



Интеллектуальное нейроуправление новостными потоками с непрерывным обучением

В. Ю. Осипов^а, доктор техн. наук, профессор, orcid.org/0000-0001-5905-4415, osipov_vasily@mail.ru

С. В. Кулешов^а, доктор техн. наук, профессор РАН, orcid.org/0000-0002-8454-5598

А. А. Зайцева^а, канд. техн. наук, старший научный сотрудник, orcid.org/0000-0002-1345-8550

Д. И. Милосердов^а, канд. техн. наук, старший научный сотрудник, orcid.org/0000-0002-5312-5531

^аСанкт-Петербургский Федеральный исследовательский центр Российской академии наук, 14-я линия В. О., 39, Санкт-Петербург, 199178, РФ

Введение: нейросетевое управление (нейроуправление) различными нелинейными объектами представляет большой теоретический и практический интерес. Однако степень интеллектуальности и функциональности известных решений по такому управлению во многом не удовлетворяет потребностям практики. **Цель:** разработать метод и систему нейроуправления с расширенной интеллектуальностью и функциональностью. **Методы:** для достижения цели предлагаются новые нейросетевые решения, ориентированные на обработку новостных потоков с изменяющимися законами поведения и выработку управляющих решений в этих условиях. **Результаты:** предложена архитектура интеллектуальной нейросетевой системы с непрерывным обучением, способной решать существенно расширенный набор творческих задач без ее перестройки. В частности, это задачи нейросетевого распознавания, прогнозирования, восстановления событий, их синтеза, управления новостными потоками и другими объектами. Разработан новый метод многоуровневой нейросетевой обработки информации в рекуррентных нейронных сетях с управляемыми элементами. Предложены новые алгоритмы управления нейронными сетями, позволяющие интеллектуально решать задачи нейроуправления новостными потоками с непрерывным обучением. Сравнительный анализ полученных результатов с известными моделями и методами показал эффективность предложенных подходов. **Практическая значимость:** предложенная архитектура позволяет решать многие творческие задачи с непрерывным обучением без ее перестройки. Разработанный метод дает возможность реализовать управляемую многоуровневую нейросетевую обработку на основе новых ассоциативных принципов. Сформулированные новые рекомендации по построению перспективных систем нейроуправления позволяют ускорить их разработку и использование на практике. **Обсуждение:** даны рекомендации по созданию перспективных систем нейроуправления новостными потоками с непрерывным обучением. В качестве направлений дальнейших исследований по созданию перспективных интеллектуальных систем нейроуправления следует выделить наделение их искусственным мышлением, поиск решений по снижению сложности реализации, а также методов энергоэффективной и малогабаритной реализации.

Ключевые слова – нейросетевое управление, интеллектуальность, непрерывное обучение, обработка новостных потоков.

Для цитирования: Осипов В. Ю., Кулешов С. В., Зайцева А. А., Милосердов Д. И. Интеллектуальное нейроуправление новостными потоками с непрерывным обучением. *Информационно-управляющие системы*, 2024, № 6, с. 35–45. doi:10.31799/1684-8853-2024-6-35-45, EDN: IDATPB

For citation: Osipov V. Y., Kuleshov S. V., Zaytseva A. A., Miloserdov D. I. Intelligent neurocontrol of news streams with continuous learning. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2024, no. 6, pp. 35–45 (In Russian). doi:10.31799/1684-8853-2024-6-35-45, EDN: IDATPB

Введение

Нейроуправление позволяет быстро формировать нейросетевые модели сложных нелинейных объектов даже при изменении законов их поведения и вырабатывать соответствующие управляющие воздействия. Не требуется трудоемкой разработки и перестройки сложных нелинейных аналитических зависимостей. В качестве объектов нейроуправления могут быть физические, химические, биологические, электронные, информационные и другие объекты. В частном случае возможно нейроуправление новостными потоками. Оно может предусматривать прогнозирование информационных событий и поиск целесообразных источ-

ников информации, селекцию интересующей информации по различным признакам. Также осуществимо противодействие возможным информационным угрозам не только через их блокирование, но и путем синтеза специальных воздействий как на источники этих угроз, так и на потребителей. Реализация нейроуправления предусматривает наличие соответствующих моделей и методов. Известен ряд традиционных подходов к управлению, в частности нейроуправлению [1–4]. Широкое применение получили трансформеры, способные с известной точностью решать различные творческие задачи, в том числе связанные с обработкой естественного языка [5]. Развиваются как архитектуры моделей, так и программное обеспечение,

упрощающее настройку и использование GPT (Generative Pretrained Transformer) [6].

Однако существующие подходы во многом не удовлетворяют современным потребностям практики, в том числе применительно к интеллектуальному управлению новостными потоками. Дальнейшее расширение интеллектуальности управления ими на основе традиционных нейросетевых решений существенно ограничено. Это касается, прежде всего, задач нейросетевой обработки потоков событий с изменяющимися законами поведения и выработки адекватных управляющих решений в этих условиях. Например, сети GPT требуют предварительного обучения, которое существенно влияет на результаты. Кроме того, результаты генеративных моделей, как правило, непредсказуемы и с трудом воспроизводимы [7]. Несовершенны применяемые архитектуры нейросетевых систем, алгоритмы их работы [8]. Возможности хранения сигналов на элементах искусственных рекуррентных нейронных сетей (РНС) и обеспечения устойчивости этих сетей при непрерывном обучении уступают характеристикам, присущим биологическим системам [9, 10]. Во многом не проработаны вопросы интеллектуальной многозадачной и многоуровневой обработки информации [11–14]. Это затрудняет переход от уровня элементарной обработки сигналов к уровню оперирования понятиями и наоборот. Остаются нерешенными проблемы нейросетевого формирования сознательных воздействий на объекты

управления. Требуют дальнейшего развития методы нейросетевой обработки информации различных масштабов в настоящем, прошлом и будущем времени [15–17].

Целью данного исследования является разработка метода и системы нейроуправления с расширенной интеллектуальностью и функциональностью применительно к новостным потокам. Для достижения этой цели предлагаются:

- новая архитектура интеллектуальной нейросетевой системы с непрерывным обучением, способной решать существенно расширенный набор творческих задач по обработке и управлению новостными потоками и другими объектами без ее перестройки;
- алгоритмы управления нейронными сетями, позволяющие интеллектуально решать задачи нейроуправления новостными потоками;
- рекомендации по построению перспективных систем нейроуправления.

Архитектура интеллектуальной системы нейроуправления

Для расширения интеллектуальности и функциональности нейросетевых систем обработки и управления новостными потоками и другими объектами предлагается структурное решение, представленное на рис. 1. В его основу положено интеллектуальное ядро [18], состоящее из двух идентичных потоковых РНС (*РНС 1* и *РНС 2*)



■ **Рис. 1.** Структура системы нейроуправления новостными потоками
 ■ **Fig. 1.** Structure of the news flow neural control system

с новым блоком управления (рис. 2). Этот блок состоит из двух связанных симметричных подсистем управления РНС 1 и РНС 2. В его состав входит общий тактовый генератор, который вырабатывает импульсы для обработки сигналов в реальном и ускоренном времени.

