье приводятся подтверждения экспериментальными данными точности при обнаружении распространенных типов DDoS-атак.

В исследовании [23] предлагается новый классификатор, основанный на использовании ТС и глубокой СНС для многофакторной классификации объектов. В этом классификаторе

¹ Атака злоумышленников на вычислительную систему, приводящая к отказу в обслуживании запросов (DDoS – *Distributed Denial of Service*).

² Метод классификации документов, где частота вхожде-

СНС используется для извлечения объектов верхнего уровня из необработанных данных. Затем объекты импортируются в слой ТС для построения базовых распределений вероятностей или масс. Эти распределения далее передаются в классификатор функций доверия, в котором они преобразуются, агрегируются по правилу Демпстера и классифицируются. В работе предлагается сквозная стратегия обучения СНС с одновременной настройкой параметров СНС и классификатора функций доверия, а также определением потерь при отклонении для правил ТС. Эксперименты со стандартными проверочными наборами данных показывают, что гибридизация классификатора функций доверия с СНС, позволяют снизить частоту ошибок за счет отбраковки тех шаблонов, которые были бы неправильно классифицированы.

Процедура распознавания действий объектов на видеокдрах низкого разрешения представлена в [24]. Предложенный подход предусматривает обучение НС с использованием отдельных видеокдрах, которые предполагаются независимыми. Далее вычисляется базовое распределение вероятностей действий на каждом видеокдрах и по правилу Демпстера осуществляется их объединение для принятия окончательного решения с использованием пороговых значений. Экспериментальные оценки этого метода, проведенные на тестовых данных большого объема с различными уровнями разрешения видео, продемонстрировали лучшие характеристики распознавания по сравнению с классификациями методами сопоставления последовательностей, голосования и BoW².

Прогнозирование выбросов газа в угольных шахтах, как эффективного метода предотвращения катастроф, рассматривается в [25]. Особенности выбросов газа являются внезапность, неравномерность, неопределенность и сложная динамика. Модель прогнозирования, описанная в статье, содержит набор показателей оценки выброса газа, блок нечеткой НС и блок ТС, объединенные в единую систему. Предварительная оценка состояния выброса газа в локальной точке забоя выполняется нечеткой НС, а затем делается глобальная оценка состояния выброса газа в забое на основе ТС.

² Метод классификации документов, где частота вхождения слова в документе используется как признак для обучения классификатора (BoW – *Bag of Words* (мешок слов)).

Результаты моделирования показывают, что этот метод может дать очень точные прогнозы выброса газа.

2.4. Примеры объединения алгоритмами теории свидетельств результатов работы нейронных сетей и других методов машинного обучения

Авторы [26,27] представляют инструмент для онлайн-мониторинга распределительных устройств с элегазовой изоляцией и диагностики существующих дефектов. Отмечается, что в настоящее время существует два различных типа шаблонов данных, используемых для такого анализа и оценки: режим частичного разряда с разрешением по фазе (PRPD – *Phase-Resolved Partial Discharges*) и режим частичного разряда с разрешением по времени (TRPD – *Time-Resolved Partial Discharges*). Их использование по отдельности может привести к противоречивым результатам распознавания, но эти два типа шаблонов данных, имеющих дополнительную информацию друг о друге, могут использоваться вместе для слияния данных с помощью ТС. В предлагаемом подходе сначала частичные разряды распознаются с использованием алгоритма обучения НС отдельно в двух режимах. Далее, производится слияние результатов и принимается окончательное решение. Результаты обширных экспериментов с двумя искусственными дефектами показывают, что предложенный метод значительно превосходит способы использования только одного типа шаблонов данных.

В статье [28] описывается применение методов интеллектуального анализа данных для выявления гепатита путем анализа отчетов о медицинской проверке функций печени. Для классификации состояний печени и использованы две искусственных НС и четыре классификатора SVM. На следующем шаге осуществлялось слияние результатов классификации двумя способами: с помощью шаблона решения и ТС. Результаты показывают, что объединенный множественный классификатор дал лучшую точность диагностики по сравнению с любым одиночным классификатором.

Гибридная методика диагностики неисправностей в сложной технической системе описана в [29]. Для обработки вибросигналов от обороту-

дования используется алгоритм декомпозиции вейвлет-пакетов и сокращения грубых наборов для извлечения вектора признаков сигнала и преобразования этого вектора в таблицу принятия решений. Для других сигналов (например, температуры или давления) данные каждого датчика объединяются для формирования вектора признаков, а НС, оптимизированная генетическим алгоритмом, используется для обучения и распознавания образов. Объединение результатов диагностики двух типов сигналов осуществляется методами ТС. Эта составная модель диагностики неисправностей, реализованная в среде Matlab, отличается высокой диагностической достоверностью и точностью.

