



М.А. Лихачев, А.И. Уваров, Б.К. Тельных, А.А. Зенкин

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ КЛАССИФИКАЦИИ ОБЪЕКТОВ ВОЗДУШНОЙ РАЗВЕДКИ ПО ТЕПЛОФИЗИЧЕСКИМ ХАРАКТЕРИСТИКАМ ЭТАЛОННЫХ МАТЕРИАЛОВ

(ВУНЦ ВВС «ВВА» г. Воронеж)

Современные оптико-электронные системы (ОЭС) размещаемые на беспилотных летательных аппаратах (БПЛА) повысили эффективность поиска и обнаружения объектов воздушной разведки, увеличили объем информации об объектах разведки, позволили непрерывно вести ее разное время суток и в различных условиях. Однако, в процессе эксплуатации данных систем появилась проблема оперативной и качественной обработки постоянно увеличивающегося потока информации.

Для решения проблемы корректной обработки объемного потока сведений следует автоматизировать ряд операций, таких как: поиск и выделение объекта разведки, сравнения имеющихся по нему данным с последующей оценкой, корреляции нескольких изображений одного и того же объекта, определение границ объекта, выделение его из фона и фильтрацию шумов, а также распознавание объекта разведки до вида, класса, типа. [1]

Для решения задачи поиска и классификации объектов применяются методы машинного обучения, однако необходимо ввести в алгоритм работы нейронной сети (НС) идентификационный признак, позволяющий классифицировать обнаруженные объекты по теплофизическим параметрам (ТФП) материалов. Необходимо добиться устойчивой классификации объектов разведки НС по их ТФП в грациях в ИК-диапазоне длин волн.

Нейросетевой подход к решению нестационарных теплофизических задач заключается в следующем [2]. Требуется в области Ω найти решение уравнения:

$$\frac{du}{dt} = A(u) + f(x), x \in \Omega \subset R^{\phi}, \quad (1)$$

удовлетворяющее условию на границе Γ :

$$B(U) = G(X), X \in \Gamma \quad (2)$$

Целью обучения НС является поиск оптимального набора весовых коэффициентов (экстремума функции) для минимизации ошибки сети.

В качестве алгоритма обучения определен метод обратного распространения ошибки на основе масштабируемого метода сопряженных градиентов.

Исходными данными для обучения НС приняты разновременные изображения в видимом и ИК – диапазоне длин волн с заранее известным расположением эталонных материалов, полученные с ОЭС БПЛА в ходе натурного суточного эксперимента (рисунок 1).




Рисунок 1 – Фотоснимки эталонных материалов в ИК и видимом диапазонах длин волн

Полученное множество входных параметров обучающей выборки представляет собой матрицу размерностью 15 x 500, строки которой соответствуют типу эталонного материала в каждом слое кубоида разновременных псевдоцветных ИК – изображений, а столбцы – градации яркости, которым соответствуют значения радиационных температур в выделенных областях изображений. Значения градации яркости приведены к логарифмическому масштабу для удобства выполнения численных расчетов. Графически обучающая выборка НС представлена на рисунке 2.

Алгоритм НС реализован в программной среде MATLAB R2014a с применением библиотеки формирования нейронных сетей Neural Network Toolbox.

На рисунке 3 графически представлен процесс обучения НС, время обучения составило 51 эпоху.

Сформирована матрица несоответствий классификатора, который был создан в результате обучения НС (рисунок 4). Стоит отметить, что на суммарной матрице доля ошибочной классификации объектов сведена к нулю.

