



<http://dx.doi.org/10.35596/1729-7648-2026-32-2-44-52>

УДК 004.67, 004.85

ИССЛЕДОВАНИЕ ВЛИЯНИЯ ГИПЕРПАРАМЕТРОВ НА ТОЧНОСТЬ НЕЙРОСЕТЕВОГО ПРЕДСКАЗАНИЯ С ИСПОЛЬЗОВАНИЕМ НАБОРА ДАННЫХ Fashion-MNIST

Д. М. КЛИМЕНКО, Е. И. КОЗЛОВА

Белорусский государственный университет (Минск, Республика Беларусь)

Аннотация. В настоящее время в области машинного обучения и искусственного интеллекта активно исследуются методы оптимизации и настройки гиперпараметров моделей. Одно из ключевых направлений таких исследований – анализ влияния изменения гиперпараметров, таких как количество слоев двумерной свертки (Conv2D) и их параметры (число фильтров, размер ядра), размер и шаг слоев максимальной подвыборки (MaxPooling2D), количество нейронов в полносвязных слоях, функции активации, размер пакета (batch_size) и количество эпох обучения, на точность предсказания модели. В статье приведен анализ влияния изменения количества слоев двумерной свертки, параметров слоев максимальной подвыборки (размер окна и шаг), количества нейронов в полносвязных слоях, выбора функции активации, размера пакета и числа эпох обучения на точность предсказания моделей машинного обучения на наборе данных Fashion-MNIST в архитектуре сверточной нейронной сети.

Ключевые слова: размер пакета, двумерная свертка, Fashion-MNIST, максимальная подвыборка, гиперпараметры, количество эпох обучения, количество фильтров, оптимизация гиперпараметров, точность предсказания, функции активации.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Для цитирования. Клименко, Д. М. Исследование влияния гиперпараметров на точность нейросетевого предсказания с использованием набора данных Fashion-MNIST / Д. М. Клименко, Е. И. Козлова // Цифровая трансформация. 2026. Т. 32, № 2. С. 44–52. <http://dx.doi.org/10.35596/1729-7648-2026-32-2-44-52>.

INVESTIGATION OF THE IMPACT OF HYPERPARAMETERS ON THE ACCURACY OF NEURAL NETWORK PREDICTIONS USING THE Fashion-MNIST DATASET

DANIIL KLIMENKA, ALENA KAZLOVA

Belarusian State University (Minsk, Republic of Belarus)

Abstract. Machine learning and artificial intelligence (AI) are currently actively researching methods for optimizing and tuning model hyperparameters. One key area of research is analyzing the impact of varying hyperparameters, such as the number of two-dimensional convolution (Conv2D) layers and their parameters (number of filters, kernel size), the size and stride of maximum pooling (MaxPooling2D) layers, the number of neurons in fully connected layers, activation functions, batch size (batch_size), and the number of training epochs, on the prediction accuracy of machine learning models using a convolutional neural network architecture on the Fashion-MNIST dataset.

Keywords: batch size, 2D convolution, Fashion-MNIST, max pooling, hyperparameters, number of training epochs, number of filters, hyperparameter optimization, prediction accuracy, activation functions.

Conflict of interests. The authors declare that there is no conflict of interests.

For citation. Klimenka D., Kazlova A. (2026) Investigation of the Impact of Hyperparameters on the Accuracy of Neural Network Predictions Using the Fashion-MNIST Dataset. *Digital Transformation*. 32 (2), 44–52. <http://dx.doi.org/10.35596/1729-7648-2026-32-2-44-52> (in Russian).

Введение

Сегодня в области машинного обучения и искусственного интеллекта одно из ключевых направлений – анализ влияния изменения гиперпараметров на точность предсказания модели, например, с использованием набора данных Fashion-MNIST. Среди основных гиперпараметров – количество слоев Conv2D и их параметры (число фильтров, размер ядра), размер и шаг pooling-слоев, количество нейронов в полносвязных слоях (Dense), функции активации, размер пакета (batch_size) и количество эпох обучения [1, 2]. Fashion-MNIST содержит черно-белые изображения одежды и аксессуаров размерами 28×28 пикселей. Этот набор данных создан в 2017 г. исследователями из Zalando Research [3] как более сложная альтернатива классическому MNIST, содержащему изображения рукописных цифр.