Похожий подход описан в [30], где представлен новый метод диагностики неисправностей подшипников с использованием слияния данных трех вибродатчиков, основанный на ТС в сочетании с генетическим алгоритмом. Полученные от датчиков векторы признаков передаются в НС для классификации неисправностей. Выходом нейросети являются нормализованные распределения вероятностей, которые и являются входом для алгоритма слияния ТС.

Высокоскоростной железнодорожный стрелочный перевод является важным сигнальным оборудованием, которое напрямую контактирует с поездом. Чтобы реализовать интеллектуальный подход к методу диагностики неисправностей в системе управления стрелками, в статье [31] обобщены 11 типичных режимов неисправностей и 8 соответствующих их типовых характеристик. Диагностика неисправностей осуществляется с помощью многофакторной нечеткой оценки и трехуровневой модели НС. Отмечается, что оба метода не могут удовлетворительно решить проблему ложных срабатываний и ложных отрицаний неисправностей, что угрожает безопасности железнодорожных операций. Поэтому, основываясь на ТС, в статье предлагается комплексная оценка неисправностей на уровне принятия решений, которая основана на взаимодополняющем слиянии результатов двух методов диагностики.

В материалах [32,33] описана вычислительная система для классификации различных процедур, используемых слепыми людьми во время тактильного изучения изображений. Подход авторов состоит в следующем. Из тра-

екторий движений извлекаются признаки, инвариантные к сдвигу, вращению и масштабу. Эти признаки определяются как числовые и логические функции и используются при обучении НС с пиковыми сигналами для дальнейшего кодирования числовых характеристик модели. После этого с помощью специализированной схемы осуществляется классификация процедур изучения и понимания изображения. ТС была применена для интегрирования данных, полученных для всех процедур. Эксперименты по информации авторов показали хорошую эффективность предложенного метода по сравнению с алгоритмом DTW и скрытой марковской моделью.

В статье [34] описывается система мониторинга уровня воды в реках, повышение которого вызвано последствиями землетрясений (например, оползней). Для глубокого обучения СНС были подготовлены шесть наборов данных, включающих оптические и топографические данные, полученные от соответствующих датчиков. Модель ТС применялась для объединения результатов каждой НС, обученной отдельным набором данных. Результаты объединения шести результирующих карт сравнивались с эталонной топографической картой. При этом подтверждено, что использование обучающего набора спектральных и топографических данных помогает выделить оползневые пласты от других подобных объектов (таких как бесплодные земли), и таким образом повышает точность картирования.

Отметим патент [35], относящийся к области нефтяной и газовой промышленности, а именно к системам мониторинга строительства нефтегазовых скважин и управления буровыми операциями, и предназначено для выявления и прогнозирования основных типов осложнений, таких как поглощение буровой промывочной жидкости или прихваты (затяжки) бурового инструмента. Представлена система диагностики осложнений типа «поглощение» на основе технологии объединения НС, которая включает НС с обратным распространением ошибки, сеть радиально-базисных функций, самоорганизующуюся карту Кохонена, НС адаптивного резонанса. В качестве основного метода объединения нейросетевых предсказаний и получения итогового прогноза рекомендована ТС, но не исключаются и другие методы: наименьших

квадратов, мажоритарного голосования, нечетких интегралов.

Другие примеры областей применения исследований в этом направлении: диагностика качества воды [36], прогнозирование трафика данных в специализированных системах [37], диагностика кибератак [38], в том числе в IoT [39], защита автомобильных самоорганизующихся сетей от несанкционированных воздействий [40,41], системы позиционирования [42], идентификация транспортных средств по видеоряду [43], управление угольным комбайном [44].

3. Выводы

Ниже приведены некоторые комментарии к результатам данного исследования и сформулированы основные выводы.

1. Выделены и проиллюстрированы три основных направления исследований и разработок, касающихся совместного использования методов НС и теории свидетельств. Показаны соответствующие архитектурные решения диагностических систем.

2. Приведенные сведения об использовании ТС при подготовке данных для создания и настройки НС позволяют выделить следующие важные аспекты:

- в целом применяемые методики помогают сэкономить время и другие ресурсы, требующиеся при проектировании и обучении применяемых моделей, особенно это касается глубоких НС;

- НС, построенные на обучающих наборах, подготовленных с помощью алгоритмов ТС, могут обладать более высокой адаптируемостью по сравнению с другими алгоритмами при сохранении высокой точности результатов (например, в диагностических системах);

- НС, построенные на обучающих наборах, подготовленных с помощью алгоритмов ТС, могут демонстрировать более высокую прогнозную способность (например, в системах автономного управления транспортными средствами).

