

# СОВРЕМЕННЫЕ ПОДХОДЫ К УПРАВЛЕНИЮ ИНФОРМАЦИОННЫМИ СИСТЕМАМИ: СЕМИОТИКА, ТРЕКИНГ И НЕЙРОННЫЕ СЕТИ

## MODERN APPROACHES TO INFORMATION SYSTEMS MANAGEMENT: SEMIOTICS, TRACKING AND NEURAL NETWORKS IN SYNERGY

A. Batanov  
A. Ruslyakov  
V. Poletaev

*Summary.* The research presented in this paper focuses on examining the synergy of neural networks, semiotics, and tracking systems in information systems. The main attention is paid to expanding the analysis of tracking data, as well as the interaction and influence of neural networks on tracking systems, with the goal of developing more intelligent and adaptive information management systems. As an illustrative example, the application of a neural network for recognizing vehicle license plates is analyzed. The results of the study consider the synergy of semiotics and tracking technologies, and also outline prospects for the development of more effective information systems capable of analyzing the surrounding world and perceiving its semiotic context.

*Keywords:* neural networks, semiotics, tracking systems, intelligent systems.

**Батанов Арсений Олегович**

Старший преподаватель, МИРЭА — Российский  
технологический университет  
batanov@mirea.ru

**Русляков Алексей Александрович**

Ассистент, МИРЭА — Российский  
технологический университет  
ruslyakov@mirea.ru

**Полетаев Владислав Александрович**

МИРЭА — Российский технологический университет  
whatisslove7@gmail.com

*Аннотация.* Исследование, представленное в данной работе, направлено на рассмотрение синергии нейронных сетей, семиотики и систем трекинга в информационных системах. Основное внимание уделяется расширению анализа данных трекинга, а также взаимодействию и влиянию нейронных сетей на системы трекинга, с целью разработки более интеллектуальных и адаптивных систем управления информацией. В качестве иллюстративного примера анализируется применение нейронной сети для распознавания автомобильных номеров. Результаты работы рассматривают синергию семиотики и технологий трекинга, а также обозначают перспективы для развития более эффективных информационных систем, способных анализировать окружающий мир и воспринимать его семиотический контекст.

*Ключевые слова:* нейронные сети, семиотика, системы трекинга, интеллектуальные системы.

### Введение

Современные информационные технологии являются катализаторами инноваций, привнося в нашу повседневную жизнь эффективные средства обработки и анализа данных. В этом контексте взаимодействие между семиотикой, трекингом и нейронными сетями становится одним из факторов в формировании интеллектуальных информационных систем. Настоящая статья предлагает анализ и обоснование этой связи, рассматривая их совместные возможности в контексте современных вызовов и перспектив развития.

### Цель работы

Целью исследования является анализ синергии семиотики, трекинга и нейронных сетей в контексте современных информационных систем. Исследование направлено на выявление взаимодействия этих ключевых компонентов для создания более интеллектуальных и адаптивных систем управления информацией.

Рассматриваемый пример применения нейронных сетей для анализа китайских автомобильных номеров, направлен на иллюстрацию эффективности синергии семиотики, трекинга и нейронных сетей в распознавании и обработке информации, что может иметь важное практическое применение в области управления и безопасности, демонстрируя принципы совокупного воздействия перечисленных компонентов в реальных сценариях.

### Интеграция семиотики, трекинга и нейронных сетей в современных информационных системах

Связь между семиотикой, трекингом и нейронными сетями в современных информационных системах представляет собой интегративное взаимодействие, оправданное не только синергией этих компонентов, но и их взаимной поддержкой, обогащающей способы восприятия, анализа и управления информацией. Обоснование этой связи лежит в следующих ключевых аспектах:

— Семиотика предоставляет каркас для организации знаний и структурирования информации

с использованием знаков и символов. Аспекты семиотики способствуют созданию семантических связей между данными, что значительно улучшает их понимание в контексте.

- Технологии трекинга обеспечивают системам способность отслеживать объекты в пространстве, что расширяет возможности визуального восприятия. Использование трекинга дополняет семиотику, позволяя системам динамически взаимодействовать с изменяющимся окружением.
- Нейронные сети обеспечивают автоматизированную обработку данных, что значительно улучшает эффективность анализа и классификации информации. Способность нейронных сетей обучаться на основе опыта дополняет семиотику и трекинг, создавая адаптивные системы.

