

СРАВНИТЕЛЬНЫЙ АНАЛИЗ НЕЙРОННЫХ СЕТЕЙ RESNET, ALEXNET И VGG ДЛЯ ЗАДАЧИ РАСПОЗНАВАНИЯ ПАРАМЕТРОВ ПУЧКОВ ЛАГЕРРА-ГАУССА С УВЕЛИЧЕННОЙ ОБЛАСТЬЮ ТЕМНОГО

И.В. Соболев¹

¹Самарский университет, г. Самара
e-mail: sobolev.ilya.ff0000@gmail.com

Аннотация

Работа посвящена изучению распознавания топологического заряда оптических вихрей Лагерра-Гаусса с увеличенной областью темного с использованием сверточных нейронных сетей. Приведены результаты распознавания топологического заряда оптических вихрей с использованием архитектур AlexNET, ResNET и VGG.

Ключевые слова: пучки Лагерра-Гаусса, преобразование Френеля, атмосферная турбулентность, вихревые пучки, топологический заряд, сверточные нейронные сети, AlexNET, ResNet, VGG.

Введение

Оптические вихри (ОВ), в частности пучки Лагерра-Гаусса (ЛГ) [1-2], стали ключевыми инструментами в современных оптических технологиях в последние десятилетия [3]. Их уникальные свойства, такие как наличие фазовой сингулярности и орбитального углового момента, открывают новые возможности для передачи и обработки информации [4]. Однако при распространении в реальных условиях, атмосферная турбулентность вызывает флуктуации показателя преломления, приводящие к случайным изменениям интенсивности и фазы лазерного пучка, что в конечном итоге приводит к значительному затруднению распознавания его параметров [5]. Решением этой проблемы может стать нахождение более устойчивых к турбулентности пучков и применение нейронных сетей (НС) для распознавания параметров ОВ. В настоящей работе представлены результаты распознавания топологического заряда (ТЗ) ОБЛГ с увеличенной областью темного с использованием сверточных НС AlexNET, ResNET и VGG.

1. Оптический вихрь Лагерра-Гаусса с увеличенной областью темного

Пучки ЛГ с увеличенной областью темного представляют собой особый класс оптических мод, которые характеризуются наличием расширенной центральной области с нулевой интенсивностью [6]. Эти пучки являются точным решением параксиального уравнения Гельмгольца:

$$E_{inc}(r, \phi) = e^{(-(\frac{r}{w_0})^2 + i(m-n)\phi)} \left(\frac{r}{w_0}\right)^{m+n} L_n^m \left(\left(\frac{r}{w_0}\right)^2\right), \quad (1)$$

где r – радиальная координата, ϕ – азимутальная координата, L_n^m – обобщенный многочлен Лагерра. Благодаря своей структуре эти пучки представляются слабо подверженными атмосферным искажениям, что позволит увеличить дальность и скорость передачи данных.

2. Материалы и методы

Для обучения НС производилась генерация наборов данных (НД), состоящих из распределений интенсивности ОБЛГ с увеличенной областью темного (1) на двойном расстоянии Рэлея $z = 2z_0$ без турбулентности и после распространения в турбулентной среде. Для моделирования эволюции оптического поля во время распространения использовалось преобразование Френеля [7]. Для генерации НД в качестве значений для моделирования были зафиксированы радиус когерентности $\rho_0 = 0,087$ мм и интенсивность турбулентности $\sigma = \pi$ [8]. Диапазоны параметров следующие:

$$n \in [1,7], n \in \mathbb{Z}, m \in [2,8], m \in \mathbb{Z}. \quad (2)$$

Для аугментации НД использовались аффинные преобразования изображений, включающие сдвиги и наклоны, которые имитируют угловые искажения, вызванные ошибками позиционирования оптической системы. На рисунке 1 показаны фрагменты сгенерированных НД.




Рисунок 1 – Фрагменты полученных НД

В данной работе было проведено исследование эффективности выбранных архитектур НС. Для определения точности распознавания мы использовали метрику точности, которая имеет следующий вид:

$$\text{accuracy} = \frac{TP+TN}{TP+TN+FP+FN}. \quad (3)$$

НС обучались на изображениях 227 на 227 с размером батча 32, оптимизатором *Adam* с шагом обучения 10^{-4} и функцией потерь в виде суммы двух кросс-энтропий для параметров n и m . Использовалась смешанная точность (*AMP*) и ранняя остановка при отсутствии улучшения валидационной ошибки в течение 10 эпох, что приводило к фактической длительности обучения 32-50 эпох.

Для оценки устойчивости моделей и уменьшения влияния успешного или неудачного разделения НД исходный НД был разделен на обучающую, валидационную и тестовую выборки с использованием различных значений гиперпараметра *seed*.

3. Результаты распознавания

Результаты распознавания параметров и ТЗ ОБ на НД без турбулентности представлены в таблице 1 и на НД с турбулентностью в таблице 2.

