

**ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ,
АВТОМАТИКА И ТЕЛЕКОММУНИКАЦИИ**

УДК 004.4 + 06

DOI 10.46973/0201-727X_2026_1_20

*И. О. Алымов***АНАЛИЗ ПАРАМЕТРОВ БАЗОВЫХ АРХИТЕКТУР НЕЙРОННЫХ СЕТЕЙ
В ТРАНСПОРТНЫХ СИСТЕМАХ УПРАВЛЕНИЯ**

Аннотация. Рассмотрен подход к повышению эффективности автоматизированных систем управления движением поездов путем интеграции нейросетевого модуля-ассистента в контур подсистемы автоматического блокирующего логического контроля (АБЛК). Выполнен анализ применимости различных архитектур нейронных сетей для решения задач интеллектуальной поддержки поездного диспетчера, включая многослойный перцептрон (*MLP*) и рекуррентные сети с долгой краткосрочной памятью (*LSTM*). На основе имитационной модели диспетчерского участка, включающего три станции, проведена количественная оценка размерности входного вектора состояния и вычислительной сложности рассматриваемых архитектур. Представлены формулы расчета количества обучаемых параметров, выполнено сравнение *MLP* и *LSTM* при одинаковых параметрах модели. Результаты сравнительного анализа демонстрируют преимущество *LSTM* с точки зрения вычислительной эффективности при сохранении структуры временных зависимостей. На основании полученных результатов обоснован выбор *LSTM* в качестве базовой архитектуры для построения интеллектуального ассистента, работающего в едином контуре с подсистемой АБЛК.

Ключевые слова: автоматизированные системы управления движением поездов, диспетчерская централизация, интеллектуальные системы поддержки принятия решений, активный блокирующий логический контроль, нейронные сети, *LSTM*, многослойный перцептрон (*MLP*).

Для цитирования: Алымов, И. О. Анализ параметров базовых архитектур нейронных сетей в транспортных системах управления / И. О. Алымов // Вестник Ростовского государственного университета путей сообщения. – 2026. – № 1. – С. 20–27. – DOI 10.46973/0201-727X_2026_1_20.

Введение

Современные автоматизированные системы управления движением поездов, такие как системы диспетчерской централизации (ДЦ), являются критически важным элементом для обеспечения перевозочного процесса. Рост интенсивности перевозочного процесса закономерно приводит к увеличению психоэмоциональной нагрузки на оперативный персонал, повышая риски, связанные с «человеческим фактором» [1, 2]. Это особенно актуально в случаях возникновения сложной поездной обстановки или нештатных ситуаций в работе устройств железнодорожной автоматики и телемеханики (ЖАТ).

Эффективным технологическим решением данной проблемы стало внедрение в состав современных систем ДЦ подсистемы автоматического блокирующего логического контроля (АБЛК). Как отмечено в работе [3], АБЛК представляет собой программный модуль, выполняющий функции активного контроля и блокировки. Его основное назначение заключается в том, чтобы в режиме реального времени выявлять логические несоответствия в работе устройств электрической централизации (ЭЦ) и автоблокировки (АБ), а также блокировать некорректные управляющие команды, формируемые на АРМ ДНЦ. Функционал АБЛК включает: блокировку выполнения недопустимых или требующих подтверждения команд, контроль принципа единоначалия, логическое обнаружение несоответствий зависимостей ЭЦ и АБ, протоколирование всех событий и формирование предупреждений для персонала. АБЛК реализует функцию детерминированного логического барьера, программно исключая возможность исполнения управляющих команд, которые не соответствуют формализованным условиям безопасности и технологическим зависимостям устройств ЭЦ и АБ. Успешный опыт эксплуатации АБЛК, в частности на полигоне Сочи – Адлер – Красная Поляна Северо-Кавказской железной дороги в период Олимпиады 2014 года, подтвердил его высокую эффективность.

Основная часть

Разрабатываемая нейросетевая модель представляет собой интеллектуальный ассистент поездного диспетчера (ДНЦ), работающий в едином контуре с подсистемой АБЛК. Ее основная задача – анализировать текущую оперативную обстановку на диспетчерском участке и предлагать диспетчеру оптимальные последовательности команд, которые заранее гарантированно проходят проверки АБЛК, тем самым повышая маневренность и гибкость управления без снижения уровня безопасности.

