

Исследование влияния обучающего набора данных на точность распознавания оптических мод Лагерра-Гаусса

А.В. Бехтерев

Самарский национальный исследовательский университет им. академика С.П. Королева
Самара, Россия
bekhterev98@mail.ru

Аннотация — В работе проведено исследование точности распознавания оптических мод Лагерра-Гаусса с геометрическими искажениями в виде аффинных преобразований сверточной нейронной сетью. Изучено влияние на точность обучающей выборки данных.

Ключевые слова — нейронные сети, моды Лагерра-Гаусса, аффинные преобразования, машинное обучение

1. ВВЕДЕНИЕ

Информационные технологии не перестают стремительно развиваться. Параллельно с этим значительно увеличивается количество информации, передаваемой цифровыми устройствами. Однако платформа для достижения полностью оптической обработки сигналов остается труднореализуемой из-за ограничений в оптических системах связи [1]. Одним из способов решения данной проблемы Гауссовы пучки. Они имеют большой потенциал для увеличения пропускной способности оптической связи и обработки информации в классических и квантовых режимах [2]. В данной работе рассматриваются пучки Лагерра-Гаусса, которые также известны как оптические вихри. Они привлекли большое внимание в области оптической связи и могут быть обработаны с использованием нейронных сетей [3]. Однако в реальных условиях оптический сигнал часто имеет искажения, связанные, например, с атмосферной турбулентностью [4]. Поэтому в работе изображения оптических мод будут подвергаться геометрическим искажениям. Целью данной работы является исследование возможности сверточной нейронной сети распознавать оптические моды Лагерра-Гаусса с геометрическими искажениями, вызванными аффинными преобразованиями, а также изучение влияния на точность распознавания способа формирования обучающей выборки.

2. ФОРМИРОВАНИЕ БАЗЫ ДАННЫХ

В работе рассматриваются моды Лагерра-Гаусса [5]. Данный класс оптических мод является решениями уравнений Максвелла в свободном пространстве в парааксиальном приближении, в цилиндрических координатах. Пучок Лагерра-Гаусса является модовым пучком. Это означает, что при распространении в свободном пространстве его структура не изменяется.

Для обучения и тестирования нейронной сети необходимо сгенерировать наборы данных. Для этого использовалась библиотека LightPipes языка программирования Python. Она позволяет задать параметры и сформировать цифровые изображения мод Лагерра- и Эрмита-Гаусса. В данной работе использовались оба класса мод. Моды Эрмита-Гаусса выступали классом неправильных изображений. При генерации изображений мод изменялись два параметра: степень n и порядок m . Примеры полученных

изображений с разными входными параметрами представлены на рис. 1.




Рис. 1. Изображения мод Лагерра-Гаусса при заданных входных параметрах: а) $m=0, n=5$; б) $m=4, n=3$; в) $m=9, n=7$

В результате генерации были получены наборы данных по 5 тысяч изображений для обоих классов оптических мод. Далее необходимо было добавить геометрические искажения. Для этой цели была написана еще одна программа на языке Python с использованием фреймворка TensorFlow. С ее помощью ко всем изображениям применялись аффинные преобразования. Аффинные преобразования включают в себя множество операций, но для данной работы были выбраны только растяжение и поворот оси. Таким образом, был создан первый набор данных, который использовался в качестве обучающего для нейронной сети. Его размерность составляла 5 тысяч. Данный набор включал в себя оригинальные изображения, а также изображения, которые были сначала растянуты с коэффициентом $k=4$, а затем ось поворачивалась на угол $\alpha=35$. Оригинальные и искаженные изображения были в отношении 1:1. Примеры изображений мод с искажениями из первой обучающей выборки представлены на рис. 2.




Рис. 2. Изображения мод Лагерра-Гаусса из первой обучающей выборки с применением аффинных преобразований с углом поворота $\alpha=35$ и коэффициентом растяжения $k=4$ при заданных входных параметрах: а) $m=0, n=5$; б) $m=4, n=3$; в) $m=9, n=7$

Также путем варьирования коэффициента растяжения и угла поворота оси были сформированы еще 5 наборов данных, включающие в себя только искаженные изображения. Первые два содержали изображения с углом поворота оси $\alpha=25$ и $\alpha=45$ соответственно. Остальные три отличались коэффициентом растяжения $k=2, k=6, k=12$. Примеры растянутых изображений представлены на рис. 3.




Рис. 3. Изображения мод Лагерра-Гаусса при заданных входных параметрах $m = 6$, $n = 2$ и растянутых с коэффициентом: а) $k = 2$; б) $k = 6$; в) $k = 12$

После чего из комбинации всех этих наборов, а также оригинальных изображений был сформирован второй обучающий набор.

3. МОДЕЛИРОВАНИЕ

Следующим этапом было создание нейронной сети. С использованием средств TensorFlow языка Python была смоделирована сверточная нейронная сеть для решения задачи распознавания. В качестве входных данных она принимала цифровые изображения мод, а выходными данными являлась вероятность принадлежности к классу мод Лагерра- или Эрмита-Гаусса. Путём проведения экспериментов была получена наиболее эффективная структура нейронной сети, которая изображена на рис. 4.

