

УДК 004.896

В. Н. ГАЛУШКО, кандидат технических наук, В. О. БЕЛЬКИН, Белорусский государственный университет транспорта, г. Гомель

ОСОБЕННОСТИ ПРИМЕНЕНИЯ ТЕХНОИНТЕЛЛЕКТА НА ТРАНСПОРТЕ И В ЭНЕРГЕТИЧЕСКОЙ ПРОМЫШЛЕННОСТИ

Интеграция разработок ученых за последние 80 лет в области искусственного интеллекта позволила создать архитектуру нейронной сети, исключающую недостатки коннекционистских систем, спроектированных ранее. Новая система способна работать с числовыми данными и изображениями в цветном и черно-белом форматах, она обладает высокой чувствительностью и применяется преимущественно для решения задач технической диагностики. Такая нейронная сеть, дополненная областью памяти с адаптированным методом обучения, находит широкое применение в энергетической промышленности для решения сложных технических задач. В статье будут рассмотрены различные способы применения бимодальной системы – определение технического состояния ядерного реактора, анализ и систематизация неупорядоченных данных по энергоресурсам, распознавание памяти и классификация неисправностей электрических машин.

В 1944 году человечество, вдохновленное биологией, впервые попыталось обуздать искусственный интеллект. Отцы-основатели Уоррен МакКаллок и Уолтер Питтс показали, что при помощи пороговых нейронных элементов можно реализовать исчисление любых логических функций. И уже в 1958 году Фрэнк Розенблатт создал вычислительную систему «Марк-1», которая стала первым нейрокомпьютером, способным обучаться. Эта система была построена на основе перцептрона – нейронной сети, разработанной Фрэнком по образу и подобию человеческого мозга, за три года до системы «Марк-1». Сей-

час ученые с каждым годом все ближе подбираются к тайнам загадочного органа. За последние 80 лет было разработано множество нейронных сетей и методов их обучения: перцептрон, сеть Кохонена, обучение Хебба, было придумано множество функций активации нейронов и т. д. Наступает момент, когда необходимо интегрировать накопленный опыт ученых-исследователей и испытать его на практике.

На рисунке 1, а представлена схема нейронной сети, учитывающая идею перцептрона Розенблата и Румельхарта, включающая преимущества обучения Хебба, а также сеть Кохонена и область памяти.




Рисунок 1 – Схема нейронной сети (а) и входного нейрона (б)

Нейронная сеть разбита на пять сегментов: входной, вероятностный, абстрактный, аналитический и реагирующий. Рассмотрим каждый из них подробнее.

Входной сегмент представляет собой матрицу входных нейронов, которые называются сенсорами. Сегмент представлен в виде матрицы для удобства

программирования, поскольку с характеристиками объектов и изображениями легче работать именно в таком виде, нежели с данными, растянутыми в вектор.

При работе с растровой графикой размер матрицы соответствует 1:1 размеру изображения. Например: размер картинки 150×150 пикселей (ширина×высота),

значит матрица будет 150×150 ($m \times n$) нейронов. В этом случае входной слой будет содержать в себе 22500 сенсоров.

Сенсоры принимают на вход значение своих пикселей по порядковому номеру. Это значит, что первый нейрон будет запоминать первый пиксель и т. д. На вход сенсора приходит структура данных, полями которой являются три канала изображения — *RGB*. Нейрон преобразует каналы в матрицу-строку и помещает ее в память нейрона.

Для работы с данными в числовом формате у сенсора имеется еще один канал с весовым коэффициентом равным единице. По этому каналу приходит сигнал с вектора входных воздействий. Значение входного сигнала перемножается с весом нейрона и помещается в буффер элемента.

В матрице под каждую измерительную характеристику объекта выделяется отдельный столбец и происходит поочередное заполнение входного слоя. Например, если мы хотим диагностировать сердечную недостаточность у человека, то на входной слой будут подаваться медицинские признаки пациента: потребление кислорода миокардом, артериальное давление, уровень сахара в крови и т. д. В этом случае под каждой из этих характеристик в матрице будет выделен отдельный столбец.