Эффективное взаимодействие между семиотикой, трекингом и нейронными сетями создает интеллектуальное информационное окружение, способное не только воспринимать данные, но и интерпретировать их, анализировать и адаптироваться к изменениям.

Авторами настоящей статьи предложены к рассмотрению вопросы связи между семиотикой, трекингом и нейронными сетями, предоставляя взгляд на эффективное использование этих компонентов для развития интеллектуальных информационных систем. Например, начиная от оптимизации безопасности дорожного движения до динамического адаптивного управления данными в режиме реального времени. Исследование анализирует, как интеграция этих технологий формирует интеллектуальное будущее цифровой среды, на примере распознавания автомобильных номеров.

Распознавание автомобильных номеров (ANPR) иллюстрирует современные вызовы и возможности в информационных технологиях, решая проблемы безопасности на дорогах, оптимизации парковок и управления транспортными потоками. Интеграция с искусственным интеллектом демонстрирует технологический прогресс и создает основу для интеллектуального развития информационных систем [8].

#### Роль семиотики в синергии с технологиями трекинга в информационных системах

Роль семиотики в синергии с технологиями трекинга в информационных системах является ключевым аспектом, обеспечивающим эффективное взаимодействие между символическими концепциями и механизмами отслеживания объектов. Семиотика, как наука о знаках и их интерпретации, играет важную роль в структурировании и восприятии информации в системах управления [9].

Таким образом, семиотика предоставляет теоретическую основу для понимания того, как символы и знаки структурируют информацию в системах управления, а взаимодействие с технологиями трекинга обеспечивает практическую реализацию этих концепций в информационных системах.

Семиотика внедряет смысл в трекинговые данные, превращая их из абстрактных информационных потоков в понятные знаки и символы. Это облегчает восприятие и понимание динамики перемещения объектов, отслеживаемых системами трекинга.

Кроме того, семиотика способствует созданию семиотического контекста, в рамках которого данные трекинга приобретают дополнительные смысловые значения [10]. Это повышает глубину анализа и помогает в понимании взаимосвязей между отслеживаемыми объектами и их окружением.

Трекинг в информационных системах играет существенную роль в сборе и анализе данных. Такие технологии обеспечивают отслеживание объектов, их перемещений и взаимодействий в реальном времени. В контексте семиотики трекинг преобразует абстрактные данные в смысловую информацию, которая становится ключевым элементом для понимания процессов и оптимизации систем управления. Интеграция трекинга в область семиотики расширяет возможности не только по сбору объективных данных, но и по их интерпретации через призму знаков и символов, усиливая тем самым аналитический потенциал системы. Такая синергия снабжает организации более точными и значимыми данными, способствуя повышению эффективности и адаптивности информационных систем.

В результате синергии семиотики и трекинговых технологий информационные системы становятся более эффективными, адаптивными и способными предоставлять более детализированную и ценную информацию для принятия управленческих решений.

Интеграция нейронных сетей в контекст семиотики и технологий трекинга представляет собой важный этап в совершенствовании информационных систем. Нейронные сети способны обрабатывать сложные данные, выявлять паттерны и извлекать смысл из информации [11], что делает их мощным инструментом для анализа данных, собранных трекинговыми технологиями. В контексте семиотики нейронные сети могут использоваться для распознавания и интерпретации семиотических элементов в данных. Это позволяет системе не только отслеживать объекты, но и понимать их семантику и взаимосвязи, обеспечивая лучшую интегративность в различные среды. В контексте распознавания автомобильных номеров это помогает достичь применимости системы

в различных странах, с учётом их особенностей, например, распознавая не только цифры, но и специальные символы. Такая интеграция создает интеллектуальные информационные системы, способные автоматически адаптироваться к изменяющейся среде, выявлять новые семиотические закономерности и предоставлять более глубокий анализ. Этот подход открывает новые перспективы для создания более эффективных и адаптивных систем управления информацией.

### Разработка и обучение нейронной сети для распознавания автомобильных номеров

Большинство работ по использованию свёрточных нейронных сетей (CNN) посвящено задачам детекции или классификации [4–6]. В то же время, рассматриваемая сегодня задача, а именно задача распознавания последовательностей на основе изображений (image-based sequence recognition), имеет ряд серьезных отличий от классических задач для свёрточных нейросетей.