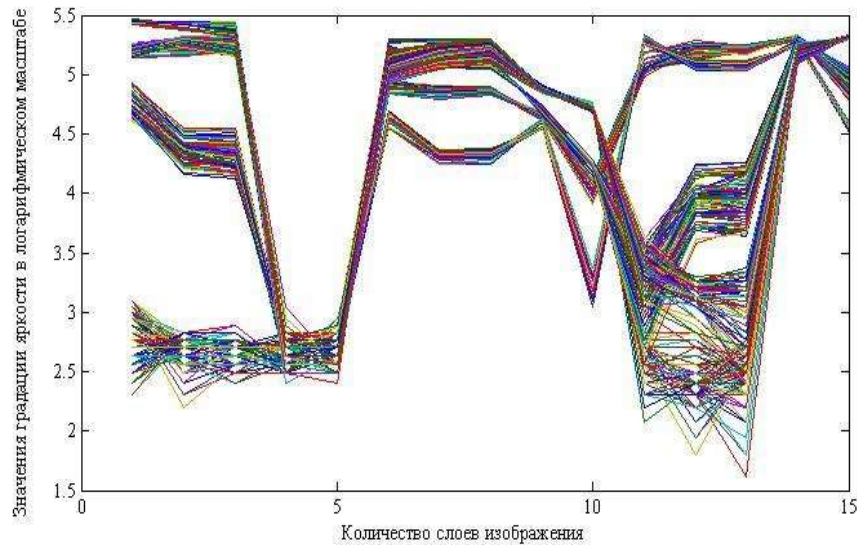


Рисунок 2 – График входных параметров обучающей выборки НС

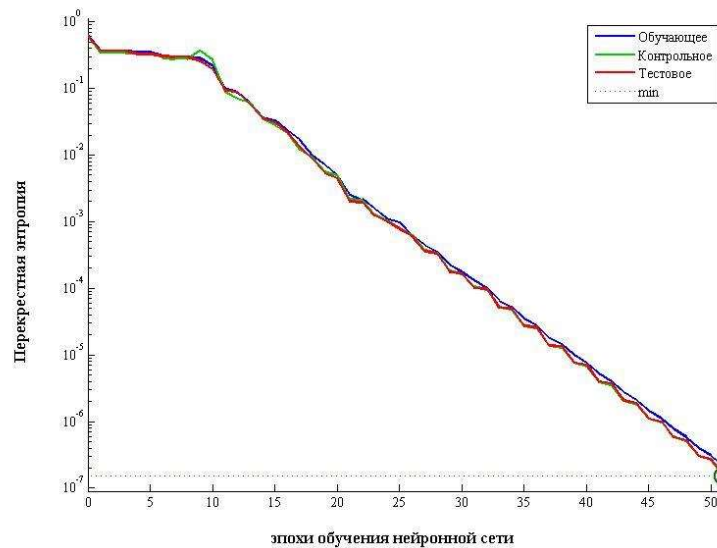


Рисунок 3 – График обучения нейронной сети

Для тестирования работы НС выбран кубоид 8 псевдоцветных ИК – изображений с заранее известным расположением эталонных материалов, полученных в результате суточного натурального эксперимента. Результат работы полученного нейросетевого алгоритма (рисунок 5), подтвердил возможность классификации объектов по ТФП материалов.

