

Л. Ю. Емалетдинова, А. В. Сергеев

ОДИН ИЗ ПОДХОДОВ К КЛАССИФИКАЦИИ ОБЪЕКТОВ С ИСПОЛЬЗОВАНИЕМ ИМПУЛЬСНЫХ НЕЙРОННЫХ СЕТЕЙ

Ключевые слова: искусственный интеллект, импульсные нейронные сети, спайк, классификация.

В статье рассматривается решение задачи классификации объектов, основанное на использовании импульсных нейронных сетей (SNN). Эти сети эффективно моделируют биологические принципы работы мозга за счет использования дискретных импульсов. Такой подход открывает новые возможности для решения задач, где важна скорость и точность обработки информации, а также энергоэффективность. Одной из самых популярных и простых моделей нейронов в импульсных нейронных сетях является модель LeakyIntegrate-and-Fire (LIF), которая описывает динамику мембранного потенциала нейрона как процесс утечки и интеграции входного тока. Этот процесс отражает биологическое поведение нейронов, где информация накапливается и передается через импульсы. Исходные данные в импульсных нейронных сетях кодируются в виде временных последовательностей импульсов, что позволяет эффективно обрабатывать информацию, которая меняется со временем. Входные нейроны вырабатывают импульсы, которые соответствуют моментам времени, отраженным во входной последовательности. Когда мембранный потенциал нейрона достигает заданного порога, происходит его активация, что приводит к генерации импульса, после чего потенциал нейрона сбрасывается до нуля, и процесс повторяется. В статье приводятся примеры использования импульсных нейронных сетей для решения двух классических задач классификации: ирисов и сортов пшеницы, которые традиционно используются исследователями для оценки эффективности разрабатываемых алгоритмов. В работе рассматриваются гиперпараметры импульсной нейронной сети, влияющие на результаты классификации, включая число пресинаптических нейронов, веса связей между нейронами, порог активации нейронов, мембранное сопротивление, потенциал покоя и другие гиперпараметры.

L. Yu. Emaletdinova, A. V. Sergeev

ONE OF THE APPROACHES TO CLASSIFYING OBJECTS USING IMPULSE NEURAL NETWORKS

Keywords: artificial intelligence, impulse neural networks, spike, classification.

The article discusses the solution of the object classification problem based on the use of impulse neural networks (SNN). These networks effectively simulate the biological principles of the brain by using discrete impulses. This approach opens up new possibilities for solving problems where the speed and accuracy of information processing, as well as energy efficiency, are important. One of the most popular and simplest models of neurons in pulsed neural networks is the LeakyIntegrate-and-Fire (LIF) model, which describes the dynamics of a neuron's membrane potential as a process of leakage and integration of input current. This process reflects the biological behavior of neurons, where information is accumulated and transmitted through impulses. The source data in pulsed neural networks is encoded as time sequences of pulses, which allows efficient processing of information that changes over time. The input neurons produce impulses that correspond to the time points reflected in the input sequence. When the membrane potential of a neuron reaches a set threshold, it is activated, which leads to the generation of a pulse, after which the potential of the neuron is reset to zero, and the process repeats. The article provides examples of using pulsed neural networks to solve two classical classification problems: irises and wheat varieties, which are traditionally used by researchers to evaluate the effectiveness of the algorithms being developed. The paper considers hyperparameters of an impulse neural network that affect classification results, including the number of presynaptic neurons, the weights of connections between neurons, the threshold of neuron activation, membrane resistance, resting potential, and other hyperparameters.

Модели и методы искусственного интеллекта в настоящее время активно используются при решении многочисленных задач, связанных с выявлением закономерностей большого числа данных, накопленных информационными системами различного назначения: построение регрессионных зависимостей, ассоциативных правил, кластеризацией и классификацией. Алгоритмы искусственного интеллекта позволяют создавать автоматизированные системы, позволяющие прогнозировать и управлять состоянием тех или иных процессов [1], распознавать объекты на изображениях [2,3], обрабатывать и генерировать конструкции естественного языка [4], аппроксимировать сложные нелинейные зависимости [5] и решать другие задачи. Одним из групп алгоритмов искусственного интеллекта являются нейронные сети разнообразных архитектур и методов обучения, причем это многообразие постоянно развивается.

