

Оценка эффективности нейронных сетей на основе критериев выполнения задачи классификации объектов

Н. О. Турсуков¹, И. И. Виксин², Е. А. Неверов³, Е. Л. Шейнман⁴, С. С. Чупров⁵

^{1,2,3,4}Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина)

⁴АО «Концерн «Океанприбор»

⁵ Колледж компьютерных и информационных наук им. Б. Томаса Голизано, Рочестерский технологический институт

¹stepingnik@gmail.com, ²wixnin@mail.ru, ³datnever@ya.ru,

⁴bell.sunny@yandex.ru, ⁵sc1723@rit.edu

Аннотация. В работе был проведен анализ моделей и архитектур нейронных сетей, осуществляющих решение задач идентификации и распознавания объектов на изображениях и данных локаторов. Для решения задачи классификации объектов были сформированы наборы данных, разбитые на несколько классов и включающие в себя информацию о различных объектах. В дальнейшем, при помощи тестовых данных была произведена реализация и оценка рассматриваемых нейронных сетей. Оценка методов нейронных сетей проводилась на основе сформированных критериев, в результате чего была определена таблица эффективности моделей. Рассматриваемые методы применения нейронных сетей, а также сформированные в результате оценки эффективности результаты планируются в дальнейшем применять в процессах автоматического машинного обучения.

Ключевые слова: нейронные сети; классификация объектов

I. ВВЕДЕНИЕ

Задача идентификации и распознавания объектов является одной из ключевых при анализе и обработке данных. Корректная локализация областей, объектов на изображениях и их дальнейшее распознавание применяется в различных задачах. Помимо этого, данные с различных локаторов и радиолокационных систем также учитываются для обнаружения и распознавания объектов. Так, методы анализа данных могут помочь определить подозрительные процессы в различных областях, распознать объекты на больших территориях, или обнаружить точки интереса на различных местностях.

Под распознаванием объектов на изображении зачастую подразумевается одна из задач компьютерного зрения, являющейся классификацией изображений. При этом локализацией изображений является задача обнаружения объекта на анализируемых изображениях. В то же время распознавание объектов возможно при анализе данных, получаемых различными датчиками и локаторами, а также путем обработки изображений оптическими радарными.

Работа выполнена при поддержке Министерства науки и высшего образования Российской Федерации "Госзадание" №075-01024-21-02 от 29.09.2021 (проект FSEE-2021-0014)

Классификация объектов зачастую предполагает предварительную обработку данных, а также применение методов машинного обучения (МО) и нейронных сетей (НС) для присвоения класса распознаваемому объекту. В связи с этим, важной задачей является выбор и настройка методов и моделей машинного обучения, позволяющих эффективно классифицировать большой объем данных. При внедрении задачи классификации в процессах автоматического машинного обучения, данная задача приобретает дополнительную важность.

Автоматическое машинное обучение является процессом автоматизации проведения этапов машинного обучения, позволяющим конечному пользователю достигать необходимых целей, не обладая глубокими знаниями о процессе работы методов машинного обучения. В связи с этим, в задаче классификации объектов необходимо учитывать эффективность используемых нейронных сетей и методов МО для определения различных классов.

Таким образом, необходимо провести анализ и выбор математических моделей и архитектур нейронных сетей, осуществляющих решение задач идентификации и распознавания различных объектов.

Необходимо провести оценку существующих методов обработки данных, получаемых при анализе различных объектов. Полученные результаты в дальнейшем можно будет применять в задаче определения принципов работы собственных математических моделей в процессах автоматического МО. Так, собственная модель в дальнейшем может быть разработана на основе оценки алгоритмов НС с точки зрения того, насколько точно они могут распознать схожие объекты, а также на основе структурно схожих наборов данных.

II. ОБЗОР СУЩЕСТВУЮЩИХ РЕШЕНИЙ

Были рассмотрены различные методы и исследования, берущие за основу нейронные сети и классифицирующие различные объекты на основе собираемых данных различными датчиками.

В статье [1] предлагается глубокая конволюционная нейронная сеть, вдохновленная слуховым восприятием,

для распознавания подводных акустических целей. Более глубокие характеристики с присущей цели информацией извлекаются каждой подсетью глубокого фильтра, что отражает структуру извлечения глубокой акустической информации слуховой системы. Сигналы шума, излучаемого кораблем, разлагаются на различные частотные компоненты с помощью многомасштабных фильтров глубокой свертки, что отражает нейронный механизм восприятия частотных компонентов и выявляет распределение различных частотных компонентов в шуме, излучаемом кораблем.