3. Приведенные сведения об использовании НС при подготовке исходных данных для алгоритмов ТС при разработке различных классификаторов, а также в прогнозирующих системах позволяют отметить:

- повышенную точность классификации исследуемых объектов (процессов), снижение частоты ошибок классификации за счет использования в алгоритмах ТС более детальных классификационных шаблонов, подготовленных при работе НС;

- сохранение достаточно высокой производительности при решении задач классификации;

- потенциальное снижение субъективности при первоначальном определении масс групповых событий, характеризующих классификационные шаблоны.

4. Приведенные сведения об объединении алгоритмами ТС результатов работы НС и других методов машинного обучения позволяют сделать вывод о том, что данный подход:

- является достаточно универсальным и довольно широко применяется в различных системах принятия решений;

- в целом снижает неопределенность результатов работы алгоритмов машинного обучения за счет совместной обработки данных от нескольких источников различными методами;

- повышает достоверность результатов работы алгоритмов машинного обучения по тем же причинам;

- в определенном смысле предотвращает последствия выбора неоптимальной структуры НС за счет потенциальной компенсации неадекватных результатов более точными, полученными от других методов.

Заключение

В работе определены варианты совместного применения НС и алгоритмов ТС в разработанных и успешно функционирующих гибридных нечетких системах. Выявлен достаточно широкий круг типов таких систем, отличающихся высокой степенью неопределенности параметров функционирования. К их числу относятся системы диагностики неисправностей оборудования в машиностроении и на транспорте, управления автономными аппаратами в различных динамически средах, универсальной классификации сложных объектов (таких как изображения), прогнозирования аномальных явлений в производственной среде, медицинской диагностики, мониторинга окружающей среды и прогнозирования природных и техногенных катастроф.

Получены подтверждения эффективности совместного применения указанных методов в части уменьшения уровня неопределенности и увеличения его доверия к данным, используемым для принятия решений. Представленные архитектурные решения служат примерами практик использования методов ТС при подготовке данных для создания и настройки НС, использования НС при подготовке исходных сведений для методов ТС, объединение результатов работы НС и других методов машинного обучения с помощью методов ТС.

Результаты настоящего исследования являются частью базиса для разработки эффективной методологии и архитектуры гибридной экспертной системы для диагностики состояния технологических процессов.