Множество архитектур нейронных сетей, которые активно используются при решении практических задач [6-8], делятся на следующие классы: сети прямого распространения, рекуррентные, сверточные сети, трансформеры, автокодировщики и генеративно-состязательные сети.

В настоящее время появилась новое направление в области искусственного интеллекта – создание импульсных (спайковых) нейронных сетей (ИНС) [9-14]. Импульсные нейронные сети имитируют биологические принципы работы мозга за счет использования дискретных импульсов. В качестве входа и выхода сети используются временные последовательности дискретных величин – импульсов, с помощью которых кодируются исходные данные и результирующие. Нейроны в таких сетях активируются только при достижении определенного порогового значения, после чего происходит генерация импульсов и

потенциал нейронов сбрасывается до нуля. Подобное представление данных позволяет выполнять вычисления асинхронно, используя только участки сети, которые участвуют в обработке импульсов. Развитие этого направления связано с преимуществами ИНС по сравнению с классическими нейронными сетями, а именно: снижением энергетических затрат и масштабируемостью.

Самой популярной и простой моделью нейронов в ИНС является модель Leaky Integrate-and-Fire (LIF), которая описывает динамику мембранного потенциала нейрона как утечку (уменьшение) и интеграцию (суммирование) входного тока:

$$\tau \frac{dV(t)}{dt} = -(V(t) - E) + R * I(t), \quad (1)$$

где $V(t)$ – мембранный потенциал нейрона в момент времени t , $I(t)$ – входной ток, поступающий от других нейронов и τ – постоянная времени нейрона, E – потенциал покоя (утечки), R – мембранное сопротивление.

Каждый выходной (постсинаптический) нейрон накапливает входной сигнал - мембранный потенциал $V(t)$. Когда мембранный потенциал $V(t)$ нейрона достигает заданного порогового значения V^* , генерируется импульс (спайк) и потенциал сбрасывается, если $V(t) \geq V^*$, то $V(t) = 0$.

После сброса потенциала в течение определенного периода нейрон нечувствителен к входному сигналу, после чего процесс возобновляется.

При решении конкретной задачи с использованием ИНС необходимо определить структуру сети, то есть определить число нейронов на входе и выходе, а также обучить сеть, подобрав веса между нейронами таким образом, чтобы получить наилучшее решение задачи.

В работе [15] рассмотрена задача классификации ирисов с использованием ИНС. Набор данных представляет собой множество примеров (Табл.1), каждый из которых содержит характеристики: длину Sepal Length и ширину Sepal Width чашелистика, длину Petal Length и ширину Petal Width лепестка, а также один из трех типов цветка Setosa, Versicolor и Virginica. На основе характеристик цветка необходимо предсказать его тип.

Таблица 1 – Фрагмент исходных данных

Table 1 – A fragment of the source data

	Sepal Length	Sepal Width	Petal Length	Petal Width	Тип цветка
1	5,1	3,5	1,4	0,2	Setosa
2	4,9	3,0	1,4	0,2	Setosa
3	4,7	3,2	1,3	0,2	Setosa
4	4,6	3,1	1,5	0,2	Setosa
5	5,0	3,6	1,4	0,2	Setosa

Рассматривается сеть, которая состоит из двух слоев: входной (пресинаптический) и выходной (постсинаптический) слои. Количество нейронов входного слоя зависит от количества характеристик,

описывающих цветков, а также от количества нейронов, которые используются для кодирования каждой характеристики. Количество нейронов выходного слоя зависит от количества типов цветка. В работе предлагается для кодирования каждой характеристики цветка использовать 10 нейронов. Поскольку характеристик 4, то вход ИНС состоит из 40 нейронов. Поскольку в исходных данных 3 типа цветков, то количество нейронов выходного слоя будет равен 3.

