

ОЦЕНКА ВЛИЯНИЯ ПРЕДОБРАБОТКИ ДАННЫХ НА ТОЧНОСТЬ РАСПОЗНАВАНИЯ ПАРАМЕТРОВ СУПЕРПОЗИЦИИ ОПТИЧЕСКИХ ВИХРЕЙ ПО ИЗОБРАЖЕНИЯМ ИНТЕНСИВНОСТИ

Д.О. Шилов¹

¹Самарский национальный исследовательский университет, г. Самара
e-mail: do.shilov@yandex.ru

Аннотация

Работа посвящена исследованию способов повышения точности классификации параметров оптических вихрей (ОВ) в различных плоскостях при распространении. Приведены результаты экспериментов по обучению свёрточных нейронных сетей (СНС) на различных тренировочных и тестовых наборах данных. Показано влияние применения нелинейных преобразований и увеличения набора данных (НД) на среднеквадратическое отклонение (СКО) значений точности классификации.

Ключевые слова: суперпозиция оптических пучков, турбулентность, набор данных, нейронные сети, классификация, ResNet, accuracy.

Введение

На протяжении нескольких десятилетий ОВ остаются приоритетным направлением волновой оптики благодаря широким перспективам использования, таким как оптическое манипулирование микрочастицами [1], системы передачи информации [2], квантовая криптография [3]. В последние годы растет интерес к распознаванию и классификации сложных ОВ [4, 5], особенно на основе СНС [6, 7]. В данной работе проведено исследование повышения точности распознавания параметров ОВ, что имеет важное прикладное значение, в особенности при наличии искажений, возникающих в процессе распространения.

1. Суперпозиция вихрей как геометрическая прогрессия с параметром

В работе рассматривались суперпозиции ОВ в виде геометрической прогрессии с параметром. Комплексная амплитуда подобных пучков имеет следующий вид [8]:

$$E_{1nl}(r, \varphi) = e^{-\frac{r^2}{\omega^2}} \times (a^l e^{ilm\varphi} + a^{l+1} e^{i(l+1)m\varphi} + \dots + a^n e^{inm\varphi}), \quad (1)$$

где a – действительный параметр, n, m, l – целые параметры.

2. Распознавание исходного набора данных.

В качестве первого эксперимента было создано 500 уникальных изображений распределений интенсивностей суперпозиции ОВ на расстоянии Рэлея. В качестве оператора распространения пучка в пространстве использовалось преобразование Френеля. В качестве значений параметров для моделирования были выбраны следующие диапазоны:

$$n \in [2, 6], \quad n \in \mathbb{Z}, \quad (2)$$

$$l \in [0, n - 1] \forall n, l \in \mathbb{Z}, \quad (3)$$

$$m = [1,5], m \in \mathbb{Z}, \quad (4)$$

$$a = \{0.5, 0.8, 1, 1.2, 1.5\}. \quad (5)$$

В качестве СНС для обучения выбрана архитектура ResNet-18. Для каждого параметра было выполнено 20 независимых экспериментов с различными наборами исходной случайной последовательности для разделения выборки на обучающую и тестовую в соотношении 80% на 20%. Параметр batch size выбран равным 32, learning rate выбран равным 0,001. Для последнего слоя learning rate равен 0,01. В качестве оптимизатора – Adam.

На рисунке 1 и 2 представлены графики точности распознавания каждого из параметров для каждого из 20 экспериментов при обучении с помощью ResNet на 10 и 100 эпохах соответственно.




Рисунок 1 – Точность распознавания параметров a, n, m, l на 10 эпохах




Рисунок 2 – Точность распознавания параметров a, n, m, l на 100 эпохах

Как видно из рисунка 2, модель демонстрирует значительное улучшение стабильности работы. Наблюдается как рост средних значений точности классификации, так и уменьшение разброса показателей между отдельными экспериментами, за исключением сильных единичных выбросов.

3. Применение преобразования в виде извлечения квадратного корня из интенсивности

Следующим этапом исследование была проверка гипотезы о возможности улучшения качества классификации параметров ОВ за счет преобразования исходного НД. Применение этого преобразования позволяет выявить часть особенностей распределений интенсивностей. На рисунке 3 представлены графики точности распознавания каждого из параметров для каждого из 20 экспериментов.