Общую логику работы системы можно представить как слаженное взаимодействие двух компонентов: нейросети-ассистента (прогнозирующий и оптимизирующий блок) и подсистемы АБЛК (верифицирующий и защитный блок). Нейросеть непрерывно анализирует тот же поток дискретных сигналов о состоянии элементов ЖАТ (рельсовых цепей, стрелок, светофоров), что и АБЛК, формируя целостную ситуационную модель. На ее основе генерируются рекомендации – наиболее рациональные последовательности действий. Ключевой этап – обязательная верификация каждой предложенной командной последовательности алгоритмами АБЛК. Только варианты, получившие формальное подтверждение на соответствие всем зависимостям и правилам безопасности, передаются поездному диспетчеру для выбора и исполнения.

Таким образом, нейросеть не отменяет и не обходит блокировки АБЛК, а предвосхищает успешный результат, экономя время диспетчера на рутинный перебор и проверку вариантов. Это превращает АБЛК из инструмента пассивного контроля в элемент интеллектуальной системы, способствующей быстрому нахождению правильных и безопасных решений.

Определение оптимальной архитектуры нейронной сети является ключевым этапом проектирования интеллектуального модуля-ассистента. Выбор должен учитывать специфику входных данных, характер решаемой задачи, а также требования к устойчивости работы, достоверности результатов и интерпретируемости решений, предъявляемые к интеллектуальному модулю в контуре взаимодействия с АБЛК.

На первых этапах разработки нейросетевого модуля подсистемы АБЛК входными данными для модуля служат исключительно дискретные сигналы о состоянии объектов систем ЖАТ на диспетчерском участке: занятость рельсовых цепей, положение стрелок, показания светофоров. Этот набор представляет собой структурированный вектор высокой размерности – на крупном диспетчерском участке количество таких сигналов может достигать нескольких сотен тысяч, каждый из которых кодируется как отдельный признак. Данный вектор является цифровым «снимком» диспетчерского участка: он с высокой детализацией фиксирует состояние всех объектов ЖАТ в текущий момент времени. С точки зрения задачи нейросеть должна оценить этот «снимок» и предложить одну или несколько допустимых и целесообразных управляющих команд. Рассмотрим два базовых класса архитектур.

Многослойный перцептрон (*MLP*). Данная классическая архитектура, состоящая из последовательности полносвязных слоёв, обрабатывает единичный входной вектор. Структурная схема многослойного перцептрона представлена на рис. 1.




Рис. 1. Структурная схема многослойного перцептрона

Ключевое преимущество *MLP* – способность выявлять сложные нелинейные зависимости между любыми сигналами в фиксированный момент времени, что хорошо подходит для задач классификации «по состоянию на сейчас». *MLP* проста для реализации и обеспечивает высокую скорость вывода, будучи эффективной для воспроизведения формальной логики, подобной алгоритмам АБЛК.

Однако её фундаментальным ограничением является полное отсутствие контекстной памяти [4]. *MLP* не учитывает, как система пришла в текущее состояние, игнорируя временные зависимости и последовательности событий, что критически важно для моделирования динамических процессов управления движением.

Рекуррентные нейронные сети (*RNN*) и их модификации, в частности сети с долгой краткосрочной памятью (*LSTM*), специально созданы для обработки последовательных данных. Структурная схема рекуррентной нейронной сети представлена на рис. 2.




Рис. 2. Структурная схема рекуррентной нейронной сети

Ключевое достоинство *RNN* – наличие внутренней памяти, позволяющей модели учитывать не только текущее состояние, но и предысторию: порядок событий, последовательность занятия рельсовых цепей, историю команд. Это критически важно для прогнозирования развития поездной обстановки. Сети с долгой краткосрочной памятью (*LSTM*) являются предпочтительными благодаря своей устойчивости к проблеме затухающего градиента [5] и способности эффективно обучаться на длинных временных зависимостях, характерных для железнодорожного графика. К недостаткам можно отнести большую вычислительную сложность и необходимость подготовки данных в виде временных рядов.