Анализ влияния гиперпараметров на точность предсказания моделей на наборе данных Fashion-MNIST – актуальная задача, которая позволит улучшить результаты обучения и оптимизировать процесс построения моделей машинного обучения. Исследование влияния гиперпараметров на точность предсказания с использованием Fashion-MNIST не только расширит знания в области машинного обучения, но и улучшит качество работы моделей, повысив их эффективность в задачах классификации изображений.

Изменяемые гиперпараметры

Fashion-MNIST содержит 70 тыс. изображений в 10 категориях одежды. На каждом изображении – по одному предмету одежды в низком разрешении (28×28 пикселей). В Fashion-MNIST используется 60 тыс. изображений для обучения нейронной сети и 10 тыс. изображений для тестирования (чтобы проверить, насколько правильно сеть обучилась их классифицировать). Этот набор данных можно сразу загрузить из библиотеки TensorFlow, поскольку он входит в ее состав.

Для исследований была выбрана следующая архитектура нейронной сети: два сверточных слоя Conv2D с 32 и 64 фильтрами соответственно; размер ядер обоих слоев (3, 3); два pooling-слоя с шагом на первом (3, 3) и на втором – (2, 2); размер окна объединения в первом слое (3, 3) и на втором (2, 2); 128 нейронов в полносвязном слое; функция активации ReLU (Rectified Linear Unit); размер пакета – 32; количество эпох обучения – 10 [4]. Выбранная архитектура (два слоя Conv2D, слой подвыборки и полносвязный слой на 128 нейронов) – классический пример сверточной сети средней глубины. Она содержит все ключевые компоненты, необходимые для извлечения признаков из изображений (свертка, pooling, нелинейная активация), но при этом не является избыточно сложной. Это позволяет четко отследить влияние изменений отдельных гиперпараметров, т. е. продемонстрировать, как их изменение сказывается на точности предсказания (повышение/снижение).

Исследовали влияние следующих гиперпараметров нейронной сети: количество слоев, участвующих в операции свертки Conv2D, и их параметры (число фильтров, размер ядра); размер и шаг pooling-слоев; количество нейронов в полносвязных слоях; функции активации; размер пакета; количество эпох обучения.

Алгоритм свертки Conv2D выбирает небольшую область изображения (ядро свертки) и умножает ее значения на веса фильтра. Проходя по всему изображению, он создает карту признаков, содержащую выявленные паттерны. Чем больше слоев Conv2D, тем глубже анализ изображения, но выше риск потери пространственной информации, увеличения вычислительной нагрузки и переобучения.

Размер и шаг pooling-слоев. Pooling – это процесс уменьшения изображения, чтобы сократить объем данных и сохранить ключевые признаки. Размер окна (pool_size) и шаг (strides) регулируют уровень уменьшения размерности. Баланс между размером окна и шагом важен для оптимального обучения нейронной сети.

Количество нейронов в полносвязных слоях. Полносвязные слои соединяют каждый нейрон текущего слоя со всеми нейронами следующего. Меньшее количество нейронов, например, 32 или 64, приводит к ускорению обучения нейронной сети, но снижает возможности для качественного анализа данных. Среднее количество нейронов 128 и 256 – баланс между вычислительной сложностью и точностью. Большее количество нейронов, например 512, обеспечивает глубокий анализ данных, но требует больше ресурсов и повышает риск переобучения. В последнем слое нейронной сети принимается решение о классификации.

Функции активации – это ключевой элемент нейронных сетей, который определяет, какие нейроны будут активны. Они помогают модели создавать нелинейные зависимости между входными и выходными данными. Перечислим типы функций активации, использованных в исследовании:

– ReLU: ускоряет обучение, предотвращает проблемы исчезающего градиента; используется в слоях Conv2D и Dense:

$$f(x) = \begin{cases} x, & \text{если } x > 0; \\ 0, & \text{если } x \leq 0; \end{cases} \quad (1)$$

– Leaky ReLU (улучшенный ReLU): предотвращает мертвые нейроны:

$$f(x) = \begin{cases} x, & \text{если } x > 0; \\ \alpha x, & \text{если } x \leq 0; \end{cases} \quad (2)$$

– Sigmoid: преобразует значения в диапазон от 0 до 1, удобно для бинарных задач; может вызывать затухание градиента в глубоких сетях:

$$f(x) = \frac{1}{1 + e^{-x}}; \quad (3)$$

– Tanh (гиперболический тангенс): выдает значения от (-1) до 1, улучшая передачу информации; хорошо работает, если входные данные нормализованы:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}; \quad (4)$$