Рисунок 3 – Точность распознавания параметров a, n, m, l на 100 эпохах с применением операции извлечения квадратного корня из интенсивности

4. Применение случайных искажений для увеличения набора данных

Для каждого уникального набора значений из исходного НД было сгенерировано 20 различных изображений. Общими для всех изображений были параметры длины когерентности $\rho_0(z)=0,2682$ и диапазон изменения фазовых скачков $\sigma = \pi$. Уникальность искажений для каждого из 20 изображений при фиксированных параметрах ОБ достигалась за счет использования различных значений параметра seed. На рисунке 4 представлены графики точности распознавания каждого из параметров для каждого из 20 экспериментов при увеличении НД с помощью случайных искажений.




Рисунок 4 – Точность распознавания параметров a , n , t , l после прохождения турбулентной среды на 10 эпохах

Таблица 1 – Средние значения точности распознавания параметров по каждому исследованию

	a	n	l	m
1	0,5005	0,4430	0,6750	0,9230
2	0,7465	0,7810	0,9580	0,9870
3	0,8945	0,8430	0,9770	0,9985
4	0,9022	0,9025	0,9458	0,9994

Таблица 2 – СКО при распознавании параметров по каждому исследованию

	a	n	l	m
1	0,1865	0,1115	0,1825	0,1578
2	0,2073	0,1187	0,0905	0,0431
3	0,0910	0,1621	0,0633	0,0067
4	0,0053	0,0061	0,0060	0,0007

Заключение

В ходе работы было проведено исследование способов повышения точности классификации параметров суперпозиции ОБ. В ходе экспериментов было установлено, что архитектура ResNet позволила достичь средней точности распознавания 74,65% до 98,7% на исходном НД при обучении на 100 эпохах. В результате применения преобразования средняя точность стала располагаться в диапазоне от 84,3% до 99,85%. Средняя точности классификации на НД, состоящем из 10000 изображений 500 различных пучков с уникальными значениями параметров после прохождения турбулентных сред составила от 90.22% до 99.94%.

Список использованных источников

1. Эритроцит в поле пучка лазерного пинцета / П. Б. Ермолинский, А. Е. Луговцов, А. Н. Семенов, А. В. Приезжев // Квантовая электроника. – 2022. – Т. 52, № 1. – С. 22–27.
2. Регистрация орбитального углового момента лазерного пучка через его разложение по оптическим вихрям и его использование в системе связи в турбулентной атмосфере / В. П. Аксенов, В. В. Дудоров, В. В. Колосов [и др.] // Оптика атмосферы и океана. – 2020. – Т. 33, № 5. – С. 347–357.
3. Аксиально-симметричные пучки Эрмита-Гаусса и протокол BB84 на их основе для канала квантовой криптографии Космос-Земля / А. Л. Соколов, В. М. Петров, В. Ю. Венедиктов, Д. Д. Решетников // Фотоника. – Т. 17, № 7. – С. 1–14.
4. Yao, K. Intelligent nanophotonics: merging photonics and artificial intelligence at the nanoscale / K. Yao, R. Unni, Y. Zheng // Nanophotonics. – 2019. – V. 8, № 3. – P. 339–366.
5. Deep-learning-based recognition of multi-singularity structured light / H. Wang, X. Yang, Z. Liy [et al.] // Nanophotonics. – 2022. – V. 11, № 4. – P. 779–786.
6. Convolutional neural network based atmospheric turbulence compensation for optical orbital angular momentum multiplexing / W. Xiong, P. Wang, M. Cheng [и др.] // Journal of Lightwave Technology. – 2020. – V. 38, № 7. – P. 1712–1721.
7. Artificial neural networks for photonic applications – from algorithms to implementation: tutorial / P. Freire, E. Manuylovich, J. E. Prilepsky [et al.] // Advances in Optics and Photonics. – 2023. – V. 15, № 3. – P. 739–834.
8. Котляр, В. В. Топологический заряд суперпозиции оптических вихрей, описываемой геометрической прогрессией / В. В. Котляр, А. А. Ковалёв // Компьютерная оптика. – 2022. – Т. 46, № 6. – С. 864–871.

EVALUATION OF THE EFFECT OF DATA PREPROCESSING ON THE ACCURACY OF RECOGNITION OF OPTICAL VORTEX SUPERPOSITION PARAMETERS FROM INTENSITY IMAGES

D.O. Shilov¹

¹*Samara National Research University, Samara
e-mail: do.shilov@yandex.ru*

Abstract

The work is devoted to the study of ways to improve the accuracy of classification of optical vortex parameters in various planes during propagation. The results of experiments on training convolutional neural networks on various training and test datasets are presented. The effect of applying nonlinear transformations and increasing the data set on the standard deviation of classification accuracy values is shown.

Keywords: superposition of optical beams, turbulence, dataset, neural networks, classification, ResNet, accuracy.