Проведенный анализ преимуществ и недостатков различных архитектур нейронных сетей требует количественного подтверждения на основе реальных параметров диспетчерского участка. Ниже представлены результаты расчетов размерности входного вектора состояния и вычислительной сложности рассматриваемых моделей.

Количественная оценка обучаемых параметров выполнена на базе имитационной модели работы диспетчерского участка, включающего три станции: «Узловая», «Разъезд 33» и «Разъезд 44» с однопутными перегонами. Информационный фрагмент имитационной модели участка представлен на рис. 3.




Рис. 3. Информационный фрагмент имитационной модели диспетчерского участка

Характеристики оснащения станций устройствами железнодорожной автоматики приведены в табл. 1.

Таблица 1

Оснащение станций смоделированного диспетчерского участка устройствами ЖАТ

Станция	Устройства ЖАТ				
	Рельсовые цепи	Светофоры	Стрелки	УКСПС	Переезд
Узловая	19 (в том числе 4 приемо-отправочных пути)	24	14	2	1
Разъезд 33	5 (в том числе 2 приемо-отправочных пути)	7	2	2	0
Разъезд 44	5 (в том числе 2 приемо-отправочных пути)	7	2	2	0

Для корректного формирования вектора дискретных данных необходимо определить перечень контролируемых состояний для каждого типа объектов. Соответствующие данные представлены в табл. 2.

Таблица 2

Контролируемые состояния объектов ЖАТ

Объект	Контролируемые состояния	Количество
Рельсовая цепь	Свободна/занята/замкнута/искусственно размыкается	4
Стрелка	Плюсовой контроль/минусовой контроль/отсутствие контроля/индивидуально замкнута/индивидуально разомкнута	5
Светофор	Разрешающее показание/запрещающее состояние/неисправность	3
Переезд	Открыт/закрыт/неисправность	3
УКСПС	Исправность устройств/срабатывание устройств	2

Представленный набор объектов и их состояний обеспечивает достаточную полноту модели для оценки вычислительной сложности нейросетевых архитектур в условиях, приближенных к реальным.

Общая размерность входного вектора D состояния для всего участка определяется по формуле

$$D = \sum_{s \in S} \left(N_{rc}^{(s)} \cdot K_{rc} + N_{sv}^{(s)} \cdot K_{sv} + N_{st}^{(s)} \cdot K_{st} + N_{uksps}^{(s)} \cdot K_{uksps} + N_{pr}^{(s)} \cdot K_{pr} \right), \quad (1)$$

где S – множество станций участка; $N_{rc}^{(s)}, N_{sv}^{(s)}, N_{st}^{(s)}, N_{uksps}^{(s)}, N_{pr}^{(s)}$ – количество соответствующих объектов (рельсовая цепь, светофор, стрелка, УКСПС, переезд соответственно) на станции s ; $K_{rc}, K_{sv}, K_{st}, K_{uksps}, K_{pr}$ – число состояний для каждого типа объектов (рельсовая цепь, светофор, стрелка, УКСПС, переезд соответственно).

Подставляя данные из табл. 1 и 2 в формулу (1), получаем, что размерность входного вектора состояния для всего рассматриваемого диспетчерского участка составляет $D = 335$ дискретных состояний.

Для оценки вычислительной сложности рассмотрим две архитектуры: многослойный перцептрон (*MLP*) и рекуррентную сеть с долгой краткосрочной памятью (*LSTM*). Параметры моделей выбраны на основе анализа современных исследований в области проектирования нейросетевых архитектур.

Размер скрытого слоя $H = 128$ принят в соответствии с эмпирическими рекомендациями [6], согласно которым для задач с объемом обучающей выборки порядка 10^4 – 10^5 (что соответствует объемам данных, собираемых на диспетчерском участке за несколько месяцев эксплуатации) оптимальное число нейронов находится в диапазоне 100–150.

Число слоев $L = 2$ выбрано исходя из теоремы об универсальной аппроксимации [7], согласно которой двух скрытых слоев достаточно для моделирования как непрерывных, так и разрывных функций, что соответствует практическим рекомендациям для задач классификации технических систем.