Каждый контроллер может брать на себя функции как управления обучением нейронной сети, так и решения задач управления. Решение об изменении режимов работы может формироваться в блоке настроек. Информация в интеллектуальное ядро может поступать от различных датчиков. Согласно рис. 1 новостные потоки и управляющие воздействия перед поступлением в РНС 1, 2 представляются в блоке кодирования в виде последовательностей совокупностей единичных импульсов (СЕИ), несущих в себе всю информацию об исходных сигналах. Существует несколько вариантов обработки информации интеллектуальным ядром нейронной сети. Согласно первому варианту каждая РНС реализована как многоуровневая структура и работает в режиме многозадачности с непрерывным обучением. В этом варианте блок управления РНС координирует их работу.

Вся интеллектуальная обработка сигналов в этом случае выполняется в РНС на втором и более высоких уровнях. Предусмотрена как восходящая, так и нисходящая многоуровневая обработка. Наличие нескольких уровней позволяет разделить обработку сигналов прошлого и будущего

от реального времени. Во втором и третьем вариантах могут использоваться РНС как с одноуровневой, так и с многоуровневой структурой. В этих вариантах, как и в работе [18], одна из РНС непрерывно обучается, а вторая нейронная сеть используется для решения творческих задач по командам с блока управления сетью. Поясним один из таких вариантов, когда РНС 1 непрерывно обучается, воспринимая совокупности единичных импульсов, несущие информацию о новостных потоках и текущих управляющих воздействиях.

При поступлении СЕИ в РНС 1 они продвигаются вдоль слоев за счет реализованных пространственных сдвигов сигналов, связываются друг с другом и с ранее запомненной информацией на элементах сети. В результате в РНС 1 формируется постоянно обновляемая модель новостных потоков и управляющих воздействий. При решении основных творческих задач блок управления системы нейрорегулирования считывает информацию о состоянии нейронов и синапсов из РНС 1 в РНС 2. Затем в зависимости от команд со стороны блока управления на РНС 2 в ней в ускоренном времени решаются творческие задачи. Среди этих задач могут выступать нейросетевое прогнозирование или восстановление пропущенных событий, формирование обоснованных управляющих решений. Например, при решении задачи управления поиском интересующих новостей после считывания информации о состоянии элементов РНС 1 в РНС 2 в эту сеть также вводится со стороны блока управления одно из альтернативных будущих управлений. РНС 2 переводится в режим ускоренного прогнозирования состояний новостных потоков. Полученные результаты прогнозирования считываются из РНС 2 в блок управления, где оцениваются по одному из заданных показателей и сохраняются вместе с вариантом управления. Затем внутренний цикл повторяется, уже с другим альтернативным управлением. В результате из конечного набора оцененных вариантов управления выбирается лучший, обеспечивающий экстремум принятого показателя эффективности. Данный вариант управления передается через РНС 2 на декодер, а затем на эффекторы и блок кодирования. После воздействия на объект управления и считывания с него информации цикл управления повторяется. Принципиальными отличиями предлагаемой архитектуры интеллектуальной системы от известных моделей [19–21] являются наличие специального блока управления и использование управляемых РНС с прозрачными логическими структурами и многоуровневой обработкой информации. Также это дает возможность решать множество различных творческих задач обработки информации нейронными сетями с непрерывным обучением без перестройки архитектуры.



■ **Рис. 2.** Блок управления рекуррентными нейронными сетями
 ■ **Fig. 2.** The control unit for recurrent neural networks

Алгоритмы нейроуправления

Поясним формальные аспекты предлагаемого нейроуправления, раскроем алгоритмы, реализующие его при решении ряда творческих задач на одной и той же структуре системы с непрерывным обучением. При рассмотрении этих алгоритмов учтем ранее выполненные исследования [17, 22–25].

Алгоритм формирования управляющих решений

Согласно этому алгоритму обрабатываемые в РНС 1 сигналы рассматриваются как две последовательности совокупностей единичных импульсов. Это последовательность \mathbf{SSP}^a , несущая информацию о новостных потоках, и последовательность \mathbf{SSP}^c , отражающая управляющие воздействия. Эти последовательности можно представить в виде

$$\left\{ \begin{array}{l} \mathbf{SSP}^c \\ \mathbf{SSP}^a \end{array} \right\} = \left\{ \begin{array}{l} \mathbf{SSP}_1^c, \mathbf{SSP}_2^c, \dots, \mathbf{SSP}_n^c \\ \mathbf{SSP}_1^a, \mathbf{SSP}_2^a, \dots, \mathbf{SSP}_n^a \end{array} \right\}. \quad (1)$$

После считывания в РНС 2 информации о состоянии РНС 1 и данных об альтернативных управлениях \mathbf{SSP}^{c_j} ее состояние можно представить в виде

$$\left\{ \begin{array}{l} \mathbf{SSP}_1^{c_j}, \mathbf{SSP}_2^{c_j}, \dots, \mathbf{SSP}_i^{c_j}, \\ \mathbf{SSP}_{i+1}^c, \mathbf{SSP}_{i+2}^c, \dots, \mathbf{SSP}_n^c \\ \emptyset_1, \emptyset_2, \dots, \emptyset_i, \mathbf{SSP}_{i+1}^a, \mathbf{SSP}_{i+2}^a, \dots, \mathbf{SSP}_n^a \end{array} \right\}. \quad (2)$$

Относительно этого состояния реализация в РНС 2 ускоренного вызова информации из памяти в направлении входа сети приводит к результату

$$\left\{ \begin{array}{l} \mathbf{SSP}_1^{c_j}, \mathbf{SSP}_2^{c_j}, \dots, \mathbf{SSP}_i^{c_j}, \\ \mathbf{SSP}_{i+1}^c, \mathbf{SSP}_{i+2}^c, \dots, \mathbf{SSP}_n^c \\ \mathbf{SSP}_1^{b_j}, \mathbf{SSP}_2^{b_j}, \dots, \mathbf{SSP}_i^{b_j}, \\ \mathbf{SSP}_{i+1}^a, \mathbf{SSP}_{i+2}^a, \dots, \mathbf{SSP}_n^a \end{array} \right\}. \quad (3)$$

Итоговый прогноз новостных потоков при планируемом управлении представляется в виде

$$\mathbf{SSP}^{b_j} = \left\{ \mathbf{SSP}_1^{b_j}, \mathbf{SSP}_2^{b_j}, \dots, \mathbf{SSP}_i^{b_j} \right\}. \quad (4)$$

Этот результат можно оценить, например, по показателю новизны $\delta W_{\Sigma_j}(t^*, \mathbf{SSP}^{c_j}, \mathbf{SSP}^{b_j})$ или достоверности информации, а также по дру-

гим показателям при планируемом j -м управляющем воздействии. Звездочка при t означает, что речь идет о будущем времени. Подробное определение этого показателя будет дано ниже при рассмотрении других правил.