Литература

1. Wang J., Jing X., Yan Z. et al. 2020. A Survey on Trust Evaluation Based on Machine Learning. *ACM Computing Surveys*. 53(5)1–36.
2. Granatyr J., Botelho V., Lessing O.R. et al. 2015. Trust and Reputation Models for Multiagent Systems. *ACM Computing Surveys*. 48(2):1–42.
3. Zhu Y. and Yan Z. 2016. A Survey on Trust Evaluation in e-Commerce. 9th EAI International Conference on Mobile Multimedia Communications (MobiMedia). Brussels. 130–139.
4. Bansal H., Kohli S. 2019. Trust Evaluation of Websites: A Comprehensive Study. *International Journal of Advanced Intelligence Paradigms*. 13(1–2):101–112.
5. Palyukh B.V., Ivanov V.K., Sotnikov A.N. 2019. Evidence Theory for Complex Engineering System Analyses. *Advances in Intelligent Systems and Computing*. 874: 70–79.
6. Иванов В.К., Виноградова Н.В., Палюх Б.В., Сотников А.Н. 2018. Современные направления развития и области приложения теории Демпстера-Шафера // Искусственный интеллект и принятие решений. 2018. №4. С.32-42.
7. Bronevich, A., Lepskiy, A., Penikas, H. 2015. The application of conflict measure to estimating incoherence of analyst's forecasts about the cost of shares of Russian companies // *Procedia Computer Science*. 55:1113–1122.
8. Еремеев А.П., Хазиев Р.Р., Зуева М.В., Цапенко И.В. Прототип диагностической системы поддержки принятия решений на основе интеграции байесовских сетей доверия и метода Демпстера-Шафера // Программные продукты и системы. 2013. №1. С.11-16.
9. Utkin V., Kaberova A., Solovyev S. 2016. Reliability Analysis of Soil Bases According to the Deformation Criterion. *International Journal for Computational Civil and Structural Engineering* 12(4):18-26.
10. Lepskiy A., Suevalov A. 2019. Application of the belief function theory to the development of trading strategies. *Procedia Computer Science*. 162:235–242.
11. Галушкин А.И. Нейронные сети. Большая российская энциклопедия. Электронная версия. URL: https://bigenc.ru/technology_and_technique/text/4114009 (дата обращения: 26.07.2021).
12. Dempster, Arthur P. 1968. A generalization of Bayesian inference. *Journal of the Royal Statistical Society, Series B*. 30:205–247.
13. Shafer G. 1976 *A Mathematical Theory of Evidence*. Princeton University Press. 314 p.
14. Yager R., Liping L. 2010 *Classic Works of the Dempster-Shafer Theory of Belief Functions*. London: Springer. 825 p.
15. Hoang D.T., Kang K.J. 2019. A Bearing Fault Diagnosis Method Using Transfer Learning and Dempster-Shafer Evidence Theory. *International Conference on Artificial Intelligence, Robotics and Control (AIRC)*. Cairo. 33–38. doi:10.1145/3388218.3388220.
16. Cao X., Zhu D. and Yang S.X. 2016. Multi-AUV Target Search Based on Bioinspired Neurodynamics Model in 3-D Underwater Environments. *IEEE Transactions on Neural Networks and Learning Systems*. 27(11):2364–2374.
16. Itkina M., Driggs-Campbell K., and Kochenderfer M.J. 2019. Dynamic Environment Prediction in Urban Scenes using Recurrent Representation Learning. *IEEE Intelligent Transportation Systems Conference (ITSC)*. Rhodes. 2052–2059.
18. Kochenderfer M.J., Mikhal M. 2017. Convolutional Neural Network Information Fusion Based on Dempster-Shafer Theory for Urban Scene Understanding. Technical Report, Stanford University. Stanford. 4321–4328. Available at: <http://cs231n.stanford.edu/reports/2017/pdfs/632.pdf> (accessed July 27, 2021).
19. Farias C. M. de, Pirmez L., Delicato F.C. et al. 2017. GROWN: A Control and Decision System for Smart Greenhouses Using Wireless Sensor Networks. *Australasian Computer Science Week Multiconference*. Geelong. (48): 1–8.
20. Zhang Z., Jiang W., Geng J., Deng X., and Li X. 2020. Fault Diagnosis Based on Non-Negative Sparse Constrained Deep Neural Networks and Dempster-Shafer Theory. *IEEE Access*. 8:18182–18195.
21. Denœux Th. 2019. Logistic Regression, Neural Networks and Dempster-Shafer Theory: A New Perspective. *Knowledge-Based Systems*. 176:54–67.
22. Chen K., Gu L., Sun J. 2020. A DoS Attack Detection Method Based on Multi-Source Data Fusion. *4th International Conference on Computer Science and Application Engineering (CSAE)*. Sanya. (116):1–8.
23. Tong Z., Xu P., Denœux, T. 2019. ConvNet and Dempster-Shafer Theory for Object Recognition. *Procs of the 13th International Conference on Scalable Uncertainty Management*. Springer International Publishing, Cham, France. 368–381. Available at: https://link.springer.com/chapter/10.1007/978-3-030-35514-2_27 (accessed July 27, 2021).
24. Gao Z., Lu G., and Yan P. 2016. Enhancing Action Recognition in Low-Resolution Videos Using Dempster-Shafer's Model. *IEEE International Conference on Digital Signal Processing (DSP)*. Beijing. 676–680.
25. Gao C., Wang F., Xu D. 2017. Gas Outburst Prediction Based on the Intelligent Dempster-Shafer Evidence Theo-