– Softmax (для многоклассовых задач – в Fashion MNIST 10 классов): преобразует выходные значения в вероятности, чтобы выбрать лучший класс; используется в последнем слое для классификации:

$$f(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}}. \quad (5)$$

Batch_size (выборка) – параметр, используемый в машинном обучении, который определяет количество обучающих примеров, обрабатываемых моделью за один шаг обучения. Влияет на скорость обучения, использование памяти и стабильность градиентного спуска. Выбор оптимального *batch_size* зависит от доступных вычислительных ресурсов и специфики задачи. Малые значения выборки могут привести к нестабильности обучения, а слишком большие – к увеличению времени обработки и потребления памяти.

Эпоха обучения – это один полный проход всех обучающих данных через модель машинного обучения. Во время обучения нейронной сети количество эпох определяет, сколько раз модель будет проходить через обучающий набор данных, что позволяет ей постепенно улучшать свои параметры и снижать ошибку предсказания. Однако выбор слишком большого или слишком малого количества эпох может привести к переобучению или недообучению соответственно [5].

Проведение экспериментов с изменением гиперпараметров

В базовой модели, относительно которой проводилось исследование, точность нейросетевого предсказания составляла 91 % при двух сверточных слоях с 32 и 64 фильтрами. В процессе экспериментов анализировались результаты изменения различных гиперпараметров.

Изменение количества слоев и ядер в Conv2D. Добавление сверточных слоев может привести как к извлечению более глубоких признаков и повышению качества работы сети, так и к переобучению. Уменьшение числа слоев свертки также имеет свои преимущества и недостатки. При изменении количества слоев Conv2D от одного до трех получены следующие результаты:

- при добавлении третьего слоя (128 фильтров) точность нейросетевого предсказания уменьшилась и составила 89 %;
- уменьшение количества слоев до одного (32 фильтра) привело к точности нейросетевого предсказания 92 %.

Для определения влияния размерности ядра на качество распознавания были выбраны значения размерности ядра (3,3), (5,5) и (7,7). При этом учитывалось, что размерность ядра (3,3) является широко используемой, поскольку хорошо выделяет мелкие детали, такие как линии и углы, (5,5) анализирует более крупные текстуры, а (7,7) позволяет глубже изучить общие формы, но приводит к потере мелких деталей. Полученные в базовой модели значения при изменении числа фильтров представлены в табл. 1.

Таблица 1. Зависимость точности работы сети от размерности ядер при двух Conv2D-слоях
Table 1. Dependence of network performance accuracy on kernel values with two Conv2D layers

Ядро		Точность предсказания, %
первого слоя с 32 фильтрами	второго слоя с 64 фильтрами	
(3,3)	(3,3)	91
(5,5)	(5,5)	91
(7,7)	(7,7)	90
(3,3)	(5,5)	91
(3,3)	(7,7)	91
(5,5)	(3,3)	92
(5,5)	(7,7)	91
(7,7)	(3,3)	90
(7,7)	(5,5)	89

В модели с уменьшенным количеством слоев (один слой с 32, 64 и 128 фильтрами) получены результаты, представленные в табл. 2.

Таблица 2. Зависимость точности работы сети от размерности ядер при одном Conv2D-слое с 32, 64 и 128 фильтрами

Table 2. Dependence of the network accuracy on the kernel size for one Conv2D layer with 32, 64, and 128 filters

Ядро одного слоя	Точность предсказания, %
С 32 фильтрами	
(3,3)	92
(5,5)	91
(7,7)	91
С 64 фильтрами	
(3,3)	91
(5,5)	91
(7,7)	90
Со 128 фильтрами	
(3,3)	92
(5,5)	91
(7,7)	91
(9,9)	91

Изменение размера окна объединения (*pool_size*) и шага перемещения окна (*strides*) pooling-слоев (*MaxPooling2D*). Результаты точности работы сети при изменении шага перемещения окна при размере окон объединения в первом и во втором слоях, равном (2,2) и (2,2) соответственно, представлены в табл. 3. Изменение размера окна объединения (*pool_size*) в базовой модели, в которой шаг перемещения окна не указан, по умолчанию принимает значение *pool_size*, как показано в табл. 4.

