

Методы машинного обучения для демультимплексирования акустических мод с орбитальным угловым моментом

Д.А. Станкевич¹

¹Волгоградский государственный университет, Университетский 100, Волгоград, Россия, 400062

Аннотация. Мультимплексирование сигналов с использованием орбитального углового момента (ОУМ) является перспективным методом мультимплексирования в системах связи. Ранее было продемонстрировано мультимплексирование ОУМ для подводной акустической связи, где передача данных осуществлялась при помощи одного акустического пучка. Для демультимплексирования сигнала ОУМ чаще всего используется классический корреляционный метод, но он чувствителен к изменениям параметров сигнала. Например, изменения параметров могут быть связаны с распространением волн через неоднородную среду. Автором предложен и апробирован подход, использующий методы машинного обучения. С его помощью удалось достичь точности демультимплексирования 96% для нестационарных сигналов.

1. Введение

Кодирование информации с использованием волн с различным орбитальным угловым моментом заключается в мультимплексировании нескольких ортогональных мод в одном пучке [1]. Этот способ кодирования широко используется для атмосферной лазерной связи, где уже продемонстрирована рекордная плотность передачи данных [2]. В работах [3, 4] предлагается использовать волны с ОУМ для гидроакустической связи, где увеличение скорости передачи данных за счет расширения спектра затруднено сильным затуханием звуковых волн в воде. За наличие у волны ОУМ ответственен множитель $\exp(il\phi)$, где ϕ – азимутальный угол в плоскости, перпендикулярной оси пучка, $l