Теперь, когда каждый столбец можно рассматривать как отдельный вектор, следует выполнить его масштабирование: нормализацию и стандартизацию. В первом случае происходит масштабирование вектора в диапазон $[0;1]$. Достигается это с помощью формулы

$$y = \frac{x_j - \min(X_i)}{\max(X_i) - \min(X_i)},$$

где y — преобразованное значение; X_i — вектор входных воздействий (i -й столбец); x_j — входной сигнал нейрона; $\min(X_i)$, $\max(X_i)$ — операции вычисления минимального и максимального значений.

Стандартизация — это процесс приведения вектора каждого признака к такому виду, что его математическое ожидание равно нулю, а дисперсия — единице;

$$y = \frac{x_j - \mu}{\sigma},$$

где y — преобразованное значение; x_j — входной сигнал нейрона; μ — среднее значение выборки, σ — среднее квадратическое отклонение.

Работу одного сенсора можно представить схемой, изображенной на рисунке 1, б.

Нейроны в этом слое хранят полученную информацию и делятся ею с другими нейронами до тех пор, пока не будет получен конечный результат сети, поэтому входной сегмент имеет центральную позицию в структуре нейронной сети, а сами нейроны преимущественно выполняют роль запоминающих элементов и поэтому не имеет никаких функций активации.

Абстрактный сегмент. В этом сегменте реализован на данный момент один нейрон «Цвета». Он определяет цвет объекта по заложенному в него математическому алгоритму. Смысл которого заключается в перерасчете формата *RGB* в *HSL*. *HSL* — это еще один

способ описания цвета. Здесь используется оттенок H (угол на цветовом круге), насыщенность S (количество цвета) и яркость L (насколько яркий цвет).

Рассмотрим на примере $R = 24$, $G = 98$, $B = 118$. Результатом пересчета является: $H = 193^\circ$, $S = 67\%$, $L = 28\%$. Это говорит нам о том, что изображение довольно насыщенное и темное. На цветовом круге 193° очень близко к голубому.

Алгоритм пересчета:

1 Найти минимальное и максимальные значения *RGB*.

2 Вычислить значение яркости L .

3 Определить насыщенность.

4 Рассчитать оттенок.

Вероятностный сегмент.

Вероятностный сегмент состоит из двух слоев ассоциативных нейронов и одного вероятностного нейрона. В ассоциативных слоях происходит непосредственная обработка данных. За счет глубинной структуры сеть находит сложные корреляции и нелинейные зависимости, подготавливая новый вектор признаков, который затем передается на вероятностный нейрон.

Нейроны первого ассоциативного слоя связаны синоптическими связями с матрицей запоминающих элементов и имеют весовые коэффициенты в количестве равном количеству входных нейронов.

Выходом буферного нейрона в первом слое является матрица-строка. Весовые коэффициенты нейронов первого ассоциативного слоя представлены матрицами-столбцами. Каждый выход буферного нейрона (матрица-строка) умножается на весовой коэффициент ассоциативного нейрона (матрица-столбец). Результатом одного умножения является число, которое затем подается на смещенную сигмоидальную (логистическую) функцию активации. Особенностью нейронов с такой передаточной характеристикой является то, что они усиливают сильные сигналы существенно меньше, чем слабые, поскольку области сильных сигналов соответствуют пологим участкам характеристик. Это позволяет предотвратить насыщение из-за больших сигналов. Когда все выходы первого ассоциативного слоя получены, они передаются нейронам второго слоя, который работает аналогичным образом.

Однако, если матрица запоминающих элементов большая, то соответственно и весовых коэффициентов у ассоциативного нейрона будет много. Это приводит к большим значениям при суммировании и некорректным значениям на выходе функций активации. Для решения этой проблемы была взята идея Дональда Хебба, которая заключается в том, чтобы максимально ослабить входные значения, без влияния на синоптические связи между активными нейронами.