Таблица 3. Зависимость точности работы сети от шагов перемещения в pooling-слоях
Table 3. Dependence of network performance accuracy on movement steps pooling layers

Шаг перемещения		Точность предсказания, %
в первом слое	во втором слое	
(3,3)	(2,2)	91
(3,3)	(1,1)	91
(3,3)	(3,3)	89
(2,2)	(1,1)	92
(2,2)	(2,2)	91
(2,2)	(3,3)	91
(1,1)	(2,2)	92
(1,1)	(3,3)	92
(1,1)	(1,1)	92

Таблица 4. Зависимость точности работы сети от размеров окон объединения в pooling-слоях
Table 4. Dependence of network performance accuracy on pooling windows in pooling layers

Размер окна объединения		Точность предсказания, %
в первом слое	во втором слое	
(3,3)	(2,2)	91
(3,3)	(1,1)	91
(3,3)	(3,3)	90
(2,2)	(1,1)	92
(2,2)	(2,2)	91
(2,2)	(3,3)	91
(1,1)	(2,2)	92
(1,1)	(3,3)	92
(1,1)	(1,1)	91

Исследование влияния количества нейронов в полносвязных слоях (Dense) на точность предсказания в базовой модели. Количество нейронов изменялось от 32 до 512. Предполагалось, что увеличение числа нейронов приведет к повышению точности предсказания, т. е. к способности модели аппроксимировать сложные функции. Однако при этом может произойти переобучение, т. е. модель не будет способна распознавать новые данные при высоком качестве распознавания данных обучающей выборки. Результаты исследований приведены в табл. 5.

Таблица 5. Зависимость точности работы сети от количества нейронов в полносвязных слоях
Table 5. Dependence of network accuracy on the number of neurons in fully connected layers

Количество нейронов	32	64	128	256	512
Точность предсказания, %	90	90	91	91	92

Изменение функции активации. Зависимость точности работы сети от выбранной функции активации приведена в табл. 6.

Таблица 6. Зависимость точности работы сети от выбранной функции активации
Table 6. Dependence of network accuracy on the selected activation function

Функция активации	ReLU	Sigmoid	Tanh	Leaky ReLU
Точность предсказания, %	92	91	91	91

Изменение размера пакета и количества эпох. Зависимости точности работы сети от количества эпох обучения нейронной сети и точности предсказания при значениях выборки (batch_size) с 32, 64 и 128 фильтрами приведены в табл. 7.

Таблица 7. Зависимость точности работы сети от количества эпох обучения нейронной сети при значениях выборки с 32, 64 и 128 фильтрами

Table 7. Dependence of the network accuracy on the number of neural network training epochs for sample values with 32, 64 and 128 filters

batch_size = 32					
Количество эпох	10	20	30	40	50
Точность предсказания, %	91	91	91	91	90
batch_size = 64					
Количество эпох	10	20	30	40	50
Точность предсказания, %	92	91	91	91	91
batch_size = 128					
Количество эпох	10	20	30	40	50
Точность предсказания, %	91	91	91	91	91

Сравнение результатов и анализ влияния каждого гиперпараметра на точность предсказания

Изменение количества слоев и ядер в Conv2D. В базовой модели было два сверточных слоя с 32 и 64 фильтрами, и точность нейросетевого предсказания составляла 91 %, а при добавлении третьего слоя уменьшилась до 89 %. Такое понижение для набора данных Fashion-MNIST может иметь несколько объяснений:

- при добавлении третьего слоя, который способен выделять более сложные и абстрактные признаки изображений, во избежание переобучения может потребоваться больше данных в обучающей выборке, что при балансе обучающей и тестовой выборок в исследуемом датасете представляется невозможным;

- при добавлении дополнительного слоя может возникнуть проблема потери информации, поскольку дополнительный слой извлекает ненужные или нерелевантные признаки изображения, что и сказывается негативно на точности предсказания;

- добавление третьего слоя увеличивает сложность модели, что также может привести к переобучению, особенно, если количество данных для обучения недостаточно.

Увеличение точности предсказания при использовании уменьшенного количества слоев (один слой с 32 фильтрами и один – с 128 фильтрами; оба слоя с размером ядер (3,3)) может быть объяснено тем, что упрощение модели улучшает ее обобщающую способность и помогает избежать переобучения. Комбинация размеров ядер (5,5) и (3,3) позволила модели лучше захватывать различные уровни деталей в изображениях, что привело к повышению точности предсказания.