Размер выходного пространства $C_{out} = 62$ соответствует количеству маршрутных команд, доступных диспетчеру на рассматриваемом диспетчерском участке. Маршрутные команды включают маршруты приема и отправления, а также маневровые маршруты в пределах станций. Выбор именно маршрутных команд в качестве выходного пространства нейросети обусловлен тем, что они составляют основу оперативной работы диспетчера и покрывают большинство штатных ситуаций управления движением.

Глубина временного окна T определяет объем исторических данных о состоянии объектов ЖАТ, доступных нейросети для анализа. Под тактом в данной работе понимается один полный цикл опроса системы диспетчерской централизации, по завершении которого формируется актуальный вектор состояния объектов. Для рассматриваемого участка длительность такта составляет от 20 до 30 с в зависимости от загрузки каналов связи. Выбор $T = 15$ тактов обусловлен необходимостью захвата полной динамики типового маршрута приема (2–4 мин). Даже при максимальной оценке длительности такта (30 с) окно $T = 15$ соответствует 7,5 мин реального времени, что гарантированно перекрывает длительность маршрута и обеспечивает захват всех значимых событий (занятие рельсовых цепей, изменение показаний светофоров), достаточных для достоверного распознавания штатных и аварийных ситуаций.

Для учета временного контекста в *MLP* применяется операция спрямления (*flatten*) последовательности из T -тактов в единый вектор размерностью $T \times D$ [8]. Спрямление преобразует многомерные входные данные в одномерный вектор путем последовательного соединения всех элементов, что позволяет подавать временную последовательность на вход стандартному многослойному перцептрон, однако приводит к потере структуры временных зависимостей [4]. Для рассматриваемого участка размерность спрямленного вектора составляет 5025.

Для *MLP* число параметров определяется как сумма параметров каждого полносвязного слоя. Для слоя, преобразующего вход размерности n в выход размерности m , количество обучаемых параметров P составляет [8]:

$$P = (n \cdot m) + m, \quad (2)$$

где $(n \cdot m)$ – число весовых коэффициентов; m – число смещений (*bias*).

Применяя формулу (2) последовательно к слоям сети с учетом спрямленного входного вектора размерности $T \times D$, скрытых слоев размера H и выходного слоя размера C_{out} , получаем выражение

$$P_{MLP} = (T \cdot D) \cdot H + H + H \cdot C_{out} + C_{out}. \quad (3)$$

В *LSTM* временная последовательность обрабатывается естественным образом, без спрямления. Число параметров для *LSTM* с L -слоями определяется по формуле [8, 9]

$$P_{LSTM} = 4 \cdot ((D + H) \cdot H + H) \cdot L + H \cdot C_{out} + C_{out}. \quad (4)$$

Результаты расчета количества обучаемых параметров представлены в табл. 3. Для всех моделей приняты единые параметры: размер скрытого слоя $H = 128$, число слоев $L = 2$, размер выходного пространства $C_{out} = 62$ (количество маршрутных команд). Глубина анализируемого временного окна составляет $T = 15$ тактов.

Таблица 3

Расчет количества обучаемых параметров

Архитектура	Учет временного контекста	Входные данные	Входная размерность	Количество параметров
<i>MLP</i> (статичный)	Не учитывается (только текущий момент) $T = 1$	Один вектор состояния	335	65 970
<i>MLP</i> (с временным окном)	Спряmlение (<i>flatten</i>) последовательности $T = 15$	15 склеенных векторов	5 025	667 838
<i>LSTM</i>	Последовательная обработка $T = 15$	Временной ряд из 15 векторов	335×15	377 150

Выводы

Как видно из полученных данных, статичный *MLP*, работающий только с текущим снимком состояния, требует минимального числа параметров (66 тыс.), однако такой подход не учитывает временной контекст и не способен различать ситуации с одинаковым текущим состоянием, но разной предысторией.

При попытке учесть временной контекст через спряmlение последовательности из $T = 15$ тактов *MLP* увеличивает число параметров более чем в 10 раз (до 668 тыс.), что ведет к резкому росту вычислительной сложности, требований к памяти и риску переобучения.

LSTM при работе с той же глубиной окна требует 377 тыс. параметров – в 1,77 раза меньше, чем *MLP*, при этом сохраняя структуру временной последовательности и способность моделировать контекст событий благодаря внутренней архитектуре с четырьмя гейтами [8, 10].