Вероятностный нейрон суммирует признаки ассоциативных нейронов. Затем отправляет результат расчета на симметричную сигмоидальную функцию активации, представленную выражением гиперболического тангенса. Выход гиперболической функции активации подается на пороговую функцию, которая переводит нейрон в одно из устойчивых состояний, соответствующих тому или иному объекту.

Стандартная, нелинейная, многослойная архитектура нейронных сетей с правилом обратного распро-

странения ошибки и прямым распространением сигнала испытывает трудности при объяснении основного аспекта человеческой памяти: способности учиться и запоминать на одном примере. Хотя сети такого рода способны запоминать единственный шаблон с высокой степенью точности, они не могут сделать это для серии таких шаблонов, не забывая всё, кроме последних нескольких. Человеческий мозг безусловно проявляет ретроактивное вмешательство в некоторой степени, но, поскольку они могут запоминать явно больше, чем последние несколько элементов из длинного списка, они не проявляют такого рода катастрофического вмешательства, которое, на первый взгляд, кажется неотъемлемым для многослойных сетей с обратным распространением ошибки. Подробно о катастрофическом вмешательстве будет рассмотрено ниже, при описании области памяти. Здесь же, в вероятностном сегменте, стоит отметить принцип обучения, который вносит свой вклад в решение проблемы забывчивости сетей.

В описываемом методе обучения есть три ключевых момента, которые важно отметить. Первый момент заключается в том, что при обучении сети, ортогональности входов достаточно для устранения вмешательства. Это значит, если сеть обучена распознавать A , то она выдаст результат $\bar{A}$, а последующее обучение шаблону B , для получения любых других выходных данных не изменит отображение A в $\bar{A}$, пока B ортогонально A .

Второй ключевой момент заключается в том, чтобы использовать активационные паттерны в ассоциации. Под активационными паттернами в данном случае подразумевается набор активных единиц, ответственных за классификацию. Именно они подлежат обвинению, когда сеть делает ошибку, и их веса корректируются. Обвинение любых других нейронов приводит к избыточным помехам.

Третий ключевой момент касается корректировки весов. Здесь не все так однозначно. Поскольку чаще всего приходится работать с растровой графикой, входной сегмент содержит в себе большое количество сенсоров. Это, как отмечалось выше, приводит к нарушению вектора активации. Поэтому изменение весов на первом вероятностном слое производится по усеченной формуле Дональда Хебба с коэффициентом скорости обучения во много раз меньше весовых коэффициентов нейронов этого слоя.

Стоит также отметить, что к использованию подобного метода обучения авторов вдохновила работа Криса Кортге, который использовал векторы новизны для решения проблемы катастрофического вмешательства нейронных сетей [5].

Следующим и, пожалуй, самым главным является реагирующий сегмент.

Он является самым важным по двум причинам:

- 1 Нейроны в этом участке связаны с областью памяти искусственного интеллекта, где хранится информация об объектах.

- 2 Именно реагирующий нейрон агрегирует полученные данные на предыдущих слоях и мажоритарным методом определяет, что за объект находится на изображении.

Реагирующий нейрон не имеет ни весовых коэффициентов, ни функций активации. Когда данные на предыдущих слоях получены, он обращается к каждому нейрону в отдельности и забирает полученный результат (цвет, форму, размер, вероятность), а затем сравнивает эти данные с теми, что хранятся в области памяти. Тот объект, данные которого ближе остальных расположены к рассчитанным значениям, подается на выход реагирующего нейрона (выход сети).

Область памяти.

Все естественные когнитивные системы, и, в частности, наша собственная, постепенно забывают ранее изученную информацию. Поэтому правдоподобные модели человеческого мозга должны демонстрировать схожие закономерности постепенного забывания старой информации по мере получения новой.

Уже в 1960-х годах ученые Мински и Паперт наблюдали, что процесс обучения новому набору паттернов внезапно и полностью стирал знания сети о том, что она уже усвоила. Они назвали это явление катастрофическим вмешательством (или катастрофическим забыванием). Причиной этого являются те особенности, которые придают сетям их широкие способности к функционированию – весовые коэффициенты. Однако основной проблемой катастрофического вмешательства является отсутствие «стабильности-пластичности». Разработанная система должна быть открыта для ввода новых данных, но не нарушаться ими [4].