С учетом (1)–(4) поиск оптимального варианта управляющего воздействия сводится к выражению

$$\begin{aligned} & \delta W_{\Sigma_o}(t^*, \mathbf{SSP}^{c_o}, \mathbf{SSP}^{b_o}) = \\ & = \text{extr}_{j \in \Omega} \delta W_{\Sigma_j}(t^*, \mathbf{SSP}^{c_j}, \mathbf{SSP}^{b_j}). \end{aligned} \quad (5)$$

Для этого на основании результатов функционирования РНС 1 в моменты времени t и $t - \Delta t$ блок управления определяет суммарный прирост весов синапсов в сети

$$\begin{aligned} & \delta W_{\Sigma}(t, t - \Delta t) = \\ & = \frac{1}{M^2(\Delta t)} \sum_{m=1}^2 \sum_{i=1}^N \sum_{s=1}^N (w_{mis}(t) - w_{mis}(t - \Delta t)), \end{aligned} \quad (6)$$

где $M(\Delta t)$ – количество обработанных единичных сигналов на временном интервале Δt ; $w_{mis}(\cdot)$ – веса отдельных is -х синапсов нейронов m -го слоя. Аналогично можно определить $\delta W_{\Sigma}(t^*, t^* - \Delta t)$ для предсказанных РНС 2 событий.

В случаях $\delta W_{\Sigma}(t, t - \Delta t) > \delta W_o$ обрабатываемую информацию можно считать новой. Это связано с тем, что при поступлении в нейронную сеть новой информации прирост весов синапсов имеет наибольшую крутизну.

Еще одним не менее важным показателем, по которому можно оценить новизну сигналов, является относительное количество нейронов, возбужденных в сети обработанными сигналами. Если входные сигналы, проходя через РНС на временном интервале Δt , вызывают в среднем за один такт относительное количество нейронов $D(\Delta t)$ меньше заданного значения D_g :

$$D(\Delta t) = \frac{1}{Z(\Delta t)} \sum_{z=1}^{Z(\Delta t)} \frac{K_z}{S_{z-1}} < D_g, \quad (7)$$

то эти сигналы можно считать новыми. В противном случае они известны РНС. В (7) приняты обозначения:

$Z(\Delta t)$ – число тактов сети на заданном интервале времени Δt , $Z(\Delta t) = \Delta t / \delta t$, δt – длительность одного такта;

K_z, S_{z-1} – число возбужденных нейронов на z -м и $(z - 1)$ -м тактах соответственно.

Также возможно использование комплексного показателя

$$F(\Delta t) = \frac{D(\Delta t)}{\Delta W_{\Sigma}(\Delta t)}. \quad (8)$$

Что касается обработки только новостных потоков, то векторы \mathbf{W}_t весов синапсов и состояний \mathbf{X}_t нейронов в используемой РНС выражаются как

$$\begin{aligned} \mathbf{W}_t &= \varphi(\mathbf{W}_{t-1}, \mathbf{X}_{t-1}, \mathbf{S}_{t-1}^a, \mathbf{U}_{t-1}); \\ \mathbf{X}_t &= \psi(\mathbf{W}_{t-1}, \mathbf{X}_{t-1}, \mathbf{S}_{t-1}^a, \mathbf{U}_{t-1}); \mathbf{S}_t^b \subset \mathbf{X}_t, \end{aligned} \quad (9)$$

где \mathbf{S}_t^a , \mathbf{S}_t^b – входные и выходные совокупности единичных импульсов; \mathbf{U}_{t-1} – вектор управления.

Возможность определения $\delta W_{\Sigma}(t, t - \Delta t)$ для РНС 1 позволяет настраивать РНС 2 на выбор данных с заданными свойствами путем пропуска через сеть исходных кодированных потоков.

При решении задач нейрорегуляции различными объектами применимы и другие целевые функции. Например, поиск подходящих управлений возможен на основе стремления найти в РНС одну или несколько областей с наибольшим или наименьшим числом возбужденных нейронов в течение заданного интервала времени. В данном случае речь идет о сигналах, вызываемых из ассоциативной памяти РНС. Отметим, что каждая область возбужденных в РНС нейронов соответствует определенному информационному событию. Наибольшее число возбужденных нейронов в определенной области свидетельствует о тесной связи между обрабатываемой информацией и извлекаемыми из памяти сигналами.

Заметим, что при обработке информации по условиям (2), (3) в памяти нейросети могут быть реализованы различные интеллектуальные операции над сигналами. Основой таких операций является управляемый ассоциативный вызов сигналов из такой памяти. Ранее такие возможности в известных работах не рассматривались.

Алгоритмы восстановления и синтеза новостных потоков

В случаях восстановления прошедших, но не воспринятых РНС 1 новостных потоков, с учетом (9) применимы правила

$$\begin{aligned} \{\mathbf{W}_t, \mathbf{X}_t\} &\rightarrow \{\mathbf{W}_t^*, \mathbf{X}_t^*\} \rightarrow \{\mathbf{W}_t^{*U} = \mathbf{W}_t^* \circ \mathbf{U}_t^*, \mathbf{X}_t^*\}; \\ \mathbf{W}_t^{*U} &= \varphi(\mathbf{W}_{t-1}^{*U}, \mathbf{X}_{t-1}^*); \\ \mathbf{X}_t^* &= \psi(\mathbf{W}_{t-1}^{*U}, \mathbf{X}_{t-1}^*); \mathbf{S}_t^{*b} \subset \mathbf{X}_t^*. \end{aligned} \quad (10)$$

Параметры $\{\mathbf{W}_t, \mathbf{X}_t\}$ без звездочки относятся РНС 1, а обозначенные звездочкой – к РНС 2.

Наличие звездочки у t характеризует обработку новостных потоков РНС 2 в ускоренном времени. Индекс U при \mathbf{W} отражает реализацию

управления ассоциативным взаимодействием сигналов в РНС 2. Обозначение \mathbf{U}_t^* соответствует вектору управления. Отметим, что при восстановлении прошедших потоков необходимо усиливать ассоциативный вызов сигналов в направлении выхода сети, а при прогнозировании, наоборот, в направлении входа сети. Формализованная схема восстановления пропущенных потоков имеет вид

$$\begin{aligned} &\{\mathbf{SSP}_1^a, \mathbf{SSP}_2^a, \dots, \mathbf{SSP}_i^a, \emptyset_{i+1}, \emptyset_{i+2}, \dots, \emptyset_n\} \rightarrow \\ &\rightarrow \{\mathbf{SSP}_1^a, \mathbf{SSP}_2^a, \dots, \mathbf{SSP}_i^a, \mathbf{SSP}_{i+1}^b, \\ &\mathbf{SSP}_{i+2}^b, \dots, \mathbf{SSP}_n^b\}. \end{aligned} \quad (11)$$

Для случаев, когда требуется синтезировать новостной поток по его окончаниям, применима схема

$$\begin{aligned} &\{\mathbf{SSP}_1^a, \mathbf{SSP}_2^a, \emptyset_3, \emptyset_4, \dots, \emptyset_{n-2}, \mathbf{SSP}_{n-1}^a, \mathbf{SSP}_n^a\} \rightarrow \\ &\rightarrow \{\mathbf{SSP}_1^a, \mathbf{SSP}_2^a, \mathbf{SSP}_3^b, \mathbf{SSP}_4^b, \dots, \\ &\mathbf{SSP}_{n-2}^b, \mathbf{SSP}_{n-1}^a, \mathbf{SSP}_n^a\}. \end{aligned} \quad (12)$$

При такой схеме управление ассоциативным вызовом сигналов из памяти РНС 2 сводится к усилению в направлении центра сети.