Изменение размера окна объединения и шага перемещения окна pooling-слоев (MaxPooling2D). Исследования проводились при фиксированном размере окна и разных шагах его перемещения, а также при фиксированном шаге перемещения изменялся размер окна. При базовом размере окна и шаге перемещения (2,2) в первом слое и (1,1) во втором точность предсказания составила 92 %. В случае с шагами перемещения (3,3) в первом слое и (3,3) во втором точность предсказания – 89 %. Во всех остальных комбинациях точность предсказания не отличалась от базовой модели и составляла 91 %.

При изменении размера окна объединения и сохранении величины шага неизменной точность предсказания колебалась в пределах 90–92 %. Наиболее высокая точность достигалась при размере окна (2,2) в первом слое и (1,1) во втором, при размере окна (1,1) в первом слое и (2,2) во втором, а также при размере окна (1,1) в первом слое и (3,3) во втором. Таким образом, для данной архитектуры нейронной сети на наборе данных Fashion-MNIST выбор шага перемещения (2,2) на первом слое и (1,1) на втором, а также вышеуказанных размеров окна объединения является наилучшим выбором с точки зрения точности предсказания.

Влияние количества нейронов в полносвязных слоях на точность предсказания в базовой модели. При изменении количества нейронов в полносвязных слоях наблюдалось следующее

влияние на точность предсказания модели: при 32 и 64 нейронах точность предсказания составила 90 %. При дальнейшем увеличении количества нейронов до 128 и 256 она увеличилась до 91 %, а при 512 нейронах наблюдалась наивысшая точность предсказания – 92 %. Увеличение количества нейронов в полносвязных слоях имеет положительное влияние на точность предсказания модели. Это обусловлено тем, что большее количество нейронов позволяет модели извлекать более сложные зависимости из данных. Так, при 512 нейронах достигается наивысшая точность предсказания, что указывает на предпочтительное использование этого значения числа нейронов в рассматриваемой модели для набора данных Fashion-MNIST. Проведенные дополнительные исследования наличия переобучения не показали.

Изменение функции активации. Согласно данным, приведенным в табл. 6, можно сделать следующие выводы:

- функция активации ReLU показывает наивысшую точность предсказания – 92 %. Применение ReLU обычно является предпочтительным вследствие ее эффективности и способности к борьбе с проблемой затухания градиента;
- функции активации Sigmoid, Tanh и Leaky ReLU показывают сопоставимые результаты точности предсказания (91 %), но немного уступают ReLU в данном случае.

Таким образом, для архитектуры нейронной сети на наборе данных Fashion-MNIST функция активации ReLU является наилучшим выбором с точки зрения точности предсказания.

Изменение размера пакета и количества эпох. По результатам экспериментов с разными значениями количества эпох и размеров пакета для сверточной нейронной сети на наборе данных Fashion-MNIST можно сделать следующие выводы:

- для размера пакета с количеством нейронов 32 точность предсказания остается примерно на одном уровне (90–91 %) при увеличении количества эпох обучения от 10 до 50. В данном случае увеличении количества эпох не приводит к значительному улучшению точности распознавания;
- для размера пакета с количеством нейронов 64 наивысшая точность в 92 % достигается при 10 эпохах, затем она уменьшается до 91 % и остается на этом уровне при дальнейшем увеличении количества эпох от 20 до 50. Итак, увеличение размера пакета до 64 позволяет повысить точность при невысоком количестве эпох по сравнению с количеством нейронов, равным 32;
- для размера пакета с количеством нейронов 128 точность предсказания остается на одном уровне (91 %) при изменении количества эпох обучения от 10 до 50. То есть увеличение размера пакета до 128 не приводит к улучшению точности предсказания.

Таким образом, увеличение размера пакета до 64 при 10 эпохах обучения хоть и незначительно, но улучшает точность предсказания модели. Однако в целом для сверточной нейронной сети на наборе данных Fashion-MNIST количество эпох не имело существенного влияния на точность предсказания.

Определение оптимальных значений гиперпараметров

Оптимизация гиперпараметров играет важную роль в обучении нейронных сетей для достижения максимальной точности классификации на различных наборах данных. Для Fashion-MNIST были определены следующие оптимальные гиперпараметры.

Conv2D-слои. Первый Conv2D-слой с 32 ядрами размером (5,5) и функцией активации ReLU позволяет извлечь локальные пространственные признаки из изображений одежды, таких как текстуры и формы. Второй Conv2D-слой с 64 ядрами размером (3,3) дополнительно улучшает абстрактное представление признаков на более высоком уровне.