Каждое значение характеристики цветка кодируется в соответствии со следующим методом:

1. Для кодирования каждой характеристики цветка

используются 10 функций Гаусса $y = ae^{-\frac{(x-m)^2}{2\sigma^2}}$, которые задаются следующим образом:

- а) Задается высота функции $a = 1$.
- б) Выбираются минимальное и максимальное значения характеристики.
- в) Рассчитывается математическое ожидание каждой из функций Гаусса:

$$m_i = x_{min} + (i - 1) * \frac{x_{max} - x_{min}}{9}, i = \overline{1,10}.$$

д) Поскольку каждая из характеристик цветка достаточно равномерно распределена на интервале $[x_{min}, x_{max}]$, то среднеквадратическое отклонение σ для каждой функции должно быть одинаковым и подбираться близким к числу, равному $\frac{(x_{max} - x_{min})}{9} : 3$.

2. На основе использования функций Гаусса для каждой из характеристик Sepal Length, Sepal Width, Petal Length, Petal Width каждого типа цветка вычисляются значения 10 функций Гаусса, построенных на предыдущем шаге. В таблице 2 представлены вычисленные значения 10 функций Гаусса для характеристики Sepal Width со значением 3,5.

Таблица 2 – Значения функций Гаусса

Table 2 – Values of Gaussian functions

Наименование	Значения
Значение характеристики Sepal Width	3,5
Интервал значений характеристики (из табл.1) $[x_{min}, x_{max}]$	[2.0; 4.4]
Мат. ожидания функций Гаусса (m_1, \dots, m_{10})	(2.0, 2.2667, 2.53, 2.8, 3.0667, 3.33, 3.6, 3.8667, 4.1333, 4.4)
Среднеквадратическое отклонение σ	0.1
Значения функций Гаусса (y_1, \dots, y_{10})	(0, 0, 0, 0, 0.000084, 0.249354, 0.606531, 0.001204, 0, 0)

Каждое из значений функций Гаусса находится в пределах интервала $[0, 1]$ и отражает уровень возбуждения соответствующего нейрона.

3. Задержка срабатывания импульса z_i каждого i -го входного нейрона, вычисляется как:

$$z_i = \begin{cases} 1 - y_i, & \text{если } y_i > y^* \\ 0, & \text{в противном случае} \end{cases}$$

2. Если при этом потенциал одного из выходных нейронов превышает пороговое значение V^* , то он генерирует импульс. Запоминается время выпуска импульса. После этого потенциал выходного нейрона сбрасывается в ноль и начинается рефрактерный период до конца текущего периода обучения. То есть потенциал нейрона остаётся равным нулю, даже если продолжают приходить импульсы от входных нейронов. Для данного нейрона этот период действует до конца текущего периода. Если за всё время периода обучения (10 мс) импульс какого-либо нейрона не превысил порогового значения, то потенциал нейрона обнуляется перед обработкой следующего примера.
3. После обработки одного вектора обучающего множества определяются следующие моменты времени:
 - t_0 – время импульса выходного нейрона, отвечающего за класс 1,
 - t_1 – время импульса выходного нейрона, отвечающего за класс 2,
 - t_2 – время импульса выходного нейрона, отвечающего за класс 3.
4. Применяется следующее правило классификации: пример относится к классу k^* , где $k^* = \operatorname{argmin}_i (t_i | t_i > 0)$. Если ни один из выходных нейронов не выработал импульс и $t_0 = 0, t_1 = 0, t_2 = 0$, то вектор остаётся неклассифицированным – в таких случаях такой вектор будет в дальнейшем засчитываться как ошибка.
6. Пункт 5 повторяется для всех примеров обучающего множества.