Так, в 1990-х годах были предложены различные методы решения стоящей проблемы. Одна из самых интересных принадлежит Макклелланду, Макнотону и О'Рейли. Их идея заключается в том, что природный способ реализации обязательного разделения заключался в эволюции двух отдельных областей мозга, гиппокампа и неокортекса. Они обосновали бимодальную архитектуру мозга следующим образом: «Последовательное приобретение новых данных несовместимо с постепенным открытием окружающего мира и может привести к катастрофическому вмешательству в то, что было ранее изучено. В свете этих наблюдений они предполагают, что неокортекс может быть оптимизирован для постепенного открытия общей структуры событий и опыта, а гиппокампальная система предназначена для обеспечения механизма быстрого приобретения новой информации без вмешательства в ранее открытые регуляры. После этого первоначального приобретения гиппокампальная система служит учителем для неокортекса [4].

На протяжении многих лет и по сей день исследователи изучают проблему катастрофического вмешательства в соединительных сетях. Моделирование истинного последовательного обучения, подобного тому, что делаем мы, люди, требует нахождения соответствующих решений этой проблемы. Недавние исследования, похоже, указывают на то, что одним из возможных решений являются две отдельные, постоянно взаимодействующие области обработки: одна для новой информации, другая для долгосрочного хранения ранее усвоенной информации [4].

Поэтому вторая часть нейронной сети представляет собой область памяти, реализованной с помощью базы

данных *Access*. Информация в базе хранится в виде таблиц, которые содержат в себе сведения об объектах, полученные ранее при решении задач или при обучении. Каждому объекту соответствуют две таблицы. Первая содержит в себе абстрактные сведения – это цвет, форма, размер. Вторая таблица последовательно связана синаптической связью с первой. В ней находится вероятность появления объекта, соответствующая одному из устойчивых состояний вероятностного нейрона, а также весовые коэффициенты вероятностного и ассоциативных нейронов.

Реагирующий нейрон связан синаптическими связями с первой таблицей каждого объекта. А за счет согласованности структуры он имеет полный доступ и ко второй таблице. Когда возникает необходимость решить ранее выполненную задачу и/или продолжить обучение сети по данному направлению, он считывает необходимую ему информацию без потери целостности, а по окончании работы помещает сведения обратно в область памяти.

Аналитический сегмент.

Этот участок представляет собой отдельный класс нейронных сетей, которые называют самоорганизующимися: векторного квантования, самоорганизующиеся карты – базовая нейронная сеть Кохонена. Он применяется всегда при работе с неупорядоченными, числовыми данными и в тех случаях, когда основная сеть затрудняется ответить, что за объект находится перед ней.

Каждый нейрон соединен со всеми компонентами входного слоя. Входной вектор – это описание одного из объектов, подлежащих кластеризации. Количество нейронов совпадает с количеством кластеров, которые должна выделить сеть. В качестве нейронов сети Кохонена применяются линейные взвешенные сумматоры. Входной вектор сети, как и входной слой, имеет вид матрицы:

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix}.$$

Каждый j -й нейрон описывается вектором весов синаптических связей:

$$W_j = \begin{bmatrix} w_{j1} & w_{j2} & \dots & w_{jn} \\ w_{21} & w_{22} & \dots & w_{2n} \\ \dots & \dots & \dots & \dots \\ w_{m1} & w_{m2} & \dots & w_{mn} \end{bmatrix}.$$

Структура аналитического участка состоит из m параллельно действующих линейных элементов. Все они имеют одинаковое число входов и получают на свои входы один и тот же вектор входных сигналов. Выходной сигнал j -го линейного элемента:

$$y_j = w_{0j} + \sum_{i=1}^n w_{ij}x_i,$$

где w_{0j} – пороговый коэффициент; w_{ij} – весовой коэффициент i -го входа j -го нейрона; $i = 1, \dots, n$ – номер входного воздействия; $j = 1, \dots, m$ – номер линейного элемента.