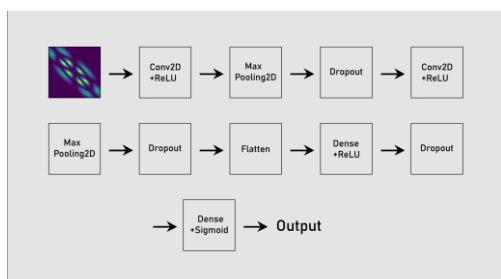


Рис. 4. Структура сверточной нейронной сети

Для исследования влияния на точность распознавания изображений с параметрами искажения, не участвующих в обучающей выборке, было получено две обученные модели, одна из которых обучалась на первом наборе данных, а вторая на полностью комбинированной выборке, которая содержала все возможные типы изображений. Количество эпох составляло пять. В результате точности обучения обеих моделей имеют высокий показатель, порядка 98% при обучении на первом наборе данных и 90% на комбинированном. На рис. 5 представлены графики точности обучения на двух выборках данных.

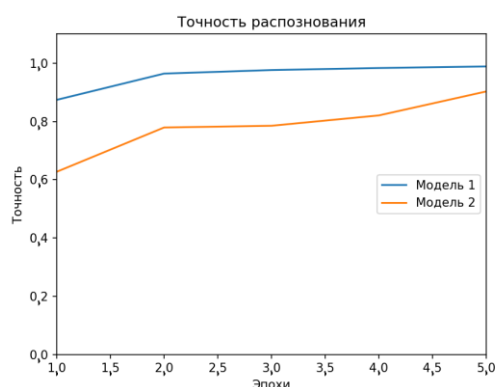


Рис. 5. Графики точности обучения нейронной сети на двух обучающих выборках

Результаты тестирования обеих моделей нейронных сетей на пяти тестовых наборах данных представлены в таблице I.

Таблица I. РЕЗУЛЬТАТЫ ТЕСТИРОВАНИЯ НЕЙРОННОЙ СЕТИ

Точность для	Проверка на наборе данных с параметром искажения				
	$\alpha = 25$	$\alpha = 45$	$k = 2$	$k = 6$	$k = 12$
Модели I, %	95,29	94,99	96,68	88,99	75,5
Модели II, %	95,88	95,04	85,71	81,05	78,03

Из таблицы I видно, что поворот не имеет существенного влияния на точность распознавания. Точность распознавания для первой модели падает незначительно: на 3%. В то же время растяжение может привести к существенному падению точности работы нейронной сети. Из полученных результатов видно, что чем сильнее растягивается изображение, тем ниже точность. Для первой модели нейронной сети точность падает на 23%, а для второй на 12%. Что абсолютные значения точности распознавания в данном случае близки для обеих моделей и составляют 76-78%.

4. ЗАКЛЮЧЕНИЕ

В ходе данной работы была исследована зависимость точности распознавания от обучающей выборки. Ввиду центросимметричности мод Лагерра-Гаусса поворот слабо влияет на точность распознавания. Существенно влияет коэффициент растяжения k . Так, например, увеличивая его до $k = 12$, точность снижается примерно на 20% и 12% для моделей, обученных на наборе с фиксированными искажениями ($k = 4$, $\alpha = 35$) и на полной комбинации всех изображений соответственно. Также было установлено, что для обучения нет необходимости использовать набор со всеми вариантами искажений. Отсутствие в обучающей выборке изображений с поворотом или низкими значениями коэффициента растяжения приводит к изменению точности примерно на 3%. Данная работа способна помочь в дальнейших исследованиях в области оптических систем связи.

ЛИТЕРАТУРА

- [1] Huang, Z. All-Optical Signal Processing of Vortex Beams with Diffractive Deep Neural Networks / Z. Huang, P. Wang, et al. // Phys. Rev. Appl. – 2020. – Vol. 15(1). – P. 014037. DOI: <https://doi.org/10.1103/PhysRevApplied.15.014037>.
- [2] Cao, M. Machine learning based accurate recognition of fractional optical vortex modes in atmospheric environment / M. Cao, Y. Yin, et al. // Appl. Phys. Lett. – 2021. – Vol. 119(14). – P. 141103. DOI: <https://doi.org/10.1063/5.0061365>
- [3] Wang, P. Diffractive Deep Neural Network for Optical Orbital Angular Momentum Multiplexing and Demultiplexing / P. Wang, W. Xiong, et al. // IEEE Journal of Selected Topics in Quantum Electronics – 2022. – Vol. 28(4). – P. 7500111. DOI: 10.1109/JSTQE.2021.307790.
- [4] Fu, X. Measuring OAM by the hybrid scheme of interference and convolutional neural network / X. Fu, Y. Bai, Y. Yang // Optical Engineering. – 2021. – Vol. 60(6). – P. 7500111. DOI: 10.1109/JSTQE.2021.307790.
- [5] Ustinov, A.V. Local characteristics of paraxial Laguerre–Gaussian vortex beams with a zero total angular momentum/ A.V. Ustinov, V.G. Niziev, S.N. Khonina, S.V. Karpeev // Journal of Modern Optics. – 2019. — Vol. 66(20). – P. 1961-1972. DOI: 10.1080/09500340.2019.1686183.