В статье [2] рассмотрена процедура обучения нейронной сети, примененная к классификации сигналов сонара от двух целей, металлического цилиндра и скалы аналогичной формы. Сети с промежуточным слоем скрытых процессоров достигли точности классификации до 100 % на обучающем наборе из 104 результатов. Эти сети правильно классифицировали до 90,4 % из 104 тестовых результатов, не содержащихся в обучающей выборке.

Следующее исследование [3] направлено на выявление наилучшей комбинации методов, которые можно использовать для задачи классификации. Этот проект касается как области анализа сигналов, так и искусственного интеллекта, поскольку система состоит из двух частей. Первый – это метод извлечения информативных признаков из данных, захваченных датчиком. Вторая часть – передать обработанные данные в нейронную сеть и предоставить классификацию типа объекта. Система смогла поместить 97,3 % объектов в правильную категорию при использовании наивысшей комбинации метода извлечения признаков и нейронной сети.

В работе [4] предлагается новая глубинная сепарабельная сверточная нейронная сеть для идентификации корабельного излучаемого шума по исходным волновым формам временной области в сквозном режиме. Глубинные особенности, содержащие внутреннюю информацию о цели, извлекаются сверточной сетью DWS, которая отражает глубокую структуру извлечения акустической информации слуховой системы. Несмотря на высокий уровень распознавания, между ним и практическим применением все еще существует определенный разрыв, и уровень распознавания нуждается в дальнейшем улучшении. Результаты эксперимента также показывают, что извлеченные 100-мерные признаки подводной акустической цели обладают хорошей разделительностью и стабильностью, а метод глубокого обучения на основе слухового восприятия имеет большой потенциал в улучшении классификационных характеристик распознавания подводных акустических целей.

По результатам исследования нейронных сетей к полученным данным, были сделаны следующие выводы. В целом, нейронные сети справляются с задачей, однако обозначенной осталась проблема подбора оптимальных параметров для различных условий, такие как количество слоев в архитектуре нейронной сети, а также прочие характеристики, связанные с формированием алгоритмов. Помимо этого, дополнительную наибольшую сложность несет экспертный выбор наиболее подходящих топологий нейронных сети под те или иные данные, что в условиях работы с разными

данными может быть затруднительным и требует привлечения экспертов в области машинного обучения.

В связи с этим, в результате исследования были выделены преимущества и недостатки различных нейронных сетей, наиболее эффективно справляющимися с обработкой и анализом получаемых данных. Обобщенная информация по преимуществам и недостаткам различных методов нейронных сетей представлена в табл. 1.

ТАБЛИЦА I. ПРЕИМУЩЕСТВА И НЕДОСТАТКИ НС

| Нейронная сеть | Преимущества | Недостатки |
|-----------------------------|--|--|
| Сверточная нейронная сеть | Высокая способность к обобщению информации | Необходимость в большом количестве примеров для обучения, высокие временные и вычислительные затраты |
| Перцептрон | Простота реализации, возможность обработки разнотипных данных | Низкая способность к обобщению информации |
| Рекуррентная нейронная сеть | Может обрабатывать ввод любой длины, может использовать свою внутреннюю память | Высокие временные и вычислительные затраты, НС склонна к проблемам взрыва и исчезновения градиента |

В ходе анализа нейронных сетей, для реализации и тестирования был выбран многослойный перцептрон. Данная нейронная сеть при своей простоте в реализации, позволяет обрабатывать разнотипные данные. В задаче классификации и распознавания объектов это преимущество позволит работать с информацией, получаемых различными локаторами или радарными, а также эффективно применять в процессах автоматического машинного обучения.

III. ОЦЕНКА ЭФФЕКТИВНОСТИ НЕЙРОННЫХ СЕТЕЙ НА ТЕСТОВЫХ ОТКРЫТЫХ ДАННЫХ

Для реализации и тестирования нейронной сети были подобраны наборы данных, представленные в табл. 2.

ТАБЛИЦА II. НАБОРЫ ДАННЫХ

| Набор данных | Признаки | Классы |
|---|--|--|
| Doppler data: Набор данных для распознавания автомобиля, человека, дрона | Признаки матрицы радара (по вертикали – доплеровские частоты, dBm, по горизонтали – ячейки расстояния) | <ul style="list-style-type: none"> автомобиль человек дрон |
| Winnipeg data: Набор данных для классификации пахотных земель | Данные радара, радиометрическая информация | <ul style="list-style-type: none"> кукуруза горох рапс соя овес пшеница широколиственные культуры |

В наборе данных [5] представлены измерения данных, полученных от радиолокационной системы. Набор содержит 17485 наблюдений. Радар использовал частотно-модулированный непрерывный сигнал в полосе частот с центром на частоте 8.75 ГГц с максимальной шириной полосы 500 МГц.