- ry. 9th International Conference on Modelling, Identification and Control (ICMIC). Kunming. 897–901.
26. Li L., Tang J., and Liu Y. 2015. Partial Discharge Recognition in Gas Insulated Switchgear Based on Multi-Information Fusion. *IEEE Transactions on Dielectrics and Electrical Insulation*. 22(2): 1080–1087.
 27. Wang, Y., Yan, J., Yang, Z. et al. 2019. Partial Discharge Pattern Recognition of Gas-Insulated Switchgear via a Light-Scale Convolutional Neural Network. *Energies*. 12(24):4674.
 28. Saha S., Saha S. and Bhattacharyya P. P. 2015. Classifier Fusion for Liver Function Test Based Indian Jaundice Classification. *International Conference on Man and Machine Interfacing (MAMI)*. Bhubaneswar. 1–6.
 29. Chen Y., Yang Y., Li J. et al. 2016. Intelligent Fault Diagnosis Technology Based on Hybrid Algorithm. *Chinese Control and Decision Conference (CCDC)*. Yinchuan. 3702–3706.
 30. Huo Z., Zhang Y., Shu L. et al. 2018. Bearing Fault Diagnosis Using Multi-Sensor Fusion Based on Weighted D-S Evidence Theory. *18th International Conference on Mechatronics – Mechatronika (ME)*. Brno. 1–6. Available at: <https://ieeexplore.ieee.org/document/8624681> (accessed July 27, 2021).
 31. Liu M., Yan X., Sun X. et al. 2016. Fault Diagnosis Method for Railway Turnout Control Circuit Based on Information Fusion. *IEEE Information Technology, Networking, Electronic and Automation Control Conference*. Chongqing. 315–320.
 32. Zhang T., Zhou T., Duerstock B.S., and Wachs J.P. 2018. Image Exploration Procedure Classification with Spike-timing Neural Network for the Blind. *24th International Conference on Pattern Recognition (ICPR)*. Beijing. 3256–3261.
 33. Zhang T., Duerstock B.S., and Wachs J.P. 2020. Classification of Blind Users' Image Exploratory Behaviors Using Spiking Neural Networks. *IEEE Trans. on Neural Systems and Rehabilitation Engineering*. 28(4):1032–1041.
 34. Ghorbanzadeh O., Meena S.R., Shahabi H. et al. 2021. Landslide Mapping Using Two Main Deep-Learning Convolution Neural Network Streams Combined by the Dempster–Shafer Model. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 14:452–463.
 35. Jian L., Liyan L., Jiadi L. et al. 2017. Drilling well leakage type diagnostic method based on neural network fusion technology. Patent CN 104121014 B. Available at: <https://patents.google.com/patent/CN104121014B/en> (accessed July 27, 2021).
 36. Ladjali M., Bouamar M., Djerioui M., and Brik Y. 2016. Performance Evaluation of ANN and SVM Multiclass Models for Intelligent Water Quality Classification Using Dempster-Shafer Theory. *International Conference on Electrical and Information Technologies (ICEIT)*. Tangier. 191–196.
 37. Soua R., Koesdwiady A., and Karray F. 2016. Big-Data-Generated Traffic Flow Prediction Using Deep Learning and Dempster-Shafer Theory. *International Joint Conference on Neural Networks (IJCNN)*. Vancouver. 3195–3202.
 38. Dallali A., Omrani T., and Rhaimi B.C. 2018. Evidence Theory Data Fusion-Based Method for Cyber-Attack Detection. *4th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP)*. Sousse. 1–4.
 39. Enăchescu C., Sándor H. and Genge B. 2019. A Multi-Model-based Approach to Detect Cyber Stealth Attacks in Industrial Internet of Things. *International Conference on Software, Telecommunications and Computer Networks (SoftCOM)*. Split. 1–6.
 40. Kushwah N. and Sonker A. 2016. Malicious Node Detection on Vehicular Ad-Hoc Network Using Dempster Shafer Theory for Denial of Services Attack. *8th International Conference on Computational Intelligence and Communication Networks (CICN)*. Tehri. 432–436.
 41. Zhang C., Chen K., Zeng X., and Xue X. 2018. Misbehavior Detection Based on Support Vector Machine and Dempster-Shafer Theory of Evidence in VANETs. *IEEE Access*. 6:59860–59870.
 42. Zou J., Guo X., Li L. et al. 2018. Deep Regression Model for Received Signal Strength based WiFi Localization. *IEEE 23rd International Conference on Digital Signal Processing (DSP)*. Shanghai. 1–4.
 43. Li J., Dong S., Yu Z. et al. 2019. Event-Based Vision Enhanced: A Joint Detection Framework in Autonomous Driving. *IEEE International Conference on Multimedia and Expo (ICME)*. Shanghai. 1396–1401.
 44. Si L., Wang Z., and Jiang G. Fusion Recognition of Shearer Coal-Rock Cutting State Based on Improved RBF Neural Network and D-S Evidence Theory. 2019. *IEEE Access*. 7:122106–122121.