Помимо этих возможно решение и других творческих задач путем управления РНС. В частности, РНС 1 может решать задачу распознавания воздействия на новостные потоки, например обнаружения фрагментов данных, не соответствующих контексту. Также в РНС 2 возможен более глубокий анализ выявленных аномалий в новостных текстах за счет усиления многократного рекуррентного вызова связанной с ними информации. Отметим, что за счет реализации приоритетных сильных связей в РНС обеспечивается взаимно однозначное соответствие между входами и выходами сетей, что позволяет успешно преобразовывать результаты обработки в соответствующие им исходные сигналы.

Наборы данных, параметры применяемых РНС и результаты моделирования

Наборы данных и параметры применяемых РНС

Для проверки корректности предлагаемых нейросетевых решений использовались различные потоковые данные после предварительной обработки с учетом известных правил [26]. Для исследования нейросетевого управления с ис-

пользованием одноуровневых РНС был сформирован тестовый набор из новостных текстов с сайтов-агрегаторов новостей <http://finam.ru>, <http://rbc.ru>, <http://mail.ru> и статей с сервиса <http://zen.yandex.ru>. Он составил 300 000 текстов без дублирования. Для подготовки наборов данных выполнен полный сбор всех доступных страниц ресурсов с последующим анализом, фильтрацией и индексацией. Все собранные из открытых источников документы были преобразованы из исходного формата (HTML, XML, DOC, PDF, ODT) в формат обычного текста без разметки, служебных областей и рекламных материалов. Они были нормализованы (удалены ненужные служебные символы) и приведены к единой кодовой таблице UTF-8. Обрабатываемым словам из текста (в качестве идентификатора токена) были назначены единичные импульсы в пространстве входных полей слоев РНС. Эксперименты проводились с использованием двухслойных потоковых РНС, содержащих от 1890 до 28 800 нейронов в каждом слое. В этих сетях за счет пространственных сдвигов обрабатываемых СЕИ слои разделялись на логические поля размерами 6×7 , 60×20 , 60×60 нейронов. Размеры логических полей, на которые были разделены слои РНС, определены в зависимости от размеров словаря входных сигналов и способа их кодирования. Количество логических полей в каждом слое определялось с учетом интервала времени, на котором обрабатываемые сигналы должны быть связаны друг с другом, и длительности одного цикла работы сети. Количество нейронов в каждом слое РНС равнялось их количеству в одном логическом поле, умноженному на число этих полей. Непрерывное обучение РНС возможно при скорости подачи сигналов в сеть, не превышающей обратной величины времени невосприимчивости нейронов после возбуждения. Использовались РНС со спиральной и петлевой логическими структурами.

Результаты моделирования

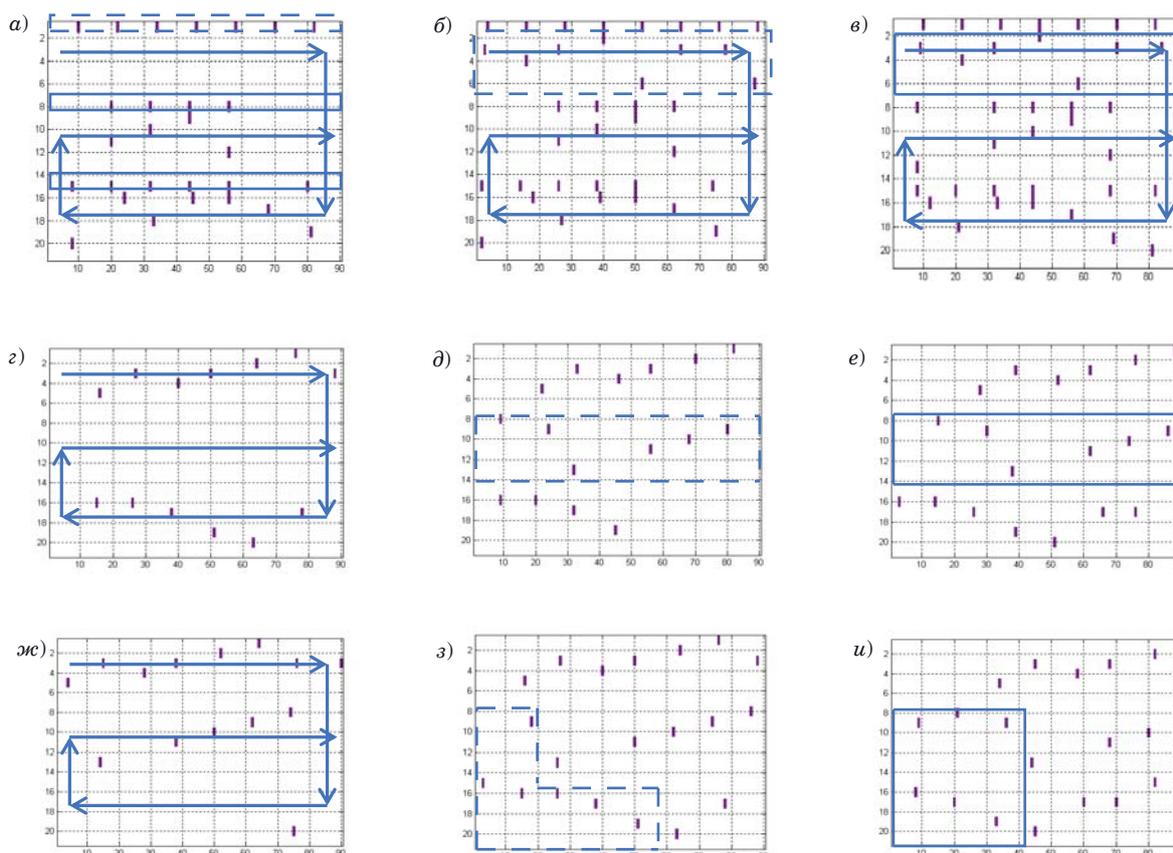
Для подтверждения работоспособности предлагаемой системы было выполнено ассоциативное связывание в РНС 1 ряда действий над источниками информации (в частности, различными запросами) и их реакциями. Затем блок управления осуществлял поиск соответствующих действий с учетом результатов прогнозирования новостных потоков РНС 2. Каждый слой в этих РНС состоял из 3150 скалярных импульсных нейронов. В РНС были реализованы петлевые логические структуры. При этом использовалось кодирование входных сигналов, исключаящее пересечение в пространстве сформированных СЕИ. Каждому обрабатываемому слову в РНС был сопоставлен свой одиночный импульс в пространстве и времени. В каждой РНС обеспе-

чивалось однозначное соответствие между входом и выходом за счет приоритизации сильных связей между нейронами. Вариант работы системы нейроуправления (см. рис. 1) был реализован с использованием одноуровневых РНС. Затем производился поиск соответствующих действий блоком управления с учетом результатов прогнозирования новостных потоков РНС 2. Пример такого прогнозирования показан на рис. 3, а–в.