Для обучения применяются механизмы конкуренции. При подаче на вход значения вектора X побеждает тот нейрон, вектор которого в наименьшей степени отличается от входного вектора.

После прохождения слоя линейных элементов сигналы посылаются на обработку по правилу «победитель забирает все». Среди выходных сигналов выполняется поиск максимального, определяется его номер. Окончательно, на выходе сигнал с найденным номером равен единице, остальные – нулю [6].

Применение нейронной сети.

Сейчас в мире происходит четвертая промышленная революция, радикально изменившая традиционные производственные процессы, благодаря активному внедрению инновационных технологий. Одной из ключевых движущих сил этой трансформации является искусственный интеллект. Поэтому правило «победитель забирает все» применимо не только к нейросетям, но и к передовым компаниям. Победителем является тот, кто успешно адаптировал искусственный интеллект для повышения эффективности технологических процессов в производственной системе. Вот некоторые из них:

- автоматизация и роботизация. Позволяют производственным системам, а также роботам учиться и адаптироваться в процессе выполнения задач;

- прогнозирование спроса и планирование производства. Позволяют анализировать большие массивы данных для прогнозирования спроса, что помогает точнее планировать производство;

- управление качеством. Нейронные сети могут принимать и анализировать информацию с первичных преобразователей, установленных на линиях, для выявления дефектов продукции на ранних стадиях. Это снижает количество брака и позволяет оперативно реагировать на проблемы, улучшая качество конечного продукта;

- техническое обслуживание оборудования. Благодаря алгоритмам машинного обучения нейросети могут предсказывать возможные поломки оборудования, анализируя его состояния, операционные данные и др. [6].

С каждым годом эта технология быстро развивается, но не так быстро, как область ее применения. Например, в 2019 году искусственный интеллект от Google проводил медицинское обследование, при этом обнаружил рак легких быстрее и лучше, чем шесть рентгенологов при таком же медицинском осмотре. Крупные автопроизводители внедряют искусственный интеллект для анализа данных с датчиков на своих сборочных линиях, что позволяет снижать количество брака. На предприятиях пищевой промышленности искусственный интеллект используется для мониторинга состояния оборудования и анализа его работы в реальном времени, что предотвращает поломки и снижает затраты на ремонт.

Несмотря на то, что в целом нейронные сети успешно справляются с вышеописанными задачами, существует проблема подбора оптимальных параметров для различных условий, таких как количество слов в архитектуре нейронной сети, а также прочие характеристики, связанные с формированием алгорит-

мов. Помимо этого, дополнительную наибольшую сложность несет экспертный выбор наиболее подходящих топологий нейронных сети под те или иные данные, что в условиях работы с разными данными может быть затруднительным и требует привлечения экспертов в области машинного обучения.

И здесь открывается еще одно преимущество разработанной нейронной сети – это ее гибкость. Она не требует выбора шаблона сети и функций активации. Количество слоев фиксировано. Единственным изменяемым параметром является скорость обучения, которая влияет на точность и время обучения.

Энергетика – это одна из ключевых отраслей экономики, которая обеспечивает функционирование всех других сфер жизни общества. С каждым годом эта отрасль становится все более важной из-за растущих потребностей в энергии и вызовов, связанных с изменением климата и ограниченностью природных ресурсов. Энергетика охватывает производство, преобразование, передачу и распределение энергии для удовлетворения потребностей населения и промышленности.

Наиболее перспективными с точки зрения использования искусственных нейронных сетей в электроэнергетике являются следующие области: прогнозирование нагрузки электроэнергетических систем; диагностика и локализация неисправностей; оптимизация распределения нагрузки; оценка надежности; динамическая устойчивость электроэнергетических систем.