Тестовое множество примеров используется для оценки точности (ассигасу) классификации и определяется как доля примеров, для которых предсказанный класс совпал с истинным:

$$\text{Assigasy} = \frac{1}{P} \sum_{p=1}^P I(k^* = k), \quad (8)$$

где $k \in \{1, 2, 3\}$ – истинное значение класса; $k^* \in \{-1, 1, 2, 3\}$ – предсказанное сетью значение класса, причем $k^* = -1$, если предсказание неверно или за период 10 мс ни один из выходных нейронов не выпустил импульс; $I(\cdot) = \begin{cases} 1, & \text{если } k^* = k \\ 0, & \text{если } k^* \neq k \end{cases}$

Если точность классификации неудовлетворительная, то целесообразно осуществить коррекцию текущих значений весов по правилу STDP (spike-timing-dependent plasticity). Суть правила заключается в следующем: для каждого входного i и выходного j нейронов изменение веса Δw_{ij} зависит от разности моментов испускания импульсов. Входной нейрон, активировавшийся раньше выходного нейрона при правильной классификации, усиливает связь с этим нейроном, а выходной нейрон, активировавшийся раньше входного при неправильной классификации, ослабляет связь с ним.

Алгоритм корректировки весов заключается в следующем:

Для каждого вектора обучающего множества (3) выполняется пункт 5. Для корректировки весов, связывающих входные и выходные нейроны, используется правило:

- Если $k^* = k$, где k – номер нейрона в векторе обучающего множества, то для i –го входного нейрона, вырабатываемого импульс не позднее k –го выходного нейрона ($t_i^{\text{BX}} - t_k^{\text{ВВХ}} \leq 0$), вес связи вычисляется как:

$$w_{ik}^{\text{H}} = w_{ik}^{\text{C}} + A^+ \exp\left(-\frac{|t_i^{\text{BX}} - t_j^{\text{ВВХ}}|}{\tau}\right) \quad (9)$$

- Если $k^* = k$, то для i –го входного нейрона, вырабатываемого импульс позднее k –го выходного нейрона ($t_i^{\text{BX}} - t_k^{\text{ВВХ}} > 0$), вес связи вычисляется как:

$$w_{ik}^{\text{H}} = w_{ik}^{\text{C}} - A^- \exp\left(-\frac{|t_i^{\text{BX}} - t_j^{\text{ВВХ}}|}{\tau}\right) \quad (10)$$

- Если $k^* \neq k$, то для любого i –го входного нейрона, вырабатываемого импульс, вес связи вычисляется как:

$$w_{ik}^{\text{H}} = w_{ik}^{\text{C}} - A^- \exp\left(-\frac{|t_i^{\text{BX}} - t_j^{\text{ВВХ}}|}{\tau}\right) \quad (11)$$

После корректировки отрицательные веса обнуляются. Параметры A^+ и A^- , τ влияют на скорость обучения и подбираются экспериментальным путем.

В таблице 4 приведены параметры алгоритма построения ИНС, влияющие на точность классификации и значения параметров, используемых при решении задачи классификации ирисов на основе набора данных Iris.

Таблица 4 – Параметры алгоритма и значения при решении задачи классификации ирисов

Table 4 – Algorithm parameters and values for solving the iris classification problem

Параметр	Значение
n – число пресинаптических нейронов	10
a, σ_1 – параметры гауссиана для характеристики Sepal Length	Соответственно 1 и 0.1
a, σ_2 – параметры гауссиана для характеристики Sepal Width	Соответственно 1 и 0.1
a, σ_3 – параметры гауссиана для характеристики Petal Length	Соответственно 1 и 0.2
a, σ_4 – параметры гауссиана для характеристики Petal Width	Соответственно 1 и 0.1
τ – постоянная времени нейрона	2,5
E – потенциал покоя (утечки)	0
R – мембранное сопротивление	5
$Const$ – константа формул (5)-(7) расчета весов	2
A^+ и A^- константы формул (9) – (11) расчета весов	0,8 и 0,88

При решении задачи классификации ирисов подбором параметров удалось добиться точности близкой к 95%. Этот же алгоритм был апробирован на

наборе данных Seeds, имеющих семь описательных характеристик и три вида зерен пшеницы. Точность классификации зерен пшеницы при тех же значениях параметров алгоритма составила 43,33%, что свидетельствует о влиянии параметров на точность классификации и их зависимости от структуры и распределении исходных данных.