Стрелками на рис. 3 показаны направления продвижения обработанных СЕИ по слоям. В приведенном примере результаты прогнозирования точно совпали с эталонными значениями. Каждому пространственно связанному одиночному импульсу было присвоено определенное слово. Высокий результат такого прогнозирования обеспечивался исключением пересечений СЕИ, введенных в систему. Аналогичная точность достигалась и при восстановлении пропущенных информационных событий. В случаях наличия пересечений СЕИ точность снижалась.

Пример результатов нейросетевого восстановления прошлых событий перед поиском управляющих решений представлен на рис. 3, г–е. На рис. 3, ж–и представлен пример нейросетевого синтеза событий. Рис. 3, в, е, и соответствуют начальным состояниям первого слоя РНС 2. На рис. 3, д, з полученные результаты отмечены штрихпунктирными линиями. Сигналы, отмеченные сплошными линиями на рис. 3, е, и, соответствуют эталонам. Результаты на рис. 3 соответствуют обработке кодовой последовательности слов *“Two roads diverged in a yellow wood, and sorry I could not travel both and be one traveler, long I stood and looked down one as far as I could to where it bent in the undergrowth”* из работы *The Road Not Taken* Роберта Ли Фроста. Во всех этих экспериментах результаты были получены с точностью 100 % ввиду отсутствия пересечения между СЕИ из-за разреженного кодирования.

С помощью нейросетевой системы была проведена серия экспериментов по выявлению новизны обработанных текстов в сравнении с уже обработанными новостями. В каждом эксперименте новостной поток состоял из двух тематических групп по 75 текстов. Общая длина последовательности составила 150 текстов. Оценивались приросты суммарных весов синапсов при обработке таких последовательностей и ошибки выявления факта новизны обработанного текста. Установлено, что возможности выявления факта новизны обработанных текстов существенно зависят от принятого абсолютного или относительного порога его выявления. Средние ошибки выявления новизны текстов в экспериментах с критерием $\delta W_{\Sigma}(t, t - \Delta t) > \Delta W_0$ составили от 10 до 30 %. При использовании комплексного показателя $F(\Delta)$ (8) и критерия $F(\Delta) < F_0$ ошиб-



■ **Рис. 3.** Примеры состояний первого слоя РНС 2: *a, z, жс* — до начала; *б* — результат прогнозирования; *д* — результат восстановления прошедших событий; *з* — результат синтеза событий; *в, е, u* — эталонное состояние

■ **Fig. 3.** Examples of states of the first layer of recurrent neural networks 2: *a, z, жс* — before the start; *б* — forecasting result; *д* — result of reconstruction of past events; *з* — result of event synthesis; *в, е, u* — reference state

ки были снижены до 1–9 %. Фильтруя тексты во второй РНС на основе новых связей и путем последующего отбора новых блоков текста в исходном новостном потоке, удалось сформировать новостные дайджесты. Функциональность предлагаемой системы определялась как сумма вероятностей получения успешных решений творческих задач, а интеллект оценивался таким же образом, но с учетом веса каждой из задач.

Обсуждение

Говоря о сравнении с существующими методами, отметим следующее. Предлагаемый метод и система, его реализующая, основаны на изобретении [22] по интеллектуальной нейросетевой обработке больших потоков данных. Как и решения [17, 23–25], предлагаемый метод использует пару нейронных сетей. В одном из вариантов метода возможна их параллельная симметричная работа. Однако, в отличие от [17, 22–24], предлагаемая система использует управляемые

многоуровневые РНС с прозрачной логической организацией, с непрерывным обучением, способные решать творческие задачи на верхних уровнях, не прерывая этого обучения. Такие возможности не предусмотрены в известных алгоритмах. Кроме того, помимо пары идентичных РНС, предлагаемая система включает в себя специальный блок управления этими сетями. Во втором варианте предлагаемый метод предусматривает непрерывное обучение РНС 1 и трансферное обучение РНС 2. Трансферное обучение предполагает периодическую передачу информации о состояниях нейронов и синапсов РНС 1 в РНС 2. В нашем случае в РНС 2 дополнительно передаются альтернативные решения управления из блока управления. Передача информации из РНС 1 в РНС 2 необходима для того, чтобы избежать прерывания обучения РНС 1. В РНС 2 на основе этой информации решаются творческие задачи путем управления процессами ассоциативного вызова сигналов из памяти нейронной сети. Возможно решение многих сложных нелинейных задач с использованием одной и той

же нейросетевой системы с непрерывным обучением без ее перестройки. К ним относятся предиктивное управление новостными потоками и другими процессами, их ассоциативный выбор на основе различных свойств, а также контролируемое восстановление и синтез. При предлагаемом нейросетевом управлении с непрерывным обучением возможен поиск соответствующих воздействий на объекты управления с оценкой ожидаемых эффектов. Это достижимо за счет многократного многошагового нейросетевого прогнозирования событий при тех же внешних условиях, но с альтернативными управляющими воздействиями. Это касается и реконструкции событий в условиях неопределенности. Развитие интеллектуальности и функциональности нейросетевой обработки достигается за счет разработки новых решений по управлению нейросетями. Рекуррентные нейронные сети и их элементы наделены новыми свойствами, которые позволяют расширять память нейронных сетей и осуществлять многоуровневую продольную и поперечную ассоциативную обработку сигналов с непрерывным обучением.

В отличие от генеративных моделей, таких как GPT [27, 28], предлагаемые решения не требуют предварительного обучения на размеченных наборах данных. Предлагаемые решения основаны не на правилах преобразования, а на управляемой многоуровневой пространственно-временной ассоциативной обработке. Разработанная интеллектуальная система нейроруавления может связывать реальные потоки событий в пространстве и времени и вырабатывать соответствующие управляющие решения с учетом их и ранее сохраненной информации. Согласно предлагаемому методу можно осуществлять различные интеллектуальные операции во времени и пространстве над сигналами в памяти нейронной сети на основе управления их ассоциативной обработкой. Современные модели GPT могут успешно автоматизировать многие процессы, связанные с текстом (генерацию, машинный перевод, классификацию), но они не могут осознавать свои действия. Это алгоритмы, работающие по строгим правилам на одном уровне иерархии, без оценки новизны и надежности обрабатываемых потоков. Эти алгоритмы не могут обеспечить безмодельное управление сложными нелинейными объектами с оценкой возможных эффектов. Без полноценной многоуровневой ассоциативной обработки сигналов невозможно построение систем с сильным искусственным интеллектом. Полученные авторами результаты позволяют снять ряд ограничений и расширить интеллектуальность и функциональность нейросетевых систем для обработки больших потоков данных, а также обеспечить более высокий уровень доверия к ним. Последнее,

наряду с другими факторами, достигается за счет наделения используемых РНС логически прозрачными одно- и многоуровневыми логическими структурами.

