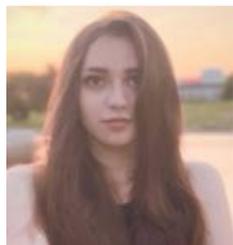


УДК 004.021:004.75

ОЦЕНКА ЗНАЧИМОСТИ ПАРАМЕТРОВ ОБУЧЕНИЯ МОДЕЛИ НЕЙРОННОЙ СЕТИ НА ПРИМЕРЕ КЛАССИФИКАТОРА ОБЪЕКТОВ НА СНИМКАХ ЗЕМНОЙ ПОВЕРХНОСТИ



Е.И. Ковшер
ассистент кафедры
электронных вычислительных
машин БГУИР, магистрант
elizavetakovsher@mail.ru



Н.В. Лапицкая
кандидат технических наук, зав.
кафедрой программного обеспечения
информационных технологий, БГУИР
lapan@bsuir.by

Е.И. Ковшер

Окончила Белорусский государственный университет информатики и радиоэлектроники. Область научных интересов связана с исследованием искусственного интеллекта и методов машинного обучения.

Н.В. Лапицкая

В 1994 году окончила факультет прикладной математики Белорусского государственного университета по специальности «прикладная математика». В 2006 году присуждена ученая степень кандидата технических наук по специальности 05.13.17 – Теоретические основы информатики. Область научных интересов связана со статистическим анализом нерегулярных данных, методами многокритериальной оптимизации, логико-вероятностными моделями, управлением рисками.

Аннотация. В исследовании проведена оценка значимости параметров обучения модели нейронной сети на примере классификатора объектов на снимках земной поверхности. Представлен комплексный анализ влияния различных факторов («объем обучающей выборки», «количество батчей» и «количество эпох обучения») на точность и устойчивость модели, что позволило определить оптимальные настройки для её обучения.

Особое внимание уделяется оценке эффективности предложенного решения. Результаты проведённых экспериментов подтверждают превосходство разработанной нейросетевой архитектуры по таким критериям, как точность классификации, скорость обработки изображений и устойчивость к изменению условий съёмки, таких как освещение, угол обзора и разрешение снимков.

Представленные выводы могут быть полезны для дальнейшего совершенствования моделей машинного обучения, используемых в задачах классификации объектов на снимках земной поверхности.

Ключевые слова: Машинное обучение, нейронные сети, DARKNET, YOLOv3, обработка геоинформационных данных.

Введение. Классификация объектов на снимках земной поверхности – важная задача, которая используется в различных областях науки, техники и экономики. Классификация позволяет извлекать ценные данные из снимков, превращая их в инструмент для анализа и принятия решений. Благодаря этому возможно более эффективное управление ресурсами, планирование и защита окружающей среды.

Объектом исследования являются снимки земной поверхности, а также объекты на снимках земной поверхности, полученных средствами дистанционного зондирования.

В качестве предмета исследования выступают методы и алгоритмы автоматического распознавания, сегментации, классификации и анализа объектов на снимках земной поверхности, основанные на современных технологиях обработки изображений и машинного обучения.

Основная цель данной работы – оценка значимости параметров обучения модели нейронной сети на примере классификатора объектов на снимках земной поверхности.

Описание модели нейронной сети для автоматического распознавания и анализа объектов на снимках земной поверхности. Тактическое планирование представляет собой определение способа проведения каждой серии испытаний машинной модели, предусмотренных планом эксперимента, и оно связано с вопросами эффективного использования выделенных для эксперимента машинных ресурсов [2].

Чем сложнее машинная модель M , тем важнее этап тактического планирования машинного эксперимента. Процесс планирования машинных экспериментов с моделью M носит итерационный характер, т. е. при уточнении некоторых свойств моделируемой системы S этапы тактического планирования экспериментов могут чередоваться. Далее будет представлена итоговая модель, в которой будут выделены наиболее значимые факторы, влияющие на точность распознавания объектов [3].