В отличие от общей задачи распознавания объектов, распознавание последовательностей требует предсказания сразу нескольких меток (labels) вместо предсказания лишь одного значения. Другим свойством задачи предсказания последовательности является сильное отличие этих самых последовательностей по длине. Например, слова могут состоять как из одной буквы (например, местоимение «я»), так сразу и из 20 символов (например, «гипертрофированность»). Таким образом, наиболее популярные модели на основе свёрток не могут быть применимы для решения данной задачи — модели CNN оперируют со входами и выходами фиксированных размеров и неспособны предсказать последовательность переменной длины.

Решением проблемы работы с последовательностями может стать использование моделей рекуррентных нейронных сетей (RNN) [12]. Плюсом RNN является то, что такому классу сетей не нужна позиция каждого элемента последовательности как во время тренировки, так и во время тестирования. Однако для применения рекуррентных нейросетей необходим этап предварительной обработки, конвертирующий исходное изображение в последовательность признаков, для чего можно использовать CNN [1].

Архитектура свёрточно-рекуррентной нейронной сети (CRNN) строится на трёх элементах:

- свёрточная нейросеть
- рекуррентная нейросеть
- слой транскрипции

В начале CRNN используются свёрточные слои для преобразования исходного изображения в последовательность признаков. После свёрточных слоёв исполь-

зуется рекуррентная сеть для предсказания на основе признаков, полученных на предыдущем шаге. Для преобразования предсказаний RNN в последовательность labels используется слой транскрипции поверх слоёв RNN и CNN. Данную задачу можно рассматривать как предсказание отдельного символа для каждой позиции, что позволяет обучить CRNN при помощи одной функции потерь, несмотря на ее «составную» архитектуру из двух различных архитектур.

Свёрточная нейронная сеть — это один из видов популярных нейросетей, которые нашли применение в области обработки изображений [2]. Она основывается на идее переиспользования частей нейронной сети для обработки небольших участков входного изображения. Каждый слой такой архитектуры извлекает информацию из фиксированного кусочка входа, что позволяет эффективно распознавать простые элементы, такие как нос, глаз, ухо и т.д. [3]

В качестве свёрточной нейросети используется комбинация слоёв субдискретизации (max pooling) и слоёв свертков (convolutional layer) без использования полносвязных слоёв (fully-connected layers). Отказ от fully-connected layers позволяет существенно сократить количество параметров в сети, что влечёт за собой увеличение скорости обучения и inference, а также уменьшение занимаемого итоговой моделью места. Такая комбинация используется для извлечения признаков объекта из входного изображения. Перед передачей в сеть все изображения необходимо масштабировать до одинаковой высоты. Затем последовательность векторов признаков извлекается из карт объектов, созданных комбинацией свёрточных слоёв, который является входными данными для рекуррентных слоёв. В частности, каждый вектор признаков последовательности объектов генерируется слева направо на картах объектов по столбцам. Это означает, что  $i$ -й вектор признаков является объединением  $i$ -х столбцов всех карт. Ширина каждого столбца в настройках фиксирована как один пиксель.

Поскольку слои свёртки и субдискретизации работают с локальными областями, они обладают свойством translation invariance. Следовательно, каждый столбец карты признаков соответствует прямоугольной области исходного изображения (называемой receptive field — полем восприятия), и такие прямоугольные области расположены в том же порядке, что и соответствующие им столбцы на картах объектов слева направо.

Поверх слоёв свертки построена глубокая двунаправленная рекуррентная нейронная сеть. Рекуррентные слои предсказывают вероятностное распределение  $y_t$  для каждого признака  $x_t$  из последовательности признаков  $X = x_1, \dots, x_T$ .

Традиционная архитектура RNN имеет скрытый слой между входным и выходным слоем [7]. Каждый раз, когда он получает признак  $xt$  в последовательности, он обновляет свое внутреннее состояние  $ht$  с помощью нелинейной функции, которая принимает как текущий вход  $xt$ , так и прошлое состояние  $ht-1$  в качестве входных данных:  $ht = g(xt, ht-1)$ . В качестве нелинейной функции  $g$  обычно берется гиперболический тангенс:  $ht = \tanh(xt, ht-1)$ . Затем выполняется предсказание  $yt$  на основе  $ht$ . Таким образом, прошлые контексты улавливаются и используются для предсказания.