Заключение

Использование модели нейронов Leaky Integrate-and-Fire, описывающей динамику мембранного потенциала нейрона как утечку и интеграцию входного тока в импульсных нейронных сетях, позволяет решать задачу классификации, выполняя вычисления асинхронно, используя только нейроны и связи, которые обрабатывают импульсы. Следует отметить, что при построении модели на каждом шаге уточняются веса не всех связей входных и выходных нейронов, как в других архитектурах нейронных сетей, а только определенных связей, нейроны которых участвуют в обработке импульсов. Это обеспечивает снижение энергозатрат. Экспериментальные результаты показали зависимость точности классификации от параметров самой модели и алгоритма определения и корректировки весов связи нейронов. Дальнейшие исследования могут быть направлены на разработку алгоритмов определения параметров, обеспечивающих заданную точность классификации.

Литература

1. Степанов, С. Ю., Сидоренко, А. Ю., Колбина, О. Н., Мартын, И. А. Информационные технологии и системы: управление, экономика, транспорт, право, 2024, № 3(51), 157-162. EDN ECBDLQ.
2. Лазарев, Е. А. Вестник науки, 2023, Т. 5, № 12-1(69), 412-415. EDN BVXPYI.
3. Хроль, Е. В., Шаронова, К. С. Современные инновации, системы и технологии, 2023, Т. 3, № 4, 311-321. DOI: 10.47813/2782-2818-2023-3-4-0311-0321. EDN WMFPMH.
4. Панкратов, А. С., Окладникова, С. В. Инженерно-строительный вестник Прикаспия, 2025, № 4(54), 63-69. DOI: 10.52684/2312-3702-2025-54-4-63-69. EDN KQHLRC.
5. Емалетдинова, Л. Ю., Кабилова, А. Н. Известия высших учебных заведений. Авиационная техника, 2019, № 2, 40-48. EDN FEHKKC.
6. Назипов, Р. С. Современная наука: актуальные проблемы теории и практики. Серия: Естественные и технические науки, 2024, № 9, 101-103. DOI: 10.37882/2223-2966.2024.9.27. EDN TFINYY.
7. Лесников, С. В. Говор: альманах, 2025, № 6, 686-693. EDN UOMKNB.
8. Черпаков, И. В. ЭФО: Экономика. Финансы. Общество, 2025, № 3(15), 110-121. DOI: 10.24412/2782-4845-2025-15-110-121. EDN ISTUPY.
9. Худайберидева, Г. Б., Кожухов, Д. А., Пименкова, А. А. Теория и практика современной науки, 2025, № 8(122), 98-105. EDN UHQCRK.
10. Аглямзянова, Г. Н., Гумерова, Л. З., Гарипова, Р. Ф. Социально-экономические и технические системы: исследование, проектирование, оптимизация, 2023, № 1(93), 6-12. EDN GSOWTQ.
11. Антонов, А. М., Щаников, С. А. Методы и устройства передачи и обработки информации, 2023, № 25, 43-52. EDN CQURGH.
12. Киселев, М. В., Урусов, А. М., Иваницкий, А. Ю. Компьютерные исследования и моделирование, 2025, Т. 17, № 3, 389-400. DOI: 10.20537/2076-7633-2025-17-3-389-400. EDN ISXQIQ.
13. Матвеев, Н. И. Инновации. Наука. Образование, 2021, № 45, 416-421. EDN LONVHM.
14. Пальчевский, Е. В., Антонов, В. В., Хасанов, И. И., Суворова, В. А. Программная инженерия, 2026, Т. 17, № 1, 3-13. DOI: 10.17587/prin.17.3-13. EDN HLACFS.
15. Первые шаги в импульсных нейронных сетях. – URL: <https://habr.com/ru/articles/746762/> (дата обращения: 20.11.2025).