MaxPooling2D-слой. Первый MaxPooling2D-слой с `pool_size = (2,2)` выполняет подвыборку признаков, что способствует уменьшению размера признаковых карт и повышению инвариантности к масштабу. Второй MaxPooling2D-слой с `pool_size = (1,1)` помогает сохранить важные детали признаков для дальнейшей обработки.

Dense-слой. Полносвязный слой с 512 нейронами и функцией активации ReLU обеспечивает высокую емкость модели для изучения более сложных зависимостей в данных.

Архитектура модели. Использование модели Sequential с определенной последовательностью сверточных, пулинговых и плотных слоев обеспечивает ее эффективное обучение для задачи классификации Fashion-MNIST. Оптимальная архитектура модели приведена на рис. 1.

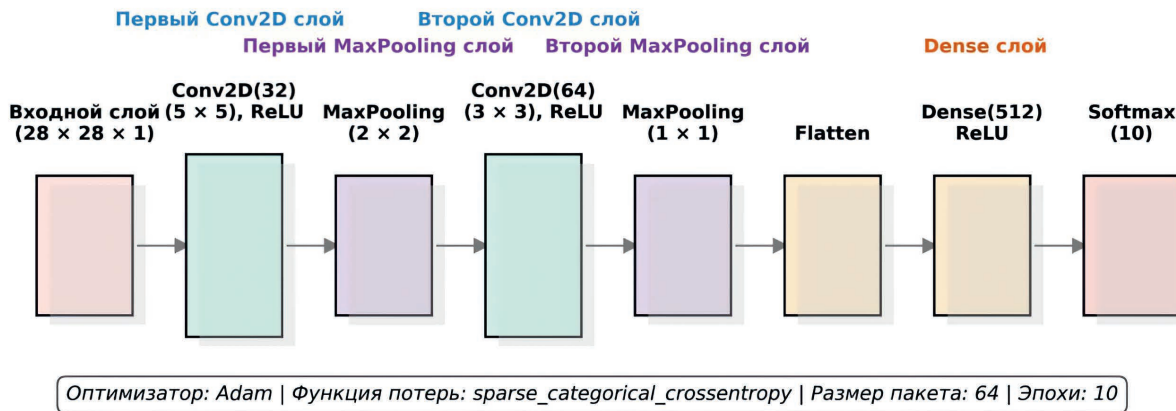


Рис. 1. Оптимальная архитектура модели
Fig. 1. Optimal model architecture

Оптимизатор и функция потерь. Оптимизатор Adam обладает хорошей скоростью сходимости и адаптивным шагом обучения, что способствует эффективной оптимизации весов модели. Функция потерь `sparse_categorical_crossentropy` применяется для многоклассовой классификации и помогает модели оценивать ошибку предсказаний.

Обучение модели. Обучение модели на 10 эпохах с размером пакета 64 обеспечивает достаточное количество итераций для настройки весов и обучения модели на данных Fashion-MNIST.

Перечисленные оптимальные гиперпараметры обеспечивают высокую точность классификации на наборе данных Fashion-MNIST (92 %) за счет эффективного извлечения признаков, адаптации модели к данным и оптимального обучения. Их подбор основан на тщательном анализе влияния каждого параметра на точность предсказания нейронной сети в процессе проведения эксперимента.

Заключение

1. Исследовано влияние гиперпараметров базовой модели сверточной нейронной сети на точность решения задачи классификации в датасете Fashion-MNIST. Рассмотрены такие параметры, как количество слоев, участвующих в операции свертки Conv2D; количество фильтров и размер ядра в каждом слое; размер и шаг pooling-слоев; количество нейронов в полносвязных слоях; функции активации; размер пакета; количество эпох обучения. Установлено, что наилучшая точность классификации достигается при следующих гиперпараметрах сети: первый Conv2D-слой с 32 ядрами размером (5,5) и функцией активации ReLU и второй Conv2D-слой с 64 ядрами размером (3,3); первый MaxPooling2D-слой с `pool_size = (2,2)` и второй MaxPooling2D-слой с `pool_size = (1,1)`; полносвязный слой с 512 нейронами и функцией активации ReLU; оптимизатор Adam и функция потерь `sparse_categorical_crossentropy`. Обучение модели оптимально проводить на 10 эпохах с размером пакета 64 для достижения наилучшей точности классификации.