Модель системы базируется на фреймворке *DARKNET* [4] – это высокопроизводительный, гибкий и легковесный фреймворк для разработки и обучения нейронных сетей, написанный на языке программирования *C* с использованием *CUDA* и *OpenCV* для ускорения вычислений на *GPU*.

Основой фреймворка *DARKNET* является модель *YOLOv3*. Это одна из наиболее популярных моделей для обнаружения объектов на изображениях. *YOLOv3* принадлежит к семейству одноэтапных детекторов, которые обрабатывают изображение целиком за один прогон через сеть, что делает их значительно быстрее, чем двухэтапные подходы (например, *Faster R-CNN*).

Модель представляется в виде черного ящика (1):

$$\eta = \eta(x, b), \quad (1)$$

где x – факторы (входные величины); b – неизвестные параметры (коэффициенты); η – реакция системы (выходная величина).

Целью анализа экспериментальных данных является определение оценок неизвестных параметров b в некоторой заданной области факторного пространства X . Графическое представление статистической модели системы демонстрирует рисунок 1. В реальных условиях, из-за наличия помехи ε , вместо истинного значения выходной величины η необходимо измерять величину Y . Следовательно, опираясь на результаты измерения, нельзя получить абсолютно точные значения b . Вместо истинных параметров b необходимо получить оценки параметров β . Тогда, оцениваемое уравнение для модели будет иметь вид, представленный в формуле (2).



Рисунок 1. Статическая модель системы

$$Y = Y(x, \beta), \quad (2)$$

где x – факторы (входные величины); β – оценка неизвестных параметров (коэффициентов); Y – реакция системы с учетом помехи ε (выходная величина).

Общая структура планирования эксперимента. Основные этапы планирования эксперимента изложены ниже.

Вначале происходит определение цели эксперимента. В этот этап входит формулировка проблемы, которую необходимо проверить, и определение того, что нужно исследовать. Цель эксперимента, проводимого в рамках работы, заключается в исследовании влияния различных факторов – «объем обучающей выборки», «количество батчей» и «количество эпох обучения» – на точность распознавания объектов на снимках земной поверхности с использованием фреймворка *DARKNET* и модели *YOLOv3*.

Следом за определением цели эксперимента следует выбор факторов и уровней их варьирования. Данная работа предполагает полный факторный эксперимент: исследуются все возможные комбинации уровней факторов. Этот этап включает в себя определение факторов, которые могут влиять на результат эксперимента, и выбор значений (уровней) для каждого фактора. Для того чтобы понять, как факторы влияют на эффективность модели *YOLOv3* при распознавании объектов на снимках земной поверхности, эти факторы («объем обучающей выборки», «количество батчей» и «количество эпох обучения») будут варьироваться в ходе эксперимента. Каждый из этих факторов может существенно повлиять на результаты, и, играя с их уровнями, представляется возможным найти оптимальные настройки для поставленной задачи.

Чем больше изображений используется для обучения, тем лучше модель «учится» обобщать данные и распознавать различные объекты, но больше данных требуют больше времени и вычислительных мощностей. Данный фактор разделен на два уровня. Уровень 1 (низкий) – 100 изображений. Меньший объем данных может быть полезен для первоначальных экспериментов, чтобы быстро проверить, как модель обучается. Подходит для небольших проектов или быстрых прототипов. Уровень 2 (высокий) – 800 изображений. Большой объем данных позволяет модели «видеть» больше примеров, что делает её более устойчивой и точной при распознавании объектов, особенно в сложных или изменчивых условиях.

Количество батчей влияет на то, сколько примеров будет обрабатываться одновременно перед обновлением модели. Меньшие батчи дают больше вариативности, но и могут быть менее стабильными. Уровень 1 (низкий) – 8 батчей. Меньшие батчи могут быть полезны для более частых обновлений весов, что иногда ускоряет процесс обучения, но на меньших батчах точность обновлений может быть не такой высокой. Уровень 2 (высокий) – 16 батчей. Большие батчи дают более точные обновления, так как модель видит больше примеров перед изменением своих весов. Это помогает сделать обучение более стабильным, но требует больше памяти.