В практическом плане наиболее простым новым вариантом реализации системы нейроруавления (см. рис. 1) является использование двух идентичных потоковых двухслойных РНС с одноуровневыми логическими структурами. Для преодоления вычислительной сложности реализации предлагаемой нейросетевой системы программными средствами предусматривается эмулирование входящих в ее состав РНС специальными программно определяемыми нейрочипами. Это могут быть цифровые нейрочипы или аналоговые микросхемы на основе мемристивных энергоэффективных технологий. Прогресс в создании требуемых нейрочипов уже есть [29]. Это также требует дальнейшей разработки идей формирования соответствующих управляющих решений в РНС на основе анализа обрабатываемой и хранимой информации. Необходима дальнейшая разработка методов управления временем обработки сигналов в РНС. РНС должны иметь возможность успешно обрабатывать события прошлого, настоящего и будущего времени в различных масштабах. Во всех случаях невозможно обойтись без соответствующих архитектурных и алгоритмических решений для построения как систем нейроруавления, используемых РНС, так и ее элементов. Предложенные в статье решения позволяют расширить взгляды на возможные пути построения интеллектуальных систем нейроруавления различными объектами.

К ограничениям предлагаемого метода и системы, его реализующей, можно отнести следующие. Время выработки управляющих решений не должно превышать предельно допустимого значения для конкретных объектов управления. Интеллектуальная система должна быть реализована средствами, позволяющими ей удовлетворять этому требованию. Для полноценного управления необходимо, чтобы в РНС 1 формировалась адекватная модель воспринимаемого процесса при ее непрерывном обучении. Частота считывания информации из РНС 1 в РНС 2 в этой системе должна быть меньше обратной величины времени обработки сигнала в РНС 2. Размеры РНС 1, 2 должны позволять им обрабатывать последовательности совокупностей единичных импульсов заданной длительности. Энергозатраты на обеспечение работы интеллектуальной системы нейроруавления и ее размерности не должны превышать допустимых требований.

Сложность решения задачи программного моделирования предлагаемой интеллектуальной системы нейроруавления на скалярных процессорах прямо пропорциональна квадрату числа

N нейронов в слоях ее нейронных сетей. При использовании графических процессоров она потенциально может быть снижена в N раз. Для полноценной практической реализации предлагаемой интеллектуальной системы нейроруления рекомендуется аппаратная реализация с использованием энергонезависимой мемристивной памяти и энергоэффективных импульсных нейронов.

Заключение

В результате исследования достигнута цель расширения интеллектуальности и функциональности нейросетевых систем управления. При достижении этой цели получены следующие результаты:

- разработана новая архитектура интеллектуальной нейросетевой системы с непрерывным обучением, способная решать существенно расширенный набор творческих задач по обработке и управлению новостными потоками и другими объектами;
- разработаны алгоритмы нейроруления, позволяющие интеллектуально решать новые задачи в нейросетевой памяти;
- сформулированы новые рекомендации по построению перспективных систем нейроруления.

Отличие предлагаемой архитектуры с интеллектуальным нейросетевым ядром от известных решений заключается в новом составе элементов и связей между ними, а также в комплексе реализованных алгоритмов нейроруления. Предложенная архитектура позволяет решать многие творческие задачи с непрерывным обучением без ее перестройки. Предложенный метод позволяет реализовать управляемую многоуровневую нейросетевую обработку на основе новых ассоциативных принципов. Сформулированные новые рекомендации по построению перспективных систем нейроруления позволяют ускорить их разработку и использование на практике. В качестве направлений дальнейших исследований по созданию перспективных интеллектуальных систем нейроруления следует выделить наделение их искусственным мышлением, поиск решений по снижению сложности реализации, а также методов энергоэффективной и малогабаритной реализации.

Финансовая поддержка

Исследование выполнено за счет государственного задания СПб ФИЦ РАН, бюджетная тема FFZF-2022-0005.

Литература

1. **Omatu S., Khalid M., Yusof R.** *Neuro-Control and its Applications, Advances in Industrial Control*. Springer-Verlag New York, LLC, 2011. 255 p. doi:10.1007/978-1-4471-3058-1
2. **Wu B., Wu J., Zhang J., Tang G., Zhao Z.** Adaptive neural control of a 2DOF helicopter with input saturation and time-varying output constraint. *Actuators*, 2022, vol. 11, iss. 11, p. 336. doi:10.3390/act11110336
3. **Jiang B., Li B., Zhou W., Lo L.-Y., Chen C.-K., Wen C.-Y.** Neural network based model predictive control for a quadrotor UAV. *Aerospace*, 2022, vol. 9, iss. 8, p. 460. doi:10.3390/aerospace9080460
4. **Новикова О. А.** Моделирование и прогнозирование динамики событий в новостных лентах на основе простой диффузионной модели. *Cloud of Science*, 2020, т. 7, № 3, с. 619–643. <https://cyberleninka.ru/article/n/modelirovanie-i-prognozirovanie-dinamiki-sobytyiy-v-novostnyh-lentah-na-osnove-prostoy-diffuzionnoy-modeli/viewer> (дата обращения: 04.04.2024).
5. **Kalyan K. S.** A survey of GPT-3 family large language models including ChatGPT and GPT-4. *Natural Language Processing Journal*, 2024, vol. 6, Article 100048. doi:10.1016/j.nlp.2023.100048
6. **McDermott M. B. A., Nestor B., Argaw P., Kohane I.** Event stream GPT: A data pre-processing and modeling library for generative, pre-trained transformers over continuous-time sequences of complex events. <https://arxiv.org/abs/2306.11547> (дата обращения: 04.04.2024).
7. **Szwoch J., Staszko M., Rzepka R., Araki K.** Limitations of large language models in propaganda detection task. *Applied Sciences (Switzerland)*, 2024, vol. 14, no. 10, p. 4330. doi:10.3390/app14104330
8. **von der Malsburg C.** Toward understanding the neural code of the brain. *Biological Cybernetics*, 2021, vol. 115, pp. 439–449. doi:10.1007/s00422-021-00903-8
9. **Haykin S.** *Neural Networks and Learning Machines*. Third ed. Prentice Hall, New York, 2008. 906 p.
10. **Bicanski A., Burgess N.** Neural vector coding in spatial cognition. *Nature Reviews Neuroscience*, 2020, vol. 21, pp. 453–470. doi:10.1038/s41583-020-0336-9
11. **Yamakawa H.** The whole brain architecture approach: Accelerating the development of artificial general intelligence by referring to the brain. *Neural Networks*, 2021, vol. 144, pp. 478–495. doi:10.1016/j.neunet.2021.09.004
12. **Du Y., Wang L., Peng Z., Guo W.** Review-based hierarchical attention cooperative neural networks for recommendation. *Neurocomputing*, 2021, vol. 447, pp. 38–47. doi:10.1016/j.neucom.2021.03.098