Таблица 1 – Результаты распознавания параметров и ТЗ ОБ на НД без турбулентности

Модель	Выборка данных	n , %	m , %	ТЗ, %
AlexNET	Обучающая	99,6	98,9	99
	Валидационная	99,5	98,7	98,9
	Тестовая	99,5	98,6	98,9
ResNET	Обучающая	97,2	91,7	92,2
	Валидационная	97,3	91,6	92,1

	Тестовая	97,2	91,6	92,2
VGG	Обучающая	96,2	95,7	94,6
	Валидационная	96,2	95,6	94,5
	Тестовая	96,3	95,5	94,4

Таблица 2 – Результаты распознавания параметров и ТЗ ОБ на НД с турбулентностью

Модель	Выборка данных	<i>n</i> , %	<i>m</i> , %	ТЗ, %
AlexNET	Обучающая	98,9	98,1	98,4
	Валидационная	97,4	95,1	96,3
	Тестовая	97,7	95,7	96,6
ResNET	Обучающая	98,4	96,1	95,5
	Валидационная	97,9	94,8	94,3
	Тестовая	97,9	94,6	94,3
VGG	Обучающая	65,4	64,7	55,4
	Валидационная	64,5	63,1	54
	Тестовая	64,5	63,3	54,5

По полученным данным, представленным в табл. 1 и табл. 2, можно сделать вывод, что для поставленной задачи распознавания параметров и ТЗ ОБЛГ с увеличенной областью темного на обоих НД возможно применение сразу двух архитектур AlexNET и ResNET, так как обе модели показали сопоставимо высокие результаты. При этом AlexNET незначительно превосходит ResNET по точности предсказания для параметра *m* и ТЗ, однако уступает в точности предсказания параметра *n*. В то же время модель VGG не справилась с поставленной задачей, продемонстрировав наименьшую точность для всех предсказываемых параметров на НД с турбулентностью. На НД с незашумленными данными все НС дают диагональным матрицы ошибок, в то время как внесение турбулентности повышает количество ложных срабатываний НС. Так AlexNET начинает ложно классифицировать пучки с $m > 3$ и $n > 3$. Особенно страдают классы с большими *n* (5,6,7), где структура колец сильнее искажается турбулентностью. Остаточные связи позволяют ResNET игнорировать высокочастотные турбулентные шумы и ошибки концентрируются на классах $m=2$ и $m=3$, где различие в интенсивности между соседними значениями может быть менее выражено при турбулентности. VGG, не имея skip-соединений, переобучается на шумах и не может обобщить искажённые структуры.

Заключение

В ходе работы было проведено исследование ОБЛГ с увеличенной темной областью и архитектуры изучаемых НС — AlexNet, ResNet и VGG. Был проведен анализ точности различных архитектур НС на двух НД. AlexNet продемонстрировала более лучшие результаты: 97,7% для *n*, 95,7% для *m* и 96,5% для ТЗ на целевом тестовом НД с турбулентностью. ResNet показала более скромные значения: 97,9% для *n*, 94,6% для *m* и 94,3% для ТЗ. VGG продемонстрировала низкую точность на турбулентных данных: 64,5% для *n*, 63,3% для *m* и 54,5% для ТЗ. Полученные результаты показывают, что

применение технологий глубокого обучения может способствовать повышению качества передачи информации в оптических системах связи.

Список использованных источников

1. Formation and Control of the Polarization Structure of Vector Structured Laguerre-Gaussian Beams / S. I. Yakubov, M. V. Bretsko, S. I. Khalilov, D. V. Maksimov, S. N. Lapaeva, Ya. E. Akimova // *Optical Memory and Neural Networks*. – 2024. – V. 33. – P. 90–97.
2. Huge spikes and dips of the orbital angular momentum in structured Laguerre-Gaussian beams resistant to simple astigmatism / A. V. Volyar, E. G. Abramochkin, Ya. E. Akimova, M. V. Bretsko // *Computer Optics*. – 2023. – V. 47, № 3. – P. 350–360.
3. OAM beam generation in space and its applications: A review / Yudong Lian, Xuan Qi, Yuhe Wang, Zhenxu Bai, Yulei Wang, Zhiwei Lu // *Optics and Lasers in Engineering*. – 2021. – V. 151, № 8.
4. Optical vortices 30 years on: OAM manipulation from topological charge to multiple singularities / Yijie Shen, Xuejiao Wang, Zhenwei Xie, Changjun Min, Xing Fu, Qiang Liu, Mali Gong, Xiacong Yuan // *Light Science and Applications*. – 2019. – V. 8, № 1.
5. Kirilenko, M. S. Modeling of one dimensional optical signal propagation in a turbulent medium / M. S. Kirilenko // *Proceedings of the International Conference on Information Technologies and Nanotechnologies*. – 2016. – P. 104–109.
6. Фурье-инвариантный пучок Лагерра–Гаусса с автофокусировкой / В. В. Котляр, Е. Г. Абрамочкин, А. А. Ковалев, Е. С. Козлова, А. А. Савельева // *Компьютерная оптика*. – 2024. – Т. 48, № 2.
7. Shilov, D. O. Influence of Atmospheric Turbulence on the Topological Charge of the Superposition of Optical Vortices / D. O. Shilov, E. S. Kozlova, E. A. Kadomina // *Optical Memory and Neural Networks*. – 2024. – V. 33. – P. 249–260.
8. Вихревой Фурье-инвариантный пучок Лагерра–Гаусса в квадрате / Е. С. Козлова, А. А. Савельева, А. А. Ковалев, В. В. Котляр // *Компьютерная оптика*. – 2023. – Т. 47, № 3.

COMPARATIVE ANALYSIS OF RESNET, ALEXNET AND VGG NEURAL NETWORKS FOR THE PROBLEM OF RECOGNITION OF LAGUERRE-GAUSSIAN BEAM PARAMETERS WITH ENLARGED DARK REGION

I.V. Sobolev¹

¹*Samara University, Samara*
e-mail: sobolev.ilya.ff0000@gmail.com

Abstract

This paper examines the topological charge recognition of Laguerre-Gaussian optical vortices with an enlarged dark region using convolutional neural networks. Results for topological charge recognition of optical vortices using the AlexNET, ResNET, and VGG architectures are presented.

Keywords: Laguerre-Gaussian beams, Fresnel transform, atmospheric turbulence, vortex beams, topological charge, convolutional neural networks, AlexNET, ResNet, VGG, persistence diagrams, posture clustering, Vicon.