Однако, базовая версия RNN страдает от проблемы vanishing gradients — из-за последовательного применения RNN cells в глубокой RNN при обучении методом обратного распространения ошибки градиент сети может быть ничтожно мал, что приведет к остановке обучения нейронной сети. Для решения данной проблемы базовая версия RNN была модифицирована до LSTM — Long-short term-memory. LSTM состоит из ячейки памяти и трех элементов, а именно элементов ввода, вывода и забывания. Концептуально ячейка памяти хранит прошлые контексты, а элементы ввода и вывода позволяют ячейке сохранять контексты в течение длительного периода времени. Тем временем память в ячейке может быть очищена с помощью ячейки забывания. Специальная конструкция LSTM позволяет фиксировать долгосрочные зависимости, которые часто встречаются в последовательностях, распознанных в изображениях.

LSTM является «направленной» сетью — она может использовать только прошедший контекст. Однако, в основанных на изображениях последовательностях контекст, полученный в обоих направлениях, может быть полезен. Поэтому в данной работе при помощи «склеивания» двух LSTM, имеющих разные направления, получается двунаправленная LSTM.

Транскрипция — это процесс преобразования предсказаний для каждого кадра, сделанных RNN, в последовательность меток. Математически транскрипция заключается в нахождении последовательности меток с наибольшей вероятностью, обусловленной предсказаниями для каждого признака. На практике существует два способа транскрипции, а именно транскрипция без лексики и транскрипция на основе лексики. Лексикон — это набор последовательностей меток, для которых предсказание является ограничением, например, словарь всех возможных символов, что могут встретиться при распознавании. В режиме без использования лексики прогнозы делаются без использования какой-либо лексики. В режиме на основе лексики прогнозы делаются путем выбора последовательности меток, которая имеет наибольшую вероятность.

Демонстрация точности и эффективности разработанной нейронной сети.

**Демонстрация точности и эффективности разработанной нейронной сети**

- В качестве метрик в нашем случае будем измерять:
1. Char Error Rate (CER) — число посимвольных ошибок
  2. Accuracy — доля правильно распознанных номеров

$$CharErrorRate = \frac{S + D + I}{N}$$

где  $S$  — количество замен символов  
 $D$  — количество удалений символов  
 $I$  — количество вставок новых символов  
 $N$  — общее количество символов

Тестирование будет проходить на специальном тестовом датасете, в котором нет пересекающихся с тренировочной выборкой примеров

Таблица 1.

Итоговые метрики

Метрика	Показатель метрики
Accuracy	0.9844
Char Error Rate	0.00263

В данном датасете в качестве символов использовались три типа знаков — иероглифы, цифры и латинские буквы.

Произведен анализ ошибок модели по знакам отдельно каждого класса.

**Иероглифы**

Самый частый иероглиф — «皖» — встречается 9491 раз, из которых модель распознала верно в 9488 случаях (3 раза модель спутала данный символ, причем с 3 разными иероглифами)

Второй по частоте иероглиф — «苏» — встречается 212 раз, из которых 209 раз модель распознала его верно (из 3 ошибок при распознавании 2 раз модель перепутала этот иероглиф с самым популярным — «皖»)

Третий по частоте иероглиф — «浙» — встречался 83 раза, из которых был верно распознан 82 раза (единственная ошибка была, когда модель перепутала этот иероглиф с самым часто встречающимся).

Остальные символы встречаются гораздо реже — некоторые 15–20 раз, но большинство в основном встречаются куда реже — в данном случае есть моменты, когда модель даже при малом количестве при обучении таких символов распознавала все символы безупречно, так и когда отличала очень плохо.

Рассмотрим такие примеры:

— «»

1. Встретился 4 раза.
2. Верно распознан 4 раза.

— «».

1. Встретился 4 раза.
2. Верно распознан 4 раза.

— «»

1. Встретился 3 раза.
2. Верно распознан 1 раз.

Большинство ошибок модели связано с редко встречающимися символами, которые по начертанию имеют схожесть с другими символами, находящимися в датасете. Возможно, первые 2 символа из верхних 3 пунктов имеют относительно уникальное начертание, позволяющее модели не путать их с другими символами, в то время как третий иероглиф может быть похож на некие другие.

### Цифры и латинские символы

Самая частая буква — А — была встречена 9766 раз, при этом распознана верно 9759 раз, 7 ошибочно (пару раз даже каким-то образом перепутал с цифрой).

Все цифры встречаются примерно одинаковое количество раз (кроме цифры 4 — она встречается в 2 с лишним раза реже, чем все остальные) — среди +- 3300 повторений каждой цифры число ошибочных распознаваний равняется 12.