Палюх Борис Васильевич. Тверской государственный технический университет. Заведующий кафедрой «Информационные системы». Доктор технических наук, профессор. Область научных интересов: системы управления, искусственный интеллект, создание и поддержка экспертных систем, эволюционное проектирование. E-mail: pboris@tstu.tver.ru

Иванов Владимир Константинович. Тверской государственный технический университет. Доцент кафедры «Информационные системы». Кандидат технических наук. Область научных интересов: информационные технологии, хранения данных, принятие решений, интеллектуальный анализ данных. E-mail: mtivk@mail.ru

Joint Use Neural Networks and Evidence Theory Methods in Control and Diagnostic Fuzzy Systems

V. K. Ivanov, B. V. Palyukh

Tver State Technical University, Tver, Russia

Abstract. The article describes the study results of various intelligent data processing methods, such as neural networks and algorithms of the theory of evidence, joint use. The study was conducted on the development of diagnostic systems examples. These methods hybridization is one of the general approaches to reduce uncertainty in the data used and increase the degree of confidence in them. The data uncertainty is of an objective nature when they are obtained from the sensors of technological equipment, from technical regulations, as well as from expert specialists. The study includes an analysis of modern developments descriptions presented at significant international conferences and published recently. Several dozen descriptions of the systems composition, structure and main algorithms functioning developed for projects in various fields were reviewed. As a result, the joint application modes of neural networks and theory of evidence algorithms including the features of architectures and their implementation are determined. We also summarized information about the effectiveness of these methods' joint application in terms of the uncertainty level reducing and confidence level increasing in the decision-making data. The scope of this study results application is the architectural solutions design of a hybrid expert system for diagnosing the technology processes state and detecting anomalies in them.

Keywords: neural network, Dempster-Schafer evidence theory, hybrid expert system, diagnostics, manufacturing process, fuzzy system, network training, belief function.

DOI

References

1. Wang J., Jing X., Yan Z. et al. 2020 A Survey on Trust Evaluation Based on Machine Learning. *ACM Computing Surveys*. 53(5)1–36. doi:10.1145/3408292.
2. Granatyr J., Botelho V., Lessing O.R. et al. 2015. Trust and Reputation Models for Multiagent Systems. *ACM Computing Surveys*. 48(2):1–42. doi:10.1145/2816826.
3. Zhu Y. and Yan Z. 2016. A Survey on Trust Evaluation in e-Commerce. 9th EAI International Conference on Mobile Multimedia Communications (MobiMedia). Brussels. 130–139. doi:10.5555/3021385.3021411.
4. Bansal H., Kohli S. 2019. Trust Evaluation of Websites: A Comprehensive Study. *International Journal of Advanced Intelligence Paradigms*. 13(1–2):101–112. doi:10.1504/IJAIP.2019.099946.
5. Palyukh B.V., Ivanov V.K., Sotnikov A.N. 2019. Evidence Theory for Complex Engineering System Analyses. *Advances in Intelligent Systems and Computing*. 874: 70–79.
6. Иванов В.К., Виноградова Н.В., Палюх Б.В., Сотников А.Н. 2018. Современные направления развития и области приложения теории Демпстера-Шафера (обзор). *Искусственный интеллект и принятие решений*. Москва. 2018. 4:32–42. doi:10.14357/20718594180403.
7. Bronevich, A., Lepskiy, A., Penikas, H. 2015. The application of conflict measure to estimating incoherence of analyst's forecasts about the cost of shares of Russian companies // *Procedia Computer Science*. 55:1113–1122.
8. Еремеев А.П., Хазиев Р.Р., Зуева М.В., Цапенко И.В. 2013. Прототип диагностической системы поддержки принятия решений на основе интеграции байесовских сетей доверия и метода Демпстера-Шафера. *Программные продукты и системы*. 1:11–16.
9. Utkin V., Kaberova A., Solovyev S. 2016. Reliability Analysis of Soil Bases According to the Deformation Criterion. *International Journal for Computational Civil and Structural Engineering* 12(4):18–26. doi:10.22337/1524-5845-2016-12-4-18-26.
10. Lepskiy A., Suevalov A. 2019. Application of the belief function theory to the development of trading strategies. *Procedia Computer Science*. 162:235–242.
11. Galushkin A.I. *Нейронные сети*. Большая российская энциклопедия. *Elektronnaya versiya*. URL: https://bigenc.ru/technology_and_technique/text/4114009 (data obrashcheniya 26 07 2021).
12. Dempster, Arthur P. 1968. A generalization of Bayesian inference. *Journal of the Royal Statistical Society, Series B*. 30:205–247.
13. Shafer G. 1976 *A Mathematical Theory of Evidence*. Princeton University Press. 314 p.
14. Yager R., Liping L. 2010 *Classic Works of the Dempster-Shafer Theory of Belief Functions*. London: Springer. 825 p.
15. Hoang D.T., Kang K.J. 2019. A Bearing Fault Diagnosis Method Using Transfer Learning and Dempster-Shafer Evidence Theory. *International Conference on Artificial Intelligence, Robotics and Control (AIRC)*. Cairo. 33–38. doi:10.1145/3388218.3388220.
16. Cao X., Zhu D., and Yang S.X. 2016. Multi-AUV Target Search Based on Bioinspired Neurodynamics Model in 3-D Underwater Environments. *IEEE Transactions on Neural Networks and Learning Systems*. 27(11):2364–2374. doi:10.1109/TNNLS.2015.2482501.
17. Itkina M., Driggs-Campbell K., and Kochenderfer M.J. 2019. Dynamic Environment Prediction in Urban Scenes using Recurrent Representation Learning. *IEEE Intelligent Transportation Systems Conference (ITSC)*. Rhodes. 2052–2059. doi:10.1109/ITSC.2019.8917271.

