

РАСПОЗНАВАНИЕ ПОЛЯРИЗАЦИОННЫХ МОД С ПОМОЩЬЮ НЕЙРОННОЙ СЕТИ ResNet-18

Н.С. Журавлев¹

¹Самарский университет, г. Самара
e-mail: nik_zhur_serg@mail.ru

Аннотация

В данной работе создан и исследован алгоритм распознавания поляризационных мод с помощью нейронной сети ResNet-18. Показано, что даже малое добавление в обучение натуральных данных к синтетическим данным существенно повышает качество распознавания: точность на натуральных изображениях выросла примерно на 10%.

Ключевые слова: векторные пучки, оптическая передача данных, нейронные сети.

Введение

Поляризационные и векторные моды света представляют интерес для современной оптики, поскольку связаны с задачами фокусировки, формирования специальных пространственных распределений поля и обработки оптической информации [1, 2, 3]. Методы поляриметрии и поляризационного анализа применяются в различных областях исследований и измерительных технологий [4]. В последние годы методы обработки сигналов и машинного обучения всё активнее используются для задач, связанных с анализом сложных оптических полей и их устойчивым распознаванием в условиях искажений [5].

В данной работе рассматривается задача автоматического распознавания поляризационных мод по данным поляризационной камеры. Основная трудность заключается в том, что объём натуральных данных ограничен, тогда как синтетические данные можно генерировать в большом количестве. Поэтому важной задачей является исследование переноса модели, обученной на синтетических данных, на натурные изображения, а также изучение совместного обучения на двух типах данных.

1. Моделирование

В работе использовалась модель цилиндрических векторных пучков, в которой компоненты электрического поля задавались в виде: (1)

$$E_x = A(r) \cos(m\varphi), \quad E_y = A(r) \sin(m\varphi), \quad (1)$$

где E_x , E_y – компоненты электрического поля по двум взаимно перпендикулярным направлениям; $A(r)$ – амплитудный профиль пучка; m – порядок поляризационной моды; r – расстояние от центра пучка; φ – полярный угол.

В простейшем случае радиальное распределение амплитуды задавалось выражением:

$$A(r) = r \exp\left(-\frac{r^2}{w^2}\right), \quad (2)$$

где w – ширина пучка. На более позднем этапе синтетический генератор был усложнён за счёт введения многокольцевой структуры и вариации параметров пучка.

Изображение, регистрируемое после поляризатора, ориентированного под углом α , вычислялось по формуле:

$$I_\alpha = (E_x \cos \alpha + E_y \sin \alpha)^2, \quad (3)$$

где I_α – интенсивность изображения после поляризатора; α – угол ориентации поляризатора. В результате для каждого примера формировались четыре канала: $I_0, I_{45}, I_{90}, I_{135}$.

На основе формул (1)–(3) был построен синтетический набор поляризационных изображений для мод $m=1$ и $m=2$. Дополнительно использовались повороты, добавление шума, изменение яркости, размытие, случайные смещения и изменение масштаба. Это позволило приблизить синтетические изображения к реальным данным, полученным с поляризационной камеры.

Итоговый улучшенный синтетический набор содержал 2000 изображений – по 1000 изображений на каждый класс. Для синтетических данных использовалось разбиение обучение: валидация: проверка = 70 : 15 : 15, что соответствовало 1400 / 299 / 301 изображениям.

Натурные изображения были получены в эксперименте и далее проходили предобработку: выделение поляризационных каналов, обрезку, изменение размера и нормировку. Всего использовалось 216 натурных изображений, из них 120 для класса $m=1$ и 96 для класса $m=2$. Для натурных данных применялось разбиение обучение: валидация: проверка = 60 : 20 : 20, что соответствовало 130 / 43 / 43 изображениям.

Таким образом, общее количество использованных в работе изображений составило 2216.

Для классификации использовалась сверточная нейронная сеть ResNet-18, первый слой которой был адаптирован для работы с четырёхканальным входом. Сравнивались следующие стратегии обучения: только на синтетических данных, только на натурных данных, совместное обучение на синтетических и натурных данных, а также предобучение на синтетических данных с последующим дообучением на натурных.