13. Saha S., Gan Z., Cheng L., Gao J., Kafka O., Xie X., Li H., Tajdari M., Kim H., Liu W. Hierarchical deep learning neural network (HiDeNN): An artificial intelligence (AI) framework for computational science and engineering. *Computer Methods in Applied Mechanics and Engineering*, 2021, vol. 373, Article 113452. doi:10.1016/j.cma.2020.113452
14. Macpherson T., Matsumoto M., Gomi H., Morimoto J., Uchibe E., Nikida T. Parallel and hierarchical neural mechanisms for adaptive and predictive behavioral control. *Neural Networks*, 2021, vol. 144, pp. 507–521. doi:10.1016/j.neunet.2021.09.009
15. Buhusi C., Oprisan S., Buhusi M. Biological and cognitive frameworks for a mental timeline. *Frontiers in Neuroscience*, 2018, vol. 12, p. 377. doi:10.3389/fnins.2018.00377
16. Raphan T., Dorokhin E., Delamater A. Modeling interval timing by recurrent neural nets. *Frontiers in Integrative Neuroscience*, vol. 13, p. 46. doi:10.3389/fnint.2019.00046
17. Osipov V., Nikiforov V., Zhukova N., Miloserdov D. Urban traffic flows forecasting by recurrent neural networks with spiral structures of layers. *Neural Computing and Applications*, 2020, vol. 32, pp. 14885–14897. doi:10.1007/s00521-020-04843-5
18. Огий О. Г., Осипов В. Ю. Нейросетевое прогнозирование трудового потенциала экипажей рыбопромысловых судов. *Морские интеллектуальные технологии*, 2023, № 4, ч. 1, с. 214–223. doi:10.37220/МИТ.2023.62.4.026
19. Xiao Z., Xing H., Zhao B., Qu R. Deep contrastive representation learning with self-distillation. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2024, vol. 8, iss. 1, pp. 3–15. doi:10.1109/TETCI.2023.3304948
20. Xiao Z., Xing H., Qu R., Feng L., Luo S., Dai P., Zhao B. and Dai Y. Densely knowledge-aware network for multivariate time series classification. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2024, vol. 54, iss. 4, pp. 2192–2204. doi:10.1109/TSMC.2023.3342640
21. Zarchi M., Shahgholi M. A novel information fusion approach using weighted neural networks for intelligent multi-class diagnostics of rotating machinery with unseen working conditions. *Journal of Vibration and Control*, 2023, vol. 29, iss. 23-24, pp. 5545–5562. doi:10.1177/10775463221138172
22. Пат. RU2737227 C1. Способ интеллектуальной многоуровневой обработки информации в нейронной сети, В. Ю. Осипов. № 2020114192; заявл. 20.4.2020; опубл. 26.11.2020, Бюл. № 33.
23. Osipov V., Kuleshov S., Zaytseva A., Levonevskiy D., Miloserdov D. Neural network forecasting of news feeds. *Expert Systems with Applications*, 2021, vol. 169, Article 114521. doi.org/10.1016/j.eswa.2020.114521
24. Осипов В. Ю., Кулешов С. В., Милосердов Д. И., Зайцева А. А., Аксенов А. Ю. Рекуррентные нейронные сети с непрерывным обучением в задачах многофункциональной обработки новостных потоков. *Информатика и автоматизация*, 2022, т. 21, № 6, с. 1145–1168. doi:10.15622/ia.21.6.3
25. Милосердов Д. И. Усовершенствованная система нейросетевого прогнозирования групп временных рядов с непрерывным обучением. *Информационно-управляющие системы*, 2024, № 1, с. 20–30. doi:10.31799/1684-8853-2024-1-20-30, EDN: FRWKWP
26. Ковалев А. Д., Никифоров И. В., Дробинцев П. Д. Автоматизированный подход к семантическому поиску по программной документации на основе алгоритма Doc2Vec. *Информационно-управляющие системы*, 2021, № 1, с. 17–27. doi:10.31799/1684-8853-2021-1-17-27
27. *Open AI GPT-4 Technical Report*. arXiv:2303.08774 [cs.CL]. <https://arxiv.org/abs/2303.08774> (дата обращения: 04.04.2024).
28. Wolfram S. *What is Chat GPT doing and why does it Work?* <https://writings.stephenwolfram.com/2023/02/what-is-chatgpt-doing-and-why-does-it-work/> (дата обращения: 04.04.2024).
29. Yao P., Wu H., Gao B., Tang J., Zhang Q., Zhang W., Yang J. J., Qian H. Fully hardware-implemented memristor convolutional neural network. *Nature*, 2020, vol. 577, pp. 641–646. doi:10.1038/s41586-020-1942-4

UDC 621.396

doi:10.31799/1684-8853-2024-6-35-45

EDN: IDATPB

Intelligent neurocontrol of news streams with continuous learningV. Y. Osipov^a, Dr. Sc., Tech., Professor, orcid.org/0000-0001-5905-4415, osipov_vasily@mail.ruS. V. Kuleshov^a, Dr. Sc., Tech., Professor RAS, orcid.org/0000-0002-8454-5598A. A. Zaytseva^a, PhD, Tech., Senior Researcher, orcid.org/0000-0002-1345-8550D. I. Miloserdov^a, PhD, Tech., Senior Researcher, orcid.org/0000-0002-5312-5531^aSt. Petersburg Federal Research Center of the RAS, 39, 14th Line, 199178, Saint-Petersburg, Russian Federation

Introduction: Neural network control (neurocontrol) of various nonlinear objects is of great theoretical and practical interest. However, the level of intelligence and functionality of known solutions for such management does not largely satisfy the needs of practice. **Purpose:** To develop a method and system of neurocontrol with advanced intelligence and functionality. **Methods:** To achieve the goal, we propose new neural network solutions, aimed at processing news streams with changing laws of behavior and at developing control decisions

under these conditions. **Results:** We propose the architecture of an intelligent neural network system with continuous learning, capable of solving a significantly expanded set of creative problems without its restructuring. In particular, these are the problems of neural network recognition, forecasting, event reconstruction, event synthesis, news flow and other object management. We develop a new method of multi-level neural network information processing in recurrent neural networks with controlled elements. We propose new neural network control algorithms, allowing intelligent solving of problems of news flow neural control with continuous learning. The comparative analysis of the obtained results with known models and methods has shown the effectiveness of the proposed approaches. **Practical relevance:** The proposed architecture enables the solution of many creative problems with continuous learning without restructuring this architecture. With the proposed method it is possible to implement controlled multi-level neural network processing based on new associative principles. With the new recommendations for building promising neural control systems being, it is possible to accelerate their development and use in practice. **Discussion:** We give recommendations for the creation of promising systems of neurocontrol of news flows with continuous learning. Among the areas of further research on the creation of promising intelligent systems of neurocontrol, it is necessary to highlight their endowment with artificial thinking, the search for the solutions to reduce the complexity of implementation, as well as methods of energy-efficient and small-sized implementation.

Keywords – neural network control, intelligence, continuous learning, news flow processing.

