

Применяются детекторы, анализирующие саму структуру сигнала DVB-T2: они распознают специфические защитные интервалы и пилот-сигналы, что повышает надежность обнаружения.

Таким образом, наиболее перспективным подходом к решению задачи обнаружения и сопровождения БПЛА является комбинирование методов пассивной локации. Комбинация анализа отраженных сигналов внешних источников подсвета, например, DVB-T2, с распределенной сетью детекторов, обрабатывающих собственное излучение дронов, позволяет объединить достоинства обоих методов: высокую точность когерентной обработки и надежность триангуляции по сигналу бортового передатчика БПЛА.

Список использованных источников

- 1.Цымблер М. Л., Миниахметов Р. М., Рогов А. А. Обзор алгоритмов локального позиционирования мобильных устройств. – Вестник ЮУрГУ, 2013.
- 2.Bachevsky S. V., Fokin G. A., Simonov A. N., Sevidov V. V. Positioning of radio emission sources with unmanned aerial vehicles using TDOA-AOA measurement processing. – Journal of Physics, 2019.
- 3.Kim M., Ichige K., Arai H. Implementation of FPGA based fast DOA estimator using unitary MUSIC algorithm. – Proceedings of Vehicular Technology Conference, 2003.
- 4.Tayem N. M., Raza S. A., Omer M. et al. Hardware implementation of a proposed QR-TLS DOA estimation method and music, esprit algorithms on NI-PXI platform. – PIER C, 2013.
- 5.Ahmed N. Radio Direction Finding, Theory and Practices. – University of Engineering and Technology, Lahore, 2016.
- 6.Pölonen K. Signal Processing Methods for Multicarrier Passive Radar and Communication Systems. – Aalto University, 2016.
- 7.Barkhatov A., Vorobev E., Kononov A. Experimental Results of DVB-T2 Passive Coherent Location Radar. – IEEE, 2017.
- 8.Воробьев Е. Н. Распознавание воздушных целей в пассивном когерентном локаторе. – Диссертация канд. техн. наук, СПбГЭТУ «ЛЭТИ», 2022.

Берестов Иван Михайлович, студ. гр. 6305-010302D, техник ООО «КВАДРО КОД», ivantcharkin@yandex.ru

Лучин Михаил Дмитриевич, студ. гр. 6305-010302D, техник ООО «КВАДРО КОД», luchin.md@4code.ru

УДК 535.421, 621.391.63, 004.85

ОПТИКО-ЭЛЕКТРОННАЯ НЕЙРОСЕТЬ ДЛЯ КЛАССИФИКАЦИИ НА ОСНОВЕ 4F-СХЕМЫ С ФИКСИРОВАННОЙ ФАЗОВОЙ МАСКОЙ

А.С. Шнитко, Р.В. Скиданов

«Самарский национальный исследовательский университет имени
академика С.П. Королёва», г. Самара

Ключевые слова: дифракционная нейронная сеть, 4F-схема, классификация изображений, гибридные вычисления, MNIST.

Современные оптические вычислительные системы (например, дифракционные нейросети на основе 4F-схемы) [1, 2] обеспечивают обработку информации со скоростью, ограниченной лишь частотой регистрации излучения. Однако для каждой новой задачи (например, классификации) в таких системах требуется расчёт и изготовление нового дифракционного оптического элемента (ДОЭ), что снижает гибкость [1] и оперативность перенастройки.

В настоящей работе моделируется гибридная оптико-электронная система, где ДОЭ выполняет первичное преобразование изображения в набор фиксированных пространственных признаков (16 прямоугольных областей), а классификация осуществляется компактной электронной нейросетью. Потенциально это позволяет быстро адаптировать систему к новым данным, переобучая только электронную часть без изменения оптического тракта [2, 3].

Численное моделирование 4F-системы реализуется каскадом двух преобразований Фурье: в частотной плоскости спектр умножается на фазовую функцию маски. Входные изображения кодируются по амплитуде, выходные регистрируются по интенсивности. Полный цикл работы 4F-системы описывается формулой:

$$I(x', y') = |\mathcal{F}\{\mathcal{F}\{f(x, y)\} \cdot t(u, v)\}|^2,$$

где $f(x, y)$ — входное поле (амплитуда изображения);

$\mathcal{F}\{\cdot\}$ — прямое преобразование Фурье;

$t(u, v)$ — фазовая функция маски в частотной плоскости;

$I(x', y')$ — выходная интенсивность, регистрируемая камерой.

Фазовая маска, рассчитанная стохастическим методом, преобразует входное когерентное излучение в выходное изображение, состоящее из 16 ярких прямоугольных зон (рис. 1), которые служат областями интереса. При подаче на вход других изображений (например, рукописных цифр) распределение интенсивности в этих зонах меняется. Для каждого входного изображения рассчитывается выходное поле, после чего из 16 областей интереса извлекаются признаки — сумма интенсивностей пикселей в каждой зоне. Для повышения информативности каждая зона разбивалась на подобласти размером $n \times n$ (где $n = 1, 2, 3$), что формирует векторы признаков размерностью 16, 64 и 144 соответственно.