18. Kochenderfer M.J., Mikhali M. 2017. Convolutional Neural Network Information Fusion Based on Dempster-Shafer Theory for Urban Scene Understanding. Technical Report, Stanford University. Stanford. 4321–4328. Available at: <http://cs231n.stanford.edu/reports/2017/pdfs/632.pdf> (accessed July 27, 2021).
19. Farias C. M. de, Pirmez L., Delicato F.C. et al. 2017. GROWN: A Control and Decision System for Smart Greenhouses Using Wireless Sensor Networks. Australasian Computer Science Week Multiconference. Geelong. (48): 1–8. doi:10.1145/3014812.3014862.
20. Zhang Z., Jiang W., Geng J., Deng X., and Li X. 2020. Fault Diagnosis Based on Non-Negative Sparse Constrained Deep Neural Networks and Dempster-Shafer Theory. IEEE Access. 8:18182–18195. doi:10.1109/ACCESS.2020.2966260.
21. Denœux Th. 2019. Logistic Regression, Neural Networks and Dempster-Shafer Theory: A New Perspective. Knowledge-Based Systems. 176:54–67. doi:10.1016/j.knsys.2019.03.030.
22. Chen K., Gu L., Sun J. 2020. A DoS Attack Detection Method Based on Multi-Source Data Fusion. 4th International Conference on Computer Science and Application Engineering (CSAE). Sanya. (116):1–8. doi:10.1145/3424978.3425098.
23. Tong Z., Xu P., Denœux, T. 2019. ConvNet and Dempster-Shafer Theory for Object Recognition. Proc of the 13th International Conference on Scalable Uncertainty Management. Springer International Publishing, Cham, France. 368–381. Available at: https://link.springer.com/chapter/10.1007/978-3-030-35514-2_27 (accessed July 27, 2021).
24. Gao Z., Lu G., and Yan P. 2016. Enhancing Action Recognition in Low-Resolution Videos Using Dempster-Shafer's Model. IEEE International Conference on Digital Signal Processing (DSP). Beijing. 676–680. doi:10.1109/ICDSP.2016.7868644.
25. Gao C., Wang F., and Xu D. 2017. Gas Outburst Prediction Based on the Intelligent Dempster-Shafer Evidence Theory. 9th International Conference on Modelling, Identification and Control (ICMIC). Kunming. 897–901. doi:10.1109/ICMIC.2017.8321582.
26. Li L., Tang J., and Liu Y. 2015. Partial Discharge Recognition in Gas Insulated Switchgear Based on Multi-Information Fusion. IEEE Transactions on Dielectrics and Electrical Insulation. 22(2): 1080–1087. doi:10.1109/TDEI.2015.7076809.
27. Wang, Y., Yan, J., Yang, Z. et al. 2019. Partial Discharge Pattern Recognition of Gas-Insulated Switchgear via a Light-Scale Convolutional Neural Network. Energies. 12(24):4674. doi:10.3390/en12244674.
28. Saha S., Saha S. and Bhattacharyya P. P. 2015. Classifier Fusion for Liver Function Test Based Indian Jaundice Classification. International Conference on Man and Machine Interfacing (MAMI). Bhubaneswar. 1–6. doi:10.1109/MAMI.2015.7456588.
29. Chen Y., Yang Y., Li J. et al. 2016. Intelligent Fault Diagnosis Technology Based on Hybrid Algorithm. Chinese Control and Decision Conference (CCDC). Yinchuan. 3702–3706. doi:10.1109/CCDC.2016.7531627.
30. Huo Z., Zhang Y., Shu L. et al. 2018. Bearing Fault Diagnosis Using Multi-Sensor Fusion Based on Weighted D-S Evidence Theory. 18th International Conference on Mechatronics – Mechatronika (ME). Brno. 1–6. Available at: <https://ieeexplore.ieee.org/document/8624681> (accessed July 27, 2021).
31. Liu M., Yan X., Sun X. et al. 2016. Fault Diagnosis Method for Railway Turnout Control Circuit Based on Information Fusion. IEEE Information Technology, Networking, Electronic and Automation Control Conference. Chongqing. 315–320. doi:10.1109/ITNEC.2016.7560373.
32. Zhang T., Zhou T., Duerstock B.S., and Wachs J.P. 2018. Image Exploration Procedure Classification with Spike-timing Neural Network for the Blind. 24th International Conference on Pattern Recognition (ICPR). Beijing. 3256–3261. doi:10.1109/ICPR.2018.8545312.
33. Zhang T., Duerstock B.S., and Wachs J.P. 2020. Classification of Blind Users' Image Exploratory Behaviors Using Spiking Neural Networks. IEEE Trans. on Neural Systems and Rehabilitation Engineering. 28(4):1032–1041. doi:10.1109/TNSRE.2019.2959555.
34. Ghorbanzadeh O., Meena S.R., Shahabi H. et al. 2021. Landslide Mapping Using Two Main Deep-Learning Convolutional Neural Network Streams Combined by the Dempster-Shafer Model. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 14:452–463. doi:10.1109/JSTARS.2020.3043836.
35. Jian L., Liyan L., Jiadi L. et al. 2017. Drilling well leakage type diagnostic method based on neural network fusion technology. Patent CN 104121014 B. Available at: <https://patents.google.com/patent/CN104121014B/en> (accessed July 27, 2021).
36. Ladjal M., Bouamar M., Djeriou M., and Brik Y. 2016. Performance Evaluation of ANN and SVM Multiclass Models for Intelligent Water Quality Classification Using Dempster-Shafer Theory. International Conference on Electrical and Information Technologies (ICEIT). Tangier. 191–196. doi:10.1109/EITech.2016.7519588.
37. Soua R., Koesdwiady A., and Karray F. 2016. Big-Data-Generated Traffic Flow Prediction Using Deep Learning and Dempster-Shafer Theory. International Joint Conference on Neural Networks (IJCNN). Vancouver. 3195–3202. doi:10.1109/IJCNN.2016.7727607.
38. Dallali A., Omrani T., and Rhaimi B.C. 2018. Evidence Theory Data Fusion-Based Method for Cyber-Attack Detection. 4th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP). Sousse. 1–4. doi:10.1109/ATSIP.2018.8364337.
39. Enăchescu C., Sándor H. and Genge B. 2019. A Multi-Model-based Approach to Detect Cyber Stealth Attacks in Industrial Internet of Things. International Conference on Software, Telecommunications and Computer Networks (SoftCOM). Split. 1–6. doi:10.23919/SOFTCOM.2019.8903645.
40. Kushwah N. and Sonker A. 2016. Malicious Node Detection on Vehicular Ad-Hoc Network Using Dempster Shafer Theory for Denial of Services Attack. 8th International Conference on Computational Intelligence and Communication Networks (CICN). Tehri. 432–436. doi:10.1109/CICN.2016.91.
41. Zhang C., Chen K., Zeng X., and Xue X. 2018. Misbehavior Detection Based on Support Vector Machine and Dempster-Shafer Theory of Evidence in VANETs. IEEE Access. 6:59860–59870. doi:10.1109/ACCESS.2018.2875678.