### Анализ ошибок модели

Для дальнейшего анализа будем использовать тестовый датасет на 10\_000 изображений — он не пересекается ни с валидационным, ни с тренировочным датасетами.

Сначала построим количество ошибок в номерах (в скольких номерах 1 ошибка, 2 ошибки и так до 7 ошибок — когда модель ошиблась в предсказании во всех позициях).

Итак, по графику видно, что модель:

- Совершила 1 ошибку в 404 номерах;
- Совершила 2 ошибки в 41 номере;
- Совершила 3 ошибки в 3 номерах;
- Совершила 5 ошибок в 2 номерах;
- Ошибок в 4, 6 или 7 позиций совершено не было.

Общий итог, исходя из анализа знаков с наибольшими ошибками в предсказаниях:

1. Иероглиф, несмотря на самое сложное написание и явное отличие от остальных символов, даже в крайне сложных случаях распознан верно — кроме одного знака, где просто нет трети иероглифа
2. Некоторые знаки модель могла спутать из-за не самой удачной фотографии самого номера — ночное освещение + не прямая проекция при фотографии, а смещенная.
3. Дополнения по иероглифам: такое хорошее различие иероглифов связано с тем, что в 4 из 6 номеров встречается самый частый иероглиф среди всех знаков (из 9999 знаков он встречается в 9700+), а также из-за крайней непохожести между собой и сложности написания — модель могла выучить некоторые паттерны и впоследствии именно из-за сложности так хорошо различать первый символ. Также в одном из знаков была замечена некорректная по длине предсказанная последовательность — вместо необходимого количества знаков моделью был предсказан на один меньше.

1. Validation loss минимальный на конец 20 эпохи, train loss также минимальный на конец 20 эпохи

Distribution of the number of errors in the numbers




Рис. 1. График распределения количества ошибок в числах




Рис. 2. График обучения модели

2. Не было момента, когда val loss рос, а train loss уменьшался — модель не недообучилась
3. Не было момента, когда val loss падал, а train loss рос — модель не переобучилась

Также на отсутствие переобучения модели указывает отсутствие резких скачков loss-а, после которых бы потери не начинали падать

Предложения по улучшению модели

1. Аугментация данных — при помощи поворотов, затемнений областей или прочих изменений изображений, содержащих в себе редкие иероглифы, можно расширить датасет и улучшить способность модели.
2. Поиск новых данных — при помощи данного приёма, модель сможет лучше адаптироваться к различным условиям среды.
3. Более длительное обучение модели — по графикам потерь можно увидеть, что вплоть до последней эпохи validation loss и train loss уменьшались, что сигнализирует об отсутствии переобучения модели. Таким образом, продолжая обучать модель после 20 эпохи, можно добиться повышения accuracy и падения CharErrorRate.
4. Ансамбль из нескольких моделей — в качестве идеи можно рассмотреть предложение ребята брали 3 модели, по-разному инициализировать веса и уже впоследствии объединять предсказания модели по каждой позиции номера — возможно, в итоге не будет такой проблемы, что модель предсказывала не все позиции или наоборот, предсказывала больше позиций, чем есть на самом деле.

**Заключение**

Статья посвящена некоторым вопросам интеграции семиотики, технологий трекинга и нейронных сетей в управлении информационными системами. Основной акцент сделан на расширение возможностей анализа данных трекинга и взаимодействие этих компонентов для создания более интеллектуальных и адаптивных систем. Авторы подчеркивают, что семиотика обеспечивает теоретическую основу для структурирования информации, трекинг расширяет возможности визуального восприятия, а нейронные сети улучшают эффективность анализа и классификации данных.

На примере применения нейронных сетей для распознавания китайских автомобильных иллюстрируется практическое применение синергии трех компонентов для решения реальных задач. Авторами показано, как совместное использование семиотики, трекинга и нейронных сетей позволяет системам не только собирать и анализировать данные, но и понимать их семантический контекст.

Результаты работы подчеркивают значимость синергии этих подходов для создания эффективных информационных систем, способных анализировать окружающий мир и воспринимать его семиотический контекст. Это открывает новые перспективы для развития интеллектуальных и адаптивных систем управления информацией, которые могут применяться в различных областях, от безопасности дорожного движения до оптимизации управления данными.