На выборке MNIST (2400 обучающих, 1000 тестовых изображений) признаки с выхода оптической части классифицировались softmax и MLP с одним скрытым слоем (ReLU). Зависимость точности от числа признаков и нейронов в MLP приведена в таблице 1.




Рисунок 1 — импульсная характеристика 4F-системы с ДОО

Таблица 1- Результаты классификации при различной размерности признаков

Число признаков	Число нейронов в скрытом слое MLP	Точность softmax, %	Точность MLP, %
16	64	61,0	63,3
64	128	86,9	88,4
144	288	93,0	93,5

При разбиении на 144 признака (3×3) точность softmax достигает 93,0%, MLP — 93,5%, но время обработки кадра принципиально различается: softmax требует менее 0,001 мс, тогда как MLP — около 66 мс (на CPU). Для задач анализа видеопотока с частотой 30–60 Гц в реальном времени [3] предпочтителен softmax. В таблице 2 приведена матрица ошибок для softmax с 144 признаками, подтверждающая стабильность классификации по всем классам.

Таблица 2 - Матрица ошибок для логистической регрессии (144 признака)

		Предсказанный класс									
		0	1	2	3	4	5	6	7	8	9
Фактический класс	0	97	0	0	2	0	0	1	0	0	0
	1	0	100	0	0	0	0	0	0	0	0
	2	0	0	92	3	3	1	0	1	0	0
	3	0	1	2	91	1	4	0	0	0	1
	4	0	2	0	0	95	0	0	0	0	3
	5	0	1	4	7	0	84	0	0	3	1
	6	2	2	0	0	1	0	95	0	0	0
	7	0	0	0	0	1	0	0	96	0	3
	8	1	0	0	4	1	0	3	1	90	0
	9	1	1	2	2	1	0	0	0	3	90

В 4F-системе с фиксированной фазовой маской, формирующей пространственные признаки, и быстрым электронным классификатором (логистическая регрессия) достигнута точность классификации рукописных цифр до 93,0% при времени обработки менее 0,001 мс на изображение. Такой гибридный подход объединяет высокую скорость оптических вычислений и гибкость электронной перенастройки, что перспективно для анализа

видеопотоков в реальном времени. Планируется экспериментальная реализация [1] и тестирование на других наборах данных.

Список использованных источников

1. Скиданов Р.В., Ханенко Ю.В., Морозов А.Е., Пронин А.С., Сорокин Д.М. Дифракционные нейронные сети на основе 4F- схемы с жидкокристаллическими модуляторами света // Оптический журнал. 2025. Т. 92. № 12. С. 66–76.

2. Khonina S.N., Kazanskiy N.L., Skidanov R.V., et al. Exploring Types of Photonic Neural Networks for Imaging and Computing—A Review // Nanomaterials. 2024. Vol. 14. Iss. 8. Art. 697

3. Kazanskiy N.L., Skidanov R.V., Nikonov A.V., et al. Intelligent video systems for unmanned aerial vehicles based on diffractive optics and deep learning // Proc. SPIE. 2020. Vol. 11516. 115160H.

Шнитко Андрей Сергеевич, студент группы 6231-030401D, каф. наноинженерии, andrej.schnitko@yandex.ru

Скиданов Роман Васильевич, д.ф.-м.н., доцент, профессор каф. киберфотоники, skidanov.rv@ssau.ru

УДК 004.622

ПРИМЕНЕНИЕ МНОГОКАНАЛЬНОЙ СУПЕРПИКСЕЛЬНОЙ СЕГМЕНТАЦИИ ДЛЯ КОМПРЕССИИ ГИПЕРСПЕКТРАЛЬНЫХ ИЗОБРАЖЕНИЙ

П.В. Чернышев

«Самарский национальный исследовательский университет имени академика С.П. Королёва», г. Самара

Ключевые слова: сегментация изображения, суперпиксели, гиперспектральные изображения.

Изображения, полученные с помощью гиперспектрального дистанционного зондирования, как правило, являются дорогостоящими, поэтому необходимо строго контролировать величину ошибки при компрессии этих изображений. Суперпиксельная сегментация позволяет выделять области на изображении, которые близки друг к другу по некоторому заданному критерию, например, по разнице яркостных значений. Если речь идет про обычные трехканальные изображения, то корреляция между соответствующими яркостными значениями пикселей в различных каналах легко заметна. Логично предположить, что подобная корреляция присутствует между каналами и у гиперспектральных изображений.

В результате сегментации изображения формируются данные двух типов: во-первых, это описания формы (границ) сегментов (суперпикселей), во-вторых, описания свойств изображения внутри каждого сегмента. Компрессия изображений предполагает минимизацию