42. Zou J., Guo X., Li L. et al. 2018. Deep Regression Model for Received Signal Strength based WiFi Localization, IEEE 23rd International Conference on Digital Signal Processing (DSP). Shanghai. 1–4. doi: 10.1109/ICDSP.2018.8631593.
43. Li J., Dong S., Yu Z. et al. 2019. Event-Based Vision Enhanced: A Joint Detection Framework in Autonomous Driving. IEEE International Conference on Multimedia and Expo (ICME). Shanghai, 1396–1401. doi:10.1109/ICME.2019.00242.
44. Si L., Wang Z., and Jiang G. Fusion Recognition of Shearer Coal-Rock Cutting State Based on Improved RBF Neural Network and D-S Evidence Theory. 2019. IEEE Access. 7:122106–122121. doi:10.1109/ACCESS.2019.2937829.

Palyukh Boris V. Doctor of technical sciences, professor. Head of Chair «Information Systems» of the Tver State Technical University. Research areas: management systems, artificial intelligence, creation and support of expert systems, evolutionary design, e-mail: pboris@tstu.tver.ru

Ivanov Vladimir K. Candidate of technical sciences, docent. Docent of Chair «Information Systems» of the Tver State Technical University. Research areas: information technologies, data warehouses, decision making, data mining, e-mail: mtivk@mail.ru