## ЛИТЕРАТУРА

1. Винокуров И.В. Использование свёрточной нейронной сети для распознавания элементов текста на отсканированных изображениях плохого качества // Программные системы: теория и приложения. 2022. Т. 13. №3(54). С. 29–43.
2. Об нейронных сетях и виды [Электронный ресурс] — Режим доступа: <https://sky.pro/media/neyronnye-seti/> (дата последнего обращения: 01.12.2023)
3. Жмуровский, К.В. Нейронный сети и как они работают: основные виды и этапы разработки нейронных сетей / К.В. Жмуровский // Современные тенденции и инновации в науке и производстве : Материалы XII Международной научно-практической конференции, Междуреченск, 26 апреля 2023 года / Редколлегия: Т.Н. Гвоздкова (отв. редактор), С.О. Марков [и др.]. — Междуреченск: Кузбасский государственный технический университет имени Т.Ф. Горбачева, 2023. — С. 417.1–417.3. — EDN ERDBKW.
4. Введение в сверточные нейронные сети. [Электронный ресурс] — Режим доступа: <https://machinelearningmastery.ru/an-introduction-to-convolutional-neural-networks-eb0b60b58fd7/> (дата последнего обращения: 05.12.2023).
5. Сверточная нейронная сеть: как устроена, архитектуры и параметры — использование сверточных нейросетей. [Электронный ресурс] — Режим доступа: <https://practicum.yandex.ru/blog/svertochnye-neyronnye-seti/> (дата последнего обращения: 06.12.2023)
6. Руководство для начинающих по сверточным нейронным сетям (CNN): пошаговое объяснение. [Электронный ресурс] — Режим доступа: <https://www.devzv.com/ru/beginners-guide-to-convolutional-neural-networks.html> (дата последнего обращения: 10.12.2023)
7. Recurrent Neural Network (RNN) architecture explained in detail. [Электронный ресурс] — Режим доступа: <https://towardsmachinelearning.org/recurrent-neural-network-architecture-explained-in-detail> (дата последнего обращения: 11.12.2023).
8. Сырецкий Г.А., Радионов А.И. Искусственный интеллект и интеллектуальные информационные системы: современное состояние // Интерэкспо Гео-Сибирь. 2006. №. URL: <https://cyberleninka.ru/article/n/iskusstvennyy-intellekt-i-intellektualnye-informatsionnye-sistemy-sovremennoe-sostoyanie> (дата обращения: 14.12.2023).
9. Цветков Виктор Яковлевич Информационное семиотическое управление // Современные технологии управления. 2017. №4 (76). URL: <https://cyberleninka.ru/article/n/informatsionnoe-semioticheskoe-upravlenie> (дата обращения: 09.12.2023).
10. Цветков Виктор Яковлевич. Семиотика информационного поля // Образовательные ресурсы и технологии. 2022. № 2 (39). С. 83–89. DOI: 10.21777/2500-2112-2022-2-83-89.
11. Дудинов И.О. Применение нейронной сети в задаче нахождения паттернов в последовательностях сигналов потребления электрической мощности // Материалы МСНК «Студенческий научный форум 2024». — 2023. — № 14. — С. 87–89
12. Применение сверточных нейронных сетей для задач NLP // Хабр. 10 апреля 2018. Режим доступа: <https://habr.com/ru/companies/ods/articles/353060/> (дата обращения: 12.12.2023)
13. Evangelos Kourdis (2022). The Routledge Handbook of Translation and Methodology (1st ed.). Routledge. Chapter: Semiotics 10.4324/9781315158945-12\
14. Serhii Yevseiev, Maksym Tolkachov, Darshan Shetty, Vladyslav Khvostenko, Anna Strelnikova, Stanislav Milevskiy, Sergii Golovashych The concept of building security of the network with elements of the semiotic approach // SR. 2023. №1 (64). URL: <https://cyberleninka.ru/article/n/the-concept-of-building-security-of-the-network-with-elements-of-the-semiotic-approach> (дата обращения: 13.12.2023).
15. Albarzan, N. (2023). The semiotic use of emojis in marketing communication (Doctoral dissertation, Duquesne University). Retrieved from <https://dsc.duq.edu/etd/2136>
16. Liu, Kecheng. (2000). Semiotics in Information Systems Engineering. 10.1017/CB09780511543364.

© Батанов Арсений Олегович (batanov@mirea.ru); Русляков Алексей Александрович (ruslyakov@mirea.ru);

Полетаев Владислав Александрович (whatislove7@gmail.com)

Журнал «Современная наука: актуальные проблемы теории и практики»