Рассмотрим работу сети на примере управления атомными электрическими станциями (АЭС). Современные подходы к решению проблемы управления АЭС базируются на мощных, обладающих высокой степенью интеллектуализации, информационных системах поддержки операторов энергоблока по ведению технологического процесса. Важнейшей функцией систем контроля и управления технологическими процессами является функция диагностирования состояния оборудования энергоблока. Поэтому в качестве объекта исследования выступает ядерный реактор типа ВВЭР-1000/В-428. Его основные характеристические признаки, по которым будет выполняться диагностика, следующие:

- температура внутри реактора, измеряемая в градусах Цельсия ($^{\circ}\text{C}$);
- расход охлаждающей жидкости, циркулирующей через реактор, в литрах в секунду (л/с);
- давление внутри реактора, измеряемое в мегапаскалях (МПа);
- уровень радиации внутри зоны реактора, измеряемый в микрозивертах в час (мкЗв/ч);
- скорость вращения турбины в оборотах в минуту;
- состояние насоса охлаждающей жидкости.

Задача нейронной сети определить аномалию для ядерного реактора (1 – аномалия есть, 0 – аномалии нет) на основе показаний первичных преобразователей. Это может быть любое аварийное событие, вызванное механическим или электрическим отказом (например, потеря потока теплоносителя – значительно снижает эффективность отвода тепла от активной зоны, активная зона реактора будет повреждена и подвергнет риску множество людей).

Набор данных содержит 2200 примеров (исходные данные получены на сайте *Kaggle*), соответствующих двум состояниям объекта. Количество примеров обучающей выборки 2000 (по 50 % на каждый класс). Количество примеров тестовой выборки 200. Для решения задачи были задействованы входной и вероятностный сегменты сети. Вероятностный нейрон имел два состояния: 0 и 1, соответствующих 2 классам. По результатам обучения сеть не сделала ни одной ошибки при классификации.

Однако бывают случаи, когда не для всех примеров обучающей выборки заблаговременно известны правильные ответы. Тогда применяется парадигма обучения нейронных сетей без учителя. Главной чертой этого метода обучения является его самостоятельность. При обучении предпринимаются попытки определения внутренней структуры поступающих в сеть данных с целью распределить образы по классам (категориям). По такому принципу работает аналитический сегмент. И чтобы продемонстрировать его работу был выбран специальный набор данных от PJM. Данные представляют собой почасовое потребление электроэнергии, выраженной в мегаваттах (МВт). Регистрация производилась с 2004 по 2018 год. Всего *DataSet* имеет свыше 127000 примеров. Сеть должна понять, как меняется потребление энергии в зависимости от времен года, не зная при этом заранее правильного ответа.

По умолчанию аналитический сегмент настроен выполнять кластеризацию по двум классам, а коэффициент скорости обучения имеет значение, ориентированное на более глубокое и детальное изучение. Поскольку времен года четыре, аналитический сегмент также будет содержать четыре нейрона.

По результатам обучения сеть все же распределила данные по двум классам, потому что строгой закономерности использования электроэнергии по месяцам не прослеживалось. Каждый месяц индивидуален, а потребление энергии зависит от температурного режима, продолжительности дня, наличия котла и кондиционера в помещении. Однако она все равно выявила, что самое большое потребление было зимой. А все остальные данные (лето, осень, весна) отнесла в отдельный класс.

Входной сегмент нейронной сети способен обрабатывать изображения любого формата, а вероятностный нейрон обладает высокой чувствительностью. Эти способности позволяют нейромодели отлично решать задачи классификации. Но реагирующий нейрон, дополненный областью памяти, расширяет ее потенциал способностью к запоминанию. В связи с этим испытываем бимодальную систему на выявлении нештатных режимов работы преобразователей энергии, запомним нескольких последних паттернов и выполним распознавание памяти.

Преобразователем энергии может быть любая электрическая машина: трансформатор, двигатель или генератор. В данном случае выступает трансформатор отечественного производства. Такие трансформаторы просты по конструкции, надежны и удобны в эксплуатации. Случаи повреждения вызваны нарушением действующих правил эксплуатации, аварийными и ненормированными режимами работы, старением изоляции обмоток, некачественной сборкой их на заводе или при монтаже и ремонте. Рассмотрим возможные наиболее распространенные неисправности силовых трансформаторов:

- повреждение магнитопровода (пожар стали) связано с нарушением изоляции между отдельными листами стали и стягивающими их болтами;
- ослабление прессовки магнитопровода. Свободное колебание крепящих деталей, колебание крайних листов магнитопровода;
- старение и износ изоляции. Происходит из-за длительной эксплуатации трансформатора, однако наблюдается и преждевременный износ, который является результатом частых перегрузок или недостаточно интенсивного охлаждения при номинальной нагрузке;
- межвитковые замыкания;
- обрыв обмотки, возникающий при сгорании выходных концов вследствие термического действия.