2. Определены оптимальные значения приведенных гиперпараметров для достижения высшей точности предсказания и повышения обобщающей способности модели.

3. Полученные данные и выводы могут быть применены в таких областях, как компьютерное зрение, распознавание образов, анализ изображений и др.

4. Работа выполнена в рамках Государственной программы научных исследований «Фотоника и электроника для инноваций» (подпрограмма «Фотоника и ее применение», задание 1.6.1), 2021–2025 гг., № ГР 20212701.

Список литературы

1. Клейнер, С. Г. Исследование точности решения задачи оптимизации гиперпараметров с помощью нейронной сети [Электронный ресурс] / С. Г. Клейнер. Режим доступа: <https://www.xn8sbempclcwd3bmt.xnplai/article/24427>. Дата доступа: 24.12.2025.
2. Игнатьева, С. А. Влияние выбора гиперпараметров при обучении сверточных нейронных сетей на точность повторной идентификации людей в системах видеонаблюдения [Электронный ресурс] / С. А. Игнатьева. Режим доступа: <https://elib.psu.by/bitstream/123456789/34506/1/163-167.pdf>. Дата доступа: 24.12.2025.

3. Fashion MNIST [Electronic resource]. Mode of access: <https://github.com/zalandoresearch/fashion-mnist>. Date of access: 24.12.2025.
4. Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions / L. Alzubaidi [et al.] // Journal of Big Data. 2021. Vol. 8, No 53. P. 2–74. <https://doi.org/10.1186/s40537-021-00444-8>.
5. Murphy, K. P. Probabilistic Machine Learning: An Introduction / K. P. Murphy. USA: MIT Press, 2022. P. 323–358.

Поступила 27.02.2026

Принята в печать 09.03.2026

Доступна на сайте 10.07.2026

References

1. Kleiner, S. G. (2025) *Study of the Accuracy of Solving a Hyper Parameter Optimization Problem Using a Neural Network*. Available: <https://www.xn8sbempclcw3bmt.xnp1ai/article/24427> (Accessed 24 December 2025) (in Russian).
2. Ignatieva S. A. (2025) *The Impact of Hyper Parameter Selection in Convolutional Neural Network Training on the Accuracy of Person Re-Identification in Video Surveillance Systems*. Available: <https://elib.psu.by/bitstream/123456789/34506/1/163-167.pdf> (Accessed 24 December 2025) (in Russian).
3. *Fashion MNIST*. Available: <https://github.com/zalandoresearch/fashion-mnist> (Accessed 24 December 2025) (in Russian).
4. Alzubaidi L., Zhang J., Humaidi A. J., Al-Dujaili A., Duan Ye, Al-Shamma O., et al. (2021) Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions. *Journal of Big Data*. 8 (53), 2–74. <https://doi.org/10.1186/s40537-021-00444-8>.
5. Murphy K. P. (2022) *Probabilistic Machine Learning: An Introduction*. USA, MIT Press Publ. 323–358.

Received: 27 February 2026

Accepted: 9 March 2026

Available on the website: 10 July 2026

Вклад авторов

Клименко Д. М. провел экспериментальные исследования и разработку модели, участвовал в интерпретации результатов эксперимента и работе над текстом статьи.

Козлова Е. И. предложила концепцию работы, провела критический анализ модели и содержания статьи, подготовила рукопись статьи для публикации.

Authors' contribution

Klimenka D. conducted experimental research and development of the model, participated in the interpretation of the experimental results and work on the text of the article.

Kazlova A. proposed the concept of the work, conducted a critical analysis of the model and content of the article, prepared the manuscript for publication.

Сведения об авторах

Клименко Д. М., студ., Белорусский государственный университет

Козлова Е. И., канд. физ.-мат. наук, доц., зав. каф. интеллектуальных систем, Белорусский государственный университет

Адрес для корреспонденции

220064, Республика Беларусь,
Минск, ул. Курчатова, 5
Белорусский государственный университет
Тел.: +375 17 209-58-36
E-mail: kozlova@bsu.by
Козлова Елена Ивановна

Information about the authors

Klimenka D., Student, Belarusian State University

Kazlova A., Cand. Sci. (Phys. and Math.) Associate Professor, Head of the Department of Intelligent Systems, Belarusian State University

Address for correspondence

220064, Republic of Belarus,
Minsk, Kurchatova St., 5
Belarusian State University
Tel.: +375 17 209-58-36
E-mail: kozlova@bsu.by
Kazlova Alena