2. Результаты

Исследование показало, что качество распознавания поляризационных мод существенно зависит от способа формирования обучающей выборки. При обучении только на синтетических изображениях модель демонстрировала ограниченное качество переноса на натурные данные. После усложнения генератора синтетических изображений и введения в обучение небольшой доли натурных данных удалось значительно повысить точность распознавания.

Итоговая оценка выполнялась по нескольким запускам модели с различными начальными условиями. Было установлено, что наилучший результат достигается при совместном обучении на синтетических и натурных изображениях. Особенно заметный выигрыш наблюдался для более сложного класса $m=2$.

Основные количественные результаты приведены в таблице 1.

Таблица 1 – Сравнение качества распознавания на натуральных данных

Способ обучения	Точность на натуральных данных	Точность для $m=2$
Только синтетические данные	$0,8837 \pm 0,0403$	$0,7368 \pm 0,0912$
Совместное обучение, доля натуральных 0,02	$0,9767 \pm 0,0233$	$0,9474 \pm 0,0526$

Как видно из таблицы 1, малое добавление натуральных изображений в процесс обучения позволяет существенно улучшить качество распознавания. Средняя точность на натуральных данных выросла с 0,8837 до 0,9767, то есть примерно на 10%. Для класса $m=2$ точность увеличилась с 0,7368 до 0,9474. Кроме того, уменьшение ошибки калибровки вероятностей показывает, что модель стала не только точнее, но и более надёжной в оценке собственной уверенности.

Таким образом, полученные результаты подтверждают, что совместное использование реалистичных синтетических данных и даже небольшого количества натуральных изображений является эффективным подходом к распознаванию поляризационных мод.

Заключение

В работе разработан и исследован алгоритм распознавания поляризационных мод по данным поляризационной камеры на основе нейронной сети ResNet-18. Построен синтетический генератор поляризационных изображений для мод $m=1$ и $m=2$, подготовлен набор натуральных изображений и реализован полный вычислительный конвейер: генерация данных, предобработка, обучение и оценка качества.

Показано, что совместное обучение на синтетических и натуральных данных обеспечивает более высокое качество, чем обучение только на синтетике. Малое добавление натуральных изображений в обучение позволило повысить точность распознавания на натуральных данных примерно на 10%. Полученные результаты подтверждают перспективность применения методов машинного обучения для автоматического анализа поляризационных мод.

Список использованных источников

1. Rashid, M. Focusing of high order cylindrical vector beams / M. Rashid, O. M. Marago, P. H. Jones. – DOI: 10.1088/1464-4258/11/6/065204 // Journal of Optics A: Pure and Applied Optics. – 2009. – V. 11. – P. 065204.
2. Kozawa, Y. Sharper focal spot formed by higher-order radially polarized laser beams / Y. Kozawa, S. Sato // Journal of the Optical Society of America A. – 2007. – V. 24, №. 6. – P. 1793–1799.
3. Vector-vortex Bessel–Gauss beams and their tightly focusing properties / K. Huang, P. Shi, G. W. Cao, K. Li, X. B. Zhang, Y. P. Li // Optics Letters. – 2011. – V. 36, № 6. – P. 888–890.
4. An Overview of Polarimetric Sensing Techniques and Technology with Applications to Different Research Fields / F. Snika, J. Craven-Jones, M. Escutic, S. Fineschid,

D. Harringtone, A. de Martinof, D. Mawetg, J. Riedih, J. S. Tyoi // Proc. of SPIE Vol. 9099, Polarization: Measurement, Analysis, and Remote Sensing XI. – 2014. – P. 90990B.

5. PhyOAM-Net: Physical prior embedded data-driven demodulation for OAM shift keying under atmospheric turbulence / J. Gao, Y. Li, R. Xu, L. Cheng, L. Zhang, D. Zhang // Optics and Lasers in Engineering. – 2026. – V. 201. – P. 109738

RECOGNITION OF POLARIZATION MODES USING THE ResNet-18 NEURAL NETWORK

N.S. Zhuravlev¹

¹*Samara University, Samara
e-mail: nik_zhur_serg@mail.ru*

Abstract

In this work, an algorithm for recognizing polarization modes using the ResNet-18 neural network was developed and studied. It was shown that even a small addition of real experimental data to synthetic data during training significantly improves recognition quality: the accuracy on real images increased by about 10%.

Keywords: vector beams, optical data transmission, neural networks.