На вход сети подаются изображения, представ-

а)



ленные графиками зависимостей, описывающих три состояния объекта исследования: отказ, предотказное состояние и нормальный режим работы. Под обучение в этот раз будет выделено 300 изображений и 2700 входных сигналов для проверки работы. Пример вектора входных воздействий представлен на рисунке 2, а.

Вероятностный нейрон имеет три уровня чувствительности и по результатам обучения распределил тестовые данные по трем классам, не сделав ни одной ошибки.

На рисунке 2, б показано, как весовые коэффициенты одного нейрона хранятся в области памяти и с какими ячейками они еще взаимодействуют.

б)




Рисунок 2 – Примеры вектора входных воздействий (а) и сохранения весовых коэффициентов ассоциативного нейрона (б)

Бимодальная система продемонстрировала неплохие результаты по распознаванию памяти. Она запомнила информацию активационных паттернов и безошибочно выполнила повторную классификации.

Задачи, стоявшие перед рассмотренными нейромоделями, на сегодняшний день уже кажутся тривиальными. Однако развитие шаблона рассмотренной структуры нейромодели, наращивание архитектуры и укрепление связей между слоями нейронов делают ее более точной и эффективной, позволит охватывать новые сферы и решать новые, более сложные задачи.

Список литературы

- 1 Головкин, В. А. Нейросетевые технологии обработки данных : учеб. пособие / В. А. Головкин, В. В. Краснопрошин. – Минск : БГУ, 2017. – 263 с.
- 2 Фишбах, Д. Психика и мозг / Д. Фишбах // В мире науки. – 1992. – № 11–12. – С. 10–20.

- 3 Куталев, А. А. Современные методы преодоления катастрофической забывчивости нейронных сетей и экспериментальная проверка вопросов их структуры / А. А. Куталев, А. А. Лапина // Компьютерные исследования и моделирование. – 2023. – Т. 15, № 1. – С. 45–56. – DOI: 10.20537/2076-7633-2023-15-1-45-56.

- 4 French, R. M. Catastrophic forgetting in connectionist networks / R. M. French // Trends in cognitive sciences. – 1999. – Vol. 3, № 4. – P. 128–135.

- 5 Korte, C. A. Episodic Memory in Connectionist Networks / C. A. Korte // Proceedings of the Annual Meeting of the Cognitive Science Society. – 1990. – Vol. 12. – P. 764–771.

- 6 Ибрагимова, Н. А. Эффективное использование искусственного интеллекта в производстве / Н. А. Ибрагимова, З. З. Ибрагимов // Экономика и социум. – 2024. – № 10-1(125). – С. 639–642.

- 7 Шарипбай, А. А. Нейронные сети : учеб. / А. А. Шарипбай. – Астана : Мастер ПО, 2018. – 397 с.

Получено 15.05.2025

V. N. Galushko, V. O. Belkin. Features of the application of techno-intelligence in transport and energy industry.

The integration of the experience of scientists over the past 80 years of work in the field of artificial intelligence made it possible to develop a neural network architecture that eliminates the shortcomings of previously created connectionist systems. The new system is capable of working with numerical data and images in color and black and white formats; it has high sensitivity and is used primarily to solve technical diagnostic problems. Such a neural network, supplemented by a memory area with an adapted learning method, finds wide application in the energy industry to solve complex technical problems. The article will consider various ways of using the bimodal system - determining the technical condition of a nuclear reactor, analyzing and systematizing unordered data on energy resources, recognizing memory and classifying faults in electrical machines.