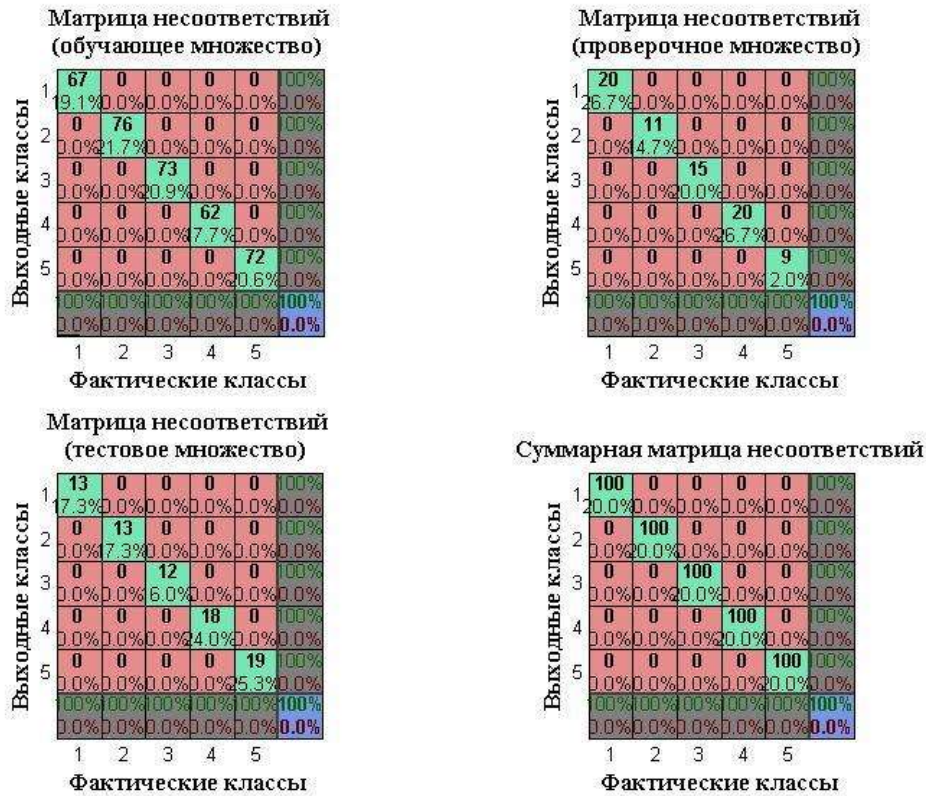


Рисунок 4 – Матрицы несоответствий классификатора НС




Рисунок 5 – Результат обработки нейронной сетью тестового изображения

На классифицированном изображении кроме эталонных объектов: эталон 1 – «песок», эталон 2 – «зеркало», эталон 3 – «пенопласт белый», эталон 4 – «пенопласт черный», эталон 5 – «металл», выявлены подповерхностные объекты – металлические диски под песком и под маскировочной сетью.



Таким образом, полученные результаты доказывают возможность практического применения нейронных сетей для автоматизированной обработки разновременных ИК – изображений получаемых с ОЭС БПЛА при ведении воздушной разведки с классификацией объектов по ТФП материалов.

Литература

1. Студитский А.С. Исследование и разработка многофункционального оптико-электронного средства наблюдения и разведки/ Студитский А.С. – М.: НИИ и МНПО «Спектр», 2013. – 112 с.
2. Ищук И.Н., Громов Ю.Ю., Постнов К.В., Степанов Е.А., Тяпкин В.Н. Корреляционная обработка кубоида инфракрасных изображений, получаемых с беспилотных летательных аппаратов. Часть 1. Моделирование и обработка инфракрасных сигнатур техногенных объектов в процессе суточного изменения температур // Техника и технологии, 2016. – № 9(3). С. 310–318.
3. Веселов, Ю. Г.; Островский, А. С.; Сельвесюк, Н. И. В сборнике: Состояние и перспективы развития современной науки по направлению «Техническое зрение и распознавание образов». Сборник научно-технической конференции, 2019. С. 173-175.
4. Ищук И.Н., Долгов А.А., Филимонов А.М., Дмитриев Д.Д. Методика оценки динамики изменения вероятностных характеристик распознавания объектов воздушной разведки // Журнал Сибирского федерального университета. Серия: Техника и технологии, 2019. – Т. 12. – №6.– С. 683-693.

А.Л. Мажаров, А.А. Столбова

РЕШЕНИЕ ЗАДАЧИ КЛАССИФИКАЦИИ НАУЧНЫХ ПУБЛИКАЦИЙ СРЕДСТВАМИ НЕЙРОННЫХ СЕТЕЙ

(Самарский университет)

Одним из этапов проведения научно-технических конференций является контент-анализ и сбор научных публикаций, присылаемых авторами в адрес организаторов. Контент-анализ публикаций включает в себя их классификацию по тематическим секциям конференции. Как правило, секцию выбирает либо участник конференции, либо организаторы, что может вести к неточностям в составлении программы. В рамках данной работы предлагается автоматизировать процесс классификации научных публикаций.

Для решения поставленной задачи применялись три вида нейронных сетей, наиболее часто применяющихся при решении задачи классификации [1]:

- одномерная сверточная нейронная сеть CNN;
- рекуррентная нейронная сеть LSTM;
- рекуррентная нейронная сеть GRU.

Моделирование и обучение выбранных нейронных сетей осуществлялось с помощью библиотеки Keras, написанной на языке Python [2].