В результате анализа установлено, что *LSTM* обеспечивает лучшее соотношение между вычислительной эффективностью и способностью к анализу динамики, следовательно, предпочтительно выбирать *LSTM* в качестве базовой архитектуры нейросетевого модуля построения интеллектуального ассистента поездного диспетчера.

Список литературы

- 1 **Алымов, И. О.** Проблемы безопасности и надежности в автоматизированных системах управления движением поездов / И. О. Алымов // Транспорт : наука, образование, производство : сборник научных трудов Международной научно-практической конференции, Ростов-на-Дону, 23–25 апреля 2025 г. – Ростов-на-Дону : Ростовский государственный университет путей сообщения, 2025. – С. 28–32. – EDN CULUWE.
- 2 Особенности эмоционального состояния работников железнодорожного транспорта / Н. Н. Малутина, А. Л. Сединин, С. В. Лузина, Н. С. Сединина // Журнал научных статей Здоровье и образование в XXI веке. – 2017. – Т. 19, № 10. – С. 109–110. – EDN ZATOKV.
- 3 **Долгий, И. Д.** Актуальность внедрения автоматического блокирующего логического контроля действий оперативного персонала в автоматизированных системах управления движением поездов / И. Д. Долгий, И. О. Алымов, А. О. Горобец // Цифровые инфокоммуникационные технологии : сборник научных трудов, Ростов-на-Дону, 27 октября 2023 г. – Ростов-на-Дону : Ростовский государственный университет путей сообщения, 2023. – С. 380–384. – EDN AJAKND.

References

- 1 **Alymov, I. O.** Problems of safety and reliability in automated train traffic control systems / I. O. Alymov // Transport : Science, Education, Production : collection of scientific papers of the International scientific and practical conference, Rostov-on-Don, April 23–25, 2025. – Rostov-on-Don : Rostov State Transport University, 2025. – P. 28–32. – EDN CULUWE.
- 2 Features of the emotional state of railway transport workers / N. N. Malyutina, A. L. Sedinin, S. V. Luzina, and N. S. Sedinin // Journal of scientific articles “Health and Education in the 21st Century”. – 2017. – Vol. 19, No. 10. – P. 109–110. – EDN ZATOKV.
- 3 **Dolgy, I. D.** The relevance of implementing automatic blocking logical control of operational personnel actions in automated train traffic management systems / I. D. Dolgy, I. O. Alymov, A. O. Gorobets // Digital infocommunication technologies : collection of scientific papers, Rostov-on-Don, October 27, 2023. – Rostov-on-Don : Rostov State Transport University, 2023. – P. 380–384. – EDN AJAKND.

4 **Комличенко, В. Н.** Сравнительный анализ различных архитектур нейронных сетей для задач регрессии / В. Н. Комличенко, В. А. Федосенко, А. С. Купрейчик // Экономика и качество систем связи. – 2025. – № 1 (35). – С. 110–121. – EDN PAGCVM.

5 **Пустынний, Я. Н.** Решение проблемы исчезающего градиента с помощью нейронных сетей долгой краткосрочной памяти / Я. Н. Пустынний // Инновации и инвестиции. – 2020. – № 2. – С. 130–132. – EDN MRQIHM.

6 **Lunt, A.** An empirically-sourced heuristic for predetermining the size of the hidden layer of a multi-layer perceptron for large datasets. Lecture Notes in Computer Science / A. Lunt, S. Xu // LNAI. – 2016. – Vol. 9992. – P. 542–547. – DOI 10.1007/978-3-319-50127-7_47.

7 **Cybenko, G.** Approximation by superpositions of a sigmoidal function / G. Cybenko // Mathematics of Control, Signals, and Systems. – 1989. – Vol. 2, No. 4. – P. 303–314. – DOI 10.1007/bf02551274.

8 **Гудфеллоу, Я.** Глубокое обучение / Я. Гудфеллоу, И. Бенджио, А. Курвиль. – Москва : ДМК Пресс, 2018. – 652 с. – ISBN 978-5-97060-618-6.

9 Data Science Stack Exchange. (2016). Number of parameters in an LSTM model. – URL: <https://data-science.stackexchange.com/questions/10615/number-of-parameters-in-an-lstm-model> (date of access: 20.02.2026).