Эпохи – это количество полных проходов через все данные. Большее количество эпох позволяет модели дольше «учиться», но может привести к переобучению, если количество эпох слишком велико. Заключительный фактор так же включает в себя два уровня, представленных ниже. Уровень 1 (низкий) – 10 эпох. Это количество эпох подходит для начальных тестов, когда нужно проверить основные параметры модели. Меньше эпох также помогает избежать чрезмерного переобучения. Уровень 2 (высокий) – 50 эпох. С большим количеством эпох модель будет иметь больше времени для обучения, что помогает достигать лучших результатов на более сложных задачах. Однако важно следить за переобучением, если модель начинает «запоминать» тренировочные данные.

Каждый из 3 предложенных факторов будет варьироваться между двумя уровнями, что даст 8 возможных комбинаций для экспериментов ($2^3 = 8$). Это даст возможность исследовать, как каждый параметр влияет на производительность модели *YOLOv3* при распознавании объектов на изображениях земной поверхности.

Следующим этапом планирования эксперимента является определение выходных переменных (откликов). Это показатели, которые будут измеряться в ходе эксперимента.

Средняя точность (mAP) – это один из наиболее важных откликов для оценки производительности модели при решении задач распознавания объектов, таких как распознавание объектов на снимках земной поверхности. Средняя точность (mAP) учитывает как точность классификации, так и правильность локализации, формула (3):

$$mAP = \frac{1}{C} \sum_{c=1}^C \frac{1}{N_c} \sum_{k=1}^{N_c} \frac{TP_c(k)}{TP_c(k) + FP_c(k)}, \quad (3)$$

где C – количество классов (в рассматриваемой модели 60); N_c – количество точек отсечения для класса c ; $TP_c(k)$ и $FP_c(k)$ – количество истинных и ложных положительных предсказаний для класса c на уровне отсечения k .

Далее происходит обработка данных. Сбор и анализ результатов с использованием статистических методов – является неотъемлемой частью планирования эксперимента.

На этапе обработки данных собираются результаты всех проведенных экспериментов, выполняется их систематизация и проводится статистический анализ для выявления значимости влияния факторов на выходную переменную (mAP).

Поскольку эксперимент является полнофакторным, каждый фактор кодируется с помощью бинарных значений (0 и 1) для удобства последующего анализа. Низкий уровень – значение 0, высокий уровень – значение 1.

В ходе эксперимента на каждом этапе фиксировался показатель mAP (основной отклик, который используется для оценки точности модели). Все собранные данные сведены в таблицу (расширенную матрицу полнофакторного эксперимента), где каждая строка соответствует одной комбинации факторов. Таблица 1, содержащая эти данные, представлена ниже. Значения mAP рассчитывались для двух изображений, местность которых содержат разные классы объектов, пригодных к распознаванию.

Таблица 1. Расширенная матрица полнофакторного эксперимента

Номер эксперимента	Объем обучающей выборки (X_1)	Количество батчей (X_2)	Количество эпох (X_3)	mAP (1, 2)
1	0	0	0	0,124400, 0,107424
2	0	0	1	0,210523, 0,171322
3	0	1	0	0,122273, 0,107425
4	0	1	1	0,217966, 0,191696
5	1	0	0	0,198827, 0,177805
6	1	0	1	0,316848, 0,278746
7	1	1	0	0,286014, 0,244481
8	1	1	1	0,311532, 0,272263

Дисперсионный и регрессионный анализ полученных в ходе планирования эксперимента данных. Дисперсионный анализ (*ANOVA*) используется для оценки значимости влияния факторов на выходную переменную – в данном случае на mAP .

Общая цель дисперсионного анализа – проверить гипотезу H_0 , а именно: выявить наиболее значимые факторы, которые существенно влияют на точность модели. Это помогает не только лучше понять влияние каждого параметра, но и сократить время на оптимизацию, сосредоточившись на наиболее важных параметрах. Для этого используется расчет отношения межгрупповой и внутригрупповой дисперсий (4):

$$F = \frac{MS_{\text{фактор}}}{MS_{\text{ошибка}}}, \quad (4)$$

где $MS_{\text{фактор}} = SS_{\text{фактор}} / df_{\text{фактор}}$ – средний квадрат отклонений, обусловленных изменением факторов; $MS_{\text{ошибка}} = SS_{\text{ошибка}} / df_{\text{ошибка}}$ – средний квадрат отклонений, обусловленных случайными ошибками; $SS_{\text{фактор}}$ – сумма квадратов отклонений из-за влияния фактора; $SS_{\text{ошибка}}$ – сумма квадратов отклонений из-за влияния фактора; $df_{\text{фактор}}$ – сумма квадратов отклонений из-за влияния фактора; $df_{\text{ошибка}}$ – сумма квадратов отклонений из-за влияния фактора.

Общая сумма квадратов отклонений – это сумма квадратов отклонений всех наблюдений от общего среднего значения отклика (5):

$$SS_{\text{общее}} = \sum_{i=1}^N (Y_i - \bar{Y})^2, \quad (5)$$

где Y_i – значение отклика (mAP) для i -й комбинации факторов; \bar{Y} – общее среднее значение mAP по всем экспериментам; N – общее количество экспериментов.

Далее для каждого фактора рассчитывается его вклад в изменчивость отклика (6):

$$SS_{\text{фактор}} = n \sum_{j=1}^2 (\bar{Y}_{\text{фактор}_j} - \bar{Y})^2, \quad (6)$$

где $\bar{Y}_{\text{фактор}_j}$ – среднее значение отклика для j -го уровня фактора; n – число повторений для каждого уровня.

В заключение рассчитывается сумма квадратов ошибок (7):

$$SS_{\text{ошибка}} = SS_{\text{общее}} - \sum SS_{\text{фактор}}, \quad (7)$$

После расчета дисперсионного анализа можно сделать следующие выводы.

Если F -критерий для фактора окажется больше табличного значения при уровне значимости $\alpha = 0,05$, значит, данный фактор оказывает статистически значимое влияние на отклик (mAP). Если F -критерий окажется меньше табличного значения, влияние фактора можно считать незначимым.

Для удобства значения F -критериев, полученные для каждого фактора, сведены в таблицу 2.

Таблица 2. Значения F -критерия для каждого фактора

Фактор	Значение F -критерия
Объем обучающей выборки (X_1)	10,997371
Количество батчей (X_2)	0,445487
Количество эпох (X_3)	5,741693

В данном случае табличное значение F -критерия при уровне значимости $\alpha = 0,05$ – 5,41. На основании этого и сформулированной ранее гипотезы H_0 сделано заключение о том, что влияние таких факторов, как «объем обучающей выборки» и «количество эпох обучения», является значимыми, в то время как влияние фактора «количество батчей» оказывает меньшее влияния, однако его также нельзя исключать в дальнейший

исследованиях.

Регрессионный анализ используется для построения математической модели, описывающей зависимость выходной переменной (*mAP*) от значений факторов. Цель – определить, какие факторы оказывают значимое влияние на результат, и получить уравнение регрессии, с помощью которого можно предсказать значение *mAP* для новых комбинаций факторов. Для оценки коэффициентов модели используется метод наименьших квадратов (МНК).

Множественная линейная регрессия предполагает, что отклик (Y , в рассматриваемом случае – *mAP*) является линейной функцией факторов (8):

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon, \quad (8)$$

где Y – выходная переменная (*mAP*); X_1, X_2, \dots, X_n – факторы; β_0 – свободный член; $\beta_1, \beta_2, \dots, \beta_n$ – коэффициенты регрессии; ε – случайная ошибка.

Метод наименьших квадратов предполагает, что минимизируется сумма квадратов отклонений фактических значений отклика от предсказанных моделью (9):

$$S = \sum_{i=1}^N (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^N (Y_i - (\beta_0 + \sum_{j=1}^n \beta_j X_{ij}))^2, \quad (9)$$

Для нахождения коэффициентов регрессии необходимо решить систему нормальных уравнений (10):

$$X^T X \beta = X^T Y, \quad (10)$$

где X – матрица факторов; β – вектор коэффициентов регрессии; Y – вектор откликов.

Регрессионный анализ позволяет получить уравнение, описывающее зависимость *mAP* от параметров модели.

В ходе планирования данного эксперимента было получено следующее уравнение, описывающее зависимость *mAP* от параметров модели (11):

$$Y = 0,0904 + 0,0628X_1 + 0,0713X_2 + 0,0655X_3, \quad (11)$$

Анализ полученного уравнения так же подтверждает сформулированную гипотезу H_0 и говорит о значительном влиянии выдвинутых в ходе работы факторов.

Результат работы модели представлен на рисунке 2.



Рисунок 2. Результат работы модели

Заключение. На основе проведенного плана эксперимента был сделан вывод, что выдвинутая гипотеза H_0 была подтверждена на основании дисперсионного и регрессионного анализа. Анализ данных, полученных в ходе эксперимента, показал, что увеличение объема обучающей выборки, оптимизация числа батчей и увеличение числа эпох обучения приводят к значительному улучшению точности модели, а также повышают ее устойчивость и производительность. Эти факторы оказали существенное влияние на качество работы модели, что подтверждает первоначальное предположение.

Список литературы

- [1] Ковшер, Е. И. Классификация и анализ снимков земной поверхности = Classification and analysis of earth surface / Е. И. Ковшер, Д. Ю. Перцев // *BIG DATA и анализ высокого уровня = BIG DATA and Advanced Analytics* : сборник научных статей X Международной научно-практической конференции, Минск, 13 марта 2024 г. : в 2 ч. Ч. 2 / Белорусский государственный университет информатики и радиоэлектроники ; редкол.: В. А. Богуш [и др.]. – Минск, 2024. – С. 152–158.
- [2] Адлер Ю.П., Макарова Е.В., Грановский Ю.В. Планирование эксперимента при поиске оптимальных условий, М – 1967.
- [3] Шовенгердт Р.А. Дистанционное зондирование. Модели и методы обработки изображений. М.: Техносфера, 2010. – 560 с.
- [4] Darknet [Электронный ресурс] – Режим доступа: <https://github.com/pjreddie/darknet> – Дата доступа: 05.03.2025.

Авторский вклад

Ковшер Елизавета Игоревна – оценка значимости параметров обучения модели нейронной сети на примере классификатора объектов на снимках земной поверхности, планирование и проведение эксперимента, интерпретация полученных результатов.

Лапицкая Наталья Владимировна – постановка задачи исследования, анализ полученных результатов.

ASSESSMENT OF THE SIGNIFICANCE OF THE TRAINING PARAMETERS OF A NEURAL NETWORK MODEL USING THE EXAMPLE OF A CLASSIFIER OF OBJECTS IN IMAGES OF THE EARTH'S SURFACE

E.I. Kovsher

*Assistant at the Department of
Electronic Computing Machines,
BSUIR, PhD student*

N.V. Lapitskaya

*PhD of Technical Sciences,
Head of the Department of
Information Technology Software,
BSUIR*

Abstract. The research assesses the significance of the training parameters of the neural network model using the example of a classifier of objects in images of the earth's surface. A comprehensive analysis of the influence of various factors ("training data size", "number of batches" and "number of training epochs") on the accuracy and stability of the model is presented, which made it possible to determine the optimal settings for its training.

Particular attention is paid to assessing the effectiveness of the proposed solution. The results of the experiments confirm the superiority of the developed neural network architecture in such criteria as classification accuracy, image processing speed and resistance to changes in shooting conditions, such as lighting, viewing angle and image resolution.

The presented results can be useful for further improvement of machine learning models used in the tasks of classifying objects in images of the earth's surface.

Keywords: Machine learning, neural networks, DARKNET, YOLOv3, geoinformation data processing.