После цепочки цифровой обработки сигнала была получена матрица 4092x512 для каждого наблюдения, где строки – ячейки расстояний, столбцы – доплеровские частоты (единицы измерения значений – дБм). Количество значений в данной матрице было уменьшено до количества, соответствующего обнаруженному объекту, и размер результирующих матриц составил 11x61. Визуализация доплеровских частот представлена на рис. 1.

Из рис. 1 видно, что паттерны матриц отличаются своеобразием для всех классов, что делает возможным и целесообразным построение системы классификации для этого набора данных. Матрица для класса «человек» в центре имеет область высоких значений дБм, которая складывается в вытянутую вертикальную фигуру. Матрица для класса «автомобиль» в центре представляет собой вытянутую горизонтальную фигуру.

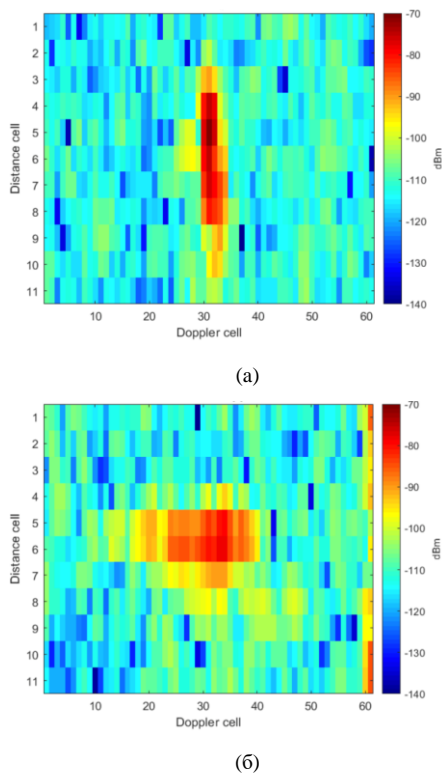


Рис. 1. Визуализация доплеровских частот: (а) – для автомобиля; (б) – для человека

Набор данных [31] содержит двухвременные данные оптического радара для классификации пахотных земель в табличной форме, полученные из изображений, собранных спутниками RapidEye, и поляриметрической радиолокационной информации, собранной беспилотными летательными аппаратами над сельскохозяйственным регионом недалеко от Виннипега (Канада), 5 и 14 июля 2012 г. Набор включает в себя 325834 наблюдений и 7 классов сельскохозяйственных культур (кукуруза, горох, рапс, соя, овес, пшеница или широколиственные культуры). Распределение классов представлено на рис. 2.

Число наблюдений для класса «1» равно 39162, для класса «2» – 3598, для класса «3» – 75673, для класса «4» – 74067, для класса «5» – 47117, для класса «6» – 85074, для класса «7» – 1143. Из рис. 4 можно сделать вывод, что соотношение наблюдений для разных классов не сбалансировано, поскольку число наблюдений для

класса «7» относится к числу наблюдений для класса «6» как 0.01, однако для проведения тестов с целью определения применимости методов машинного обучения было решено отнести данное условие к разряду допустимых.




Рис. 2. Распределение данных в наборе данных

Для найденных наборов данных была произведена проверка эффективности нейронных сетей – многослойных перцептронов. Оптимизация архитектуры и параметров производилась вручную. Оценка различных методов производилась на АРМ с процессором Intel Core i7-9700KF. Обучение нейронной сети занимало от 1 минуты до 10 минут – время работы зависело от размера набора данных и количества эпох обучения.

Для оценки эффективности рассчитывались метрики Accuracy, Precision, Recall, F1. Их расчет представлен в (1) – (4) соответственно:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}, \quad (1)$$

$$\text{Precision} = \frac{TP}{TP + FP}, \quad (2)$$

$$\text{Recall} = \frac{TP}{TP + FN}, \quad (3)$$

$$F1 = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}}. \quad (4)$$

где: TP – число истинно-положительных распознаваний; TN – число истинно-отрицательных распознаваний; FP – число ложно-положительных распознаваний; FN – число ложно-отрицательных распознаваний.