10 Hochreiter, S. Long short-term memory / S. Hochreiter, J. Schmidhuber // Neural Computation. – 1997. – Vol. 9 (8). – P. 1735–1780. – DOI 10.1162/neco.1097.9.8.1735.

4 **Komlichenko, V. N.** Comparative analysis of various neural network architectures for regression problems / V. N. Komlichenko, V. A. Fedosenko, A. S. Kupreichik // Economics and Quality of Communication Systems. – 2025. – No. 1 (35). – P. 110–121. – EDN PAGCVM.

5 **Pustiny, Ya. N.** Solving the problem of a vanishing gradient using neural networks of long short-term memory / Ya. N. Pustiny // Innovations and Investments. – 2020. – No. 2. – P. 130–132. – EDN MRQIHM.

6 **Lunt, A.** An empirically-sourced heuristic for predetermining the size of the hidden layer of a multi-layer perceptron for large datasets. Lecture Notes in Computer Science / A. Lunt, S. Xu // LNAI. – 2016. – Vol. 9992. – P. 542–547. – DOI 10.1007/978-3-319-50127-7_47.

7 **Cybenko, G.** Approximation by superpositions of a sigmoidal function / G. Cybenko // Mathematics of Control, Signals, and Systems. – 1989. – Vol. 2, No. 4. – P. 303–314. – DOI 10.1007/bf02551274.

8 **Goodfellow, Ya.** Deep learning / Ya. Goodfellow, I. Bendjio, A. Courville. Moscow : DMK Press, 2018. 652 p. – ISBN 978-5-97060-618-6.

9 Data Science Stack Exchange. (2016). Number of parameters in an LSTM model. – URL: <https://datascience.stackexchange.com/questions/10615/number-of-parameters-in-an-lstm-model> (date of access: 20.02.2026).

10 Hochreiter, S. Long short-term memory / S. Hochreiter, J. Schmidhuber // Neural Computation. – 1997. – Vol. 9 (8). – P. 1735–1780. – DOI 10.1162/neco.1097.9.8.1735

I. O. Alymov

ANALYSIS OF PARAMETERS OF BASIC NEURAL NETWORK ARCHITECTURES IN TRANSPORT CONTROL SYSTEMS

Abstract. The article considers an approach to improving the efficiency of automated train control systems by integrating a neural network assistant module into the contour of the automatic blocking logical control (ABLC) subsystem. An analysis of the applicability of various neural network architectures for solving problems of intelligent support for train dispatchers is carried out, including multilayer perceptron (MLP) and long short-term memory networks (LSTM). Based on a simulation model of a dispatching section comprising three stations, quantitative assessment of the dimension of the input vector of the state a quantitative assessment of the input state vector dimension and computational complexity of the considered architectures is performed. Formulas for calculating the number of trainable parameters are presented, and a comparison of MLP and LSTM with identical model parameters is made. The results of the comparative analysis demonstrate the advantage of LSTM in terms of computational efficiency while preserving the structure of temporal dependencies. Based on the obtained results, the choice of LSTM as the basic architecture for building an intelligent assistant operating in a single contour with the ABLC subsystem is substantiated.

Keywords: automated train control systems, the human factor, dispatch centralization, intelligent decision support systems, active blocking logical control, neural networks, *LSTM*, multilayer perceptron (*MLP*).

For citation: Alymov, I. O. Analysis of parameters of basic neural network architectures in transport control systems / I. O. Alymov // Vestnik Rostovskogo Gosudarstvennogo Universiteta Putej Soobshcheniya. – 2026 – No. 1. – P. 20–27. – DOI 10.46973/0201-727X_2026_1_20.

Сведения об авторах**АЛЫМОВ ИЛЬЯ ОЛЕГОВИЧ**

Ростовский государственный университет путей сообщения (РГУПС),
кафедра «Автоматика и телемеханика на железнодорожном транспорте»,
аспирант,
e-mail: ilya-alymov@mail.ru

Information about the authors**Alymov Ilya Olegovich**

Rostov State Transport University (RSTU),
Chair “Railway Automation and
Telemechanics”,
Postgraduate Student,
e-mail: ilya-alymov@mail.ru