For citation: Osipov V. Y., Kuleshov S. V., Zaytseva A. A., Miloserdov D. I. Intelligent neurocontrol of news streams with continuous learning. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2024, no. 6, pp. 35–45 (In Russian). doi:10.31799/1684-8853-2024-6-35-45, EDN: IDATPB

References

- Omatu S., Khalid M., Yusof R. *Neuro-Control and its Applications, Advances in Industrial Control*. Springer-Verlag New York, LLC, 2011. 255 p. doi:10.1007/978-1-4471-3058-1
- Wu B., Wu J., Zhang J., Tang G., Zhao Z. Adaptive neural control of a 2DOF helicopter with input saturation and time-varying output constraint. *Actuators*, 2022, vol. 11, iss. 11, p. 336. doi:10.3390/act11110336
- Jiang B., Li B., Zhou W., Lo L.-Y., Chen C.-K., Wen C.-Y. Neural network based model predictive control for a quadrotor UAV. *Aerospace*, 2022, vol. 9, iss. 8, p. 460. doi:10.3390/aerospace9080460
- Novikova O. A. Modeling and forecasting the dynamics of events in news feeds based on a simple diffusion model. *Cloud of Science*, 2020, vol. 7, no. 3, pp. 619–643. Available at: <https://cyberleninka.ru/article/n/modelirovanie-i-prognozirovanie-dinamiki-sobytyi-v-novostnyh-lentah-na-osnove-prostoy-diffuzionnoy-modeli/viewer> (accessed 04 April 2024) (In Russian).
- Kalyan K. S. A survey of GPT-3 family large language models including ChatGPT and GPT-4. *Natural Language Processing Journal*, 2024, vol. 6, Article 100048. doi:10.1016/j.nlp.2023.100048
- McDermott M. B. A., Nestor B., Argaw P., Kohane I. Event stream GPT: A data pre-processing and modeling library for generative, pre-trained transformers over continuous-time sequences of complex events. Available at: <https://arxiv.org/abs/2306.11547> (accessed 04 April 2024).
- Szwoch J., Staszko M., Rzepka R., Araki K. Limitations of large language models in propaganda detection task. *Applied Sciences (Switzerland)*, 2024, vol. 14, no. 10, p. 4330. doi:10.3390/app141043308.
- von der Malsburg C. Toward understanding the neural code of the brain. *Biological Cybernetics*, 2021, vol. 115, pp. 439–449. doi:10.1007/s00422-021-00903-8
- Haykin S. *Neural Networks and Learning Machines*. Third ed. Prentice Hall, New York, 2008. 906 p.
- Bicanski A., Burgess N. Neural vector coding in spatial cognition. *Nature Reviews Neuroscience*, 2020, vol. 21, pp. 453–470. doi:10.1038/s41583-020-0336-9
- Yamakawa H. The whole brain architecture approach: Accelerating the development of artificial general intelligence by referring to the brain. *Neural Networks*, 2021, vol. 144, pp. 478–495. doi:10.1016/j.neunet.2021.09.004
- Du Y., Wang L., Peng Z., Guo W. Review-based hierarchical attention cooperative neural networks for recommendation. *Neurocomputing*, 2021, vol. 447, pp. 38–47. doi:10.1016/j.neucom.2021.03.098
- Saha S., Gan Z., Cheng L., Gao J., Kafka O., Xie X., Li H., Tajdari M., Kim H., Liu W. Hierarchical deep learning neural network (HiDeNN): An artificial intelligence (AI) framework for computational science and engineering. *Computer Methods in Applied Mechanics and Engineering*, 2021, vol. 373, Article 113452. doi:10.1016/j.cma.2020.113452
- Macpherson T., Matsumoto M., Gomi H., Morimoto J., Uchibe E., Nikida T. Parallel and hierarchical neural mechanisms for adaptive and predictive behavioral control. *Neural Networks*, 2021, vol. 144, pp. 507–521. doi:10.1016/j.neunet.2021.09.009
- Buhusi C., Oprisan S., Buhusi M. Biological and cognitive frameworks for a mental timeline. *Frontiers in Neuroscience*, 2018, vol. 12, p. 377. doi:10.3389/fnins.2018.00377
- Raphan T., Dorokhin E., Delamater A. Modeling interval timing by recurrent neural nets. *Frontiers in Integrative Neuroscience*, vol. 13, p. 46. doi:10.3389/fnint.2019.00046
- Osipov V., Nikiforov V., Zhukova N., Miloserdov D. Urban traffic flows forecasting by recurrent neural networks with spiral structures of layers. *Neural Computing and Applications*, 2020, vol. 32, pp. 14885–14897. doi:10.1007/s00521-020-04843-5
- Ogij O., Osipov V. Neural network forecasting of labor potential of fishing vessel crews. *Marine Intellectual Technologies*, 2023, no. 4, part 1, pp. 214–223 (In Russian). doi: 10.37220/MIT.2023.62.4.026
- Xiao Z., Xing H., Zhao B., Qu R. Deep contrastive representation learning with self-distillation. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2024, vol. 8, iss. 1, pp. 3–15. doi:10.1109/TETCI.2023.3304948
- Xiao Z., Xing H., Qu R., Feng L., Luo S., Dai P., Zhao B. and Dai Y. Densely knowledge-aware network for multivariate time series classification. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2024, vol. 54, iss. 4, pp. 2192–2204. doi:10.1109/TSMC.2023.3342640
- Zarchi M., Shahgholi M. A novel information fusion approach using weighted neural networks for intelligent multi-class diagnostics of rotating machinery with unseen working conditions. *Journal of Vibration and Control*, 2023, vol. 29, iss. 23-24, pp. 5545–5562. doi:10.1177/10775463221138172
- Osipov V. Y. *Sposob intellektual'noy mnogourovnevnoy obrabotki informatsii v neyronnoy seti* [Method for intelligent multi-level information processing in neural network]. Patent no. RU 2737227 C1, 2020.
- Osipov V., Kuleshov S., Zaytseva A., Levonevskiy D., Miloserdov D. Neural network forecasting of news feeds. *Expert systems with applications*, 2021, vol. 169, p. 114521. doi. org/10.1016/j.eswa.2020.114521
- Osipov V., Kuleshov S., Miloserdov D., Zaytseva A., Aksenov A. Recurrent neural networks with continuous learning in problems of news streams multifunctional processing. *Informatics and Automation*, 2022, vol. 21, no. 6, pp. 1145–1168 (In Russian). doi:10.15622/ia.21.6.3
- Miloserdov D. I. Advanced neural network forecasting system with continuous learning for grouped time series. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2024, no. 1, pp. 20–30 (In Russian). doi:10.31799/1684-8853-2024-1-20-30, EDN: FRWKWP
- Kovalev A. D., Nikiforov I. V., Drobintsev P. D. Automated approach to semantic search through software documentation based on Doc2Vec algorithm. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2021, no. 1, pp. 17–27 (In Russian). doi:10.31799/1684-8853-2021-1-17-27
- Open AI GPT-4 Technical Report*. arXiv:2303.08774 [cs.CL]. Available at: <https://arxiv.org/abs/2303.08774> (accessed 04 April 2024).
- Wolfram S. *What is Chat GPT doing and why does it Work?* Available at: <https://writings.stephenwolfram.com/2023/02/what-is-chatgpt-doing-and-why-does-it-work/> (accessed 04 April 2024)
- Yao P., Wu H., Gao B., Tang J., Zhang Q., Zhang W., Yang J. J., Qian H. Fully hardware-implemented memristor convolutional neural network. *Nature*, 2020, vol. 577, pp. 641–646. doi:10.1038/s41586-020-1942-4