1. Stepanov, S. U., Sidorenko, A. U., Kolbina, O. N., Martyn, I. A. Information Technologies and Systems: Management, Economics, Transport, Law, 2024, No. 3(51), 157-162. EDN ECBDLQ.
2. Lazarev, E. A. Bulletin of Science, 2023, Vol. 5, No. 12-1(69), 412-415. EDN BVXPYI.
3. Khol, E. V., Sharonova, K. S. Modern Innovations, Systems and Technologies, 2023, Vol. 3, No. 4, 311-321. DOI: 10.47813/2782-2818-2023-3-4-0311-0321. EDN WMFPMH.
4. Pankrashov, A. S., Okladnikova, S. V. Engineering and Construction Bulletin of the Caspian Region, 2025, No. 4(54), 63-69. DOI: 10.52684/2312-3702-2025-54-4-63-69. EDN KQHLRC.
5. Emaletdinova, L. U., Kabirova, A. N. News of Higher Educational Institutions. Aviation Technology, 2019, No. 2, 40-48. EDN FEHKKC.
6. Nazipov, R. S. Modern Science: Relevant Problems of Theory and Practice. Series: Natural and Technical Sciences, 2024, No. 9, 101-103. DOI: 10.37882/2223-2966.2024.9.27. EDN TFINYY.
7. Lesnikov, S. V. Govor: Almanac, 2025, No. 6, 686-693. EDN UOMKNB.
8. Cherpakov, I. V. EFO: Economics. Finance. Society, 2025, No. 3(15), 110-121. DOI: 10.24412/2782-4845-2025-15-110-121. EDN ISTUPY.
9. Khudaibiredeva, G. B., Kozukhov, D. A., Pimenova, A. A. Theory and Practice of Modern Science, 2025, No. 8(122), 98-105. EDN UHQCRK.
10. Aglamzyanova, G. N., Gumerova, L. Z., Garipova, R. F. Socio-Economic and Technical Systems: Research, Design, Optimization, 2023, No. 1(93), 6-12. EDN GSOWTQ.
11. Antonov, A. M., Shchanikov, S. A. Methods and Devices of Information Transmission and Processing, 2023, No. 25, 43-52. EDN CQURGH.
12. Kiselev, M. V., Urosov, A. M., Ivanitsky, A. U. Computer Research and Modeling, 2025, Vol. 17, No. 3, 389-400. DOI: 10.20537/2076-7633-2025-17-3-389-400. EDN ISXQIQ.
13. Matveev, N. I. Innovations. Science. Education, 2021, No. 45, 416-421. EDN LONVHM.
14. Palychevsky, E. V., Antonov, V. V., Khasanov, I. I., Suvorova, V. A. Software Engineering, 2026, Vol. 17, No. 1, 3-13. DOI: 10.17587/prin.17.3-13. EDN HLACFS.
15. First steps in spiking neural networks. – URL: <https://habr.com/ru/articles/746762/> (accessed 20.11.2025).

References

© Л. Ю. Емалетдинова – д-р техн. наук, профессор кафедры Прикладной математики и информатики (ПМИ), Казанский национальный исследовательский технический университет им. А.Н. Туполева (КНИТУ им. А.Н. Туполева), Казань, Россия, lilia@stcline.ru; А. В. Сергеев – магистр кафедры ПМИ, КНИТУ им. А.Н. Туполева, antser98@gmail.com.

© L. Yu. Emaletdinova – Doctor of sciences in engineering, Professor of the Department of Applied Mathematics and Informatics, Kazan National Research Technical University named after A.N. Tupolev (KNRTU named after A.N. Tupolev), Kazan, Russia, lilia@stcline.ru; A. V. Sergeev – Master-Student of the Department of the AMI, KNRTU named after A.N. Tupolev, antser98@gmail.com.

Дата поступления рукописи в редакцию – 06.04.26.

Дата принятия рукописи в печать – 29.04.26.