В табл. 3 представлены результаты оценки нейронной сети на тестовых выборках.

ТАБЛИЦА 3. МЕТРИКИ ОЦЕНКИ НЕЙРОННЫХ СЕТЕЙ

| Метрика | Doppler data | Winnipeg data – первый период | Winnipeg data – второй период |
|-------------------|--------------|-------------------------------|-------------------------------|
| Accuracy | 0.86 | 0.9 | 0.86 |
| Precision (macro) | 0.86 | 0.9 | 0.87 |
| Recall (macro) | 0.86 | 0.9 | 0.82 |
| F1 (macro) | 0.86 | 0.9 | 0.83 |

Общая точность нейронных сетей на разных наборах данных превысила 0.85. На основе результатов работы нейронной сети для каждого тестового набора данных была построена матрица ошибок.

Матрицы ошибок представлены на рис. 3.

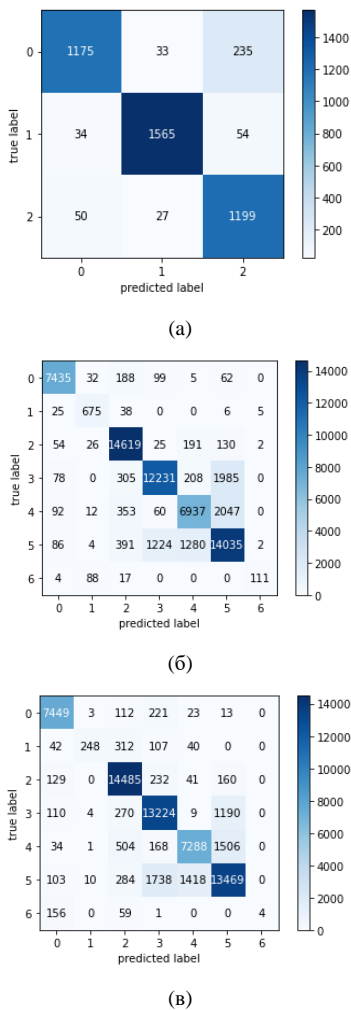


Рис. 3. Матрицы ошибок нейронных сетей для тестовых наборов: (а) dopplerdata; (б) – первый временной период Winnipegdata; (в) – второй временной период Winnipegdata

Нейронные сети показали высокое качество классификации – таким образом, они тоже могут быть использованы при решении задач распознавания объектов. Исходя из данных анализа (табл. 3) и совокупности метрик, представленных в ней, для работы с наборами входных данных был получен результат, позволяющий применить рассматриваемую нейронную сеть в задачах автоматического машинного обучения.

IV. ЗАКЛЮЧЕНИЕ

В ходе работы был проведен обзор методов классификации, потенциально применимых для решения поставленной задачи распознавания объектов. Также был проведен сравнительный анализ нейронных сетей, используемых непосредственно в задачах классификации, на открытых тестовых данных. В ходе анализа существующих решений был выбран многослойный перцептрон для дальнейшей реализации на тестовых данных.

Для оценки эффективности различных методов машинного обучения было подобрано 2 набора данных, произведены оптимизация гиперпараметров и обучение моделей. Нейронная сеть доказала свою применимость для подобранных наборов данных.

СПИСОК ЛИТЕРАТУРЫ

- [1] Yang H. et al. A deep convolutional neural network inspired by auditory perception for underwater acoustic target recognition // Sensors. 2019. Т. 19. №. 5. С. 1104.
- [2] Gorman R.P., Sejnowski T.J. Analysis of hidden units in a layered network trained to classify sonar targets // Neural networks. 1988. Т. 1. №. 1. С. 75-89.
- [3] Gimse H. Classification of Marine Vessels Using Sonar Data and a Neural Network :дис. NTNU, 2017.
- [4] Hu G., Wang K., Liu L. Underwater acoustic target recognition based on depthwise separable convolution neural networks //Sensors. 2021. Т. 21. №. 4. –С. 1429.
- [5] RealDopplerRAD-DARdatabase [Электронный ресурс]. – Режим доступа: <https://www.kaggle.com/datasets/iroltan/real-doppler-raddar-database>, свободный. Яз. англ. (дата обращения 25.02.2023).
- [6] CroplandMapping [Электронный ресурс]. – Режим доступа: <https://www.kaggle.com/datasets/pcbreviglieri/cropland-mapping>, свободный. Яз. англ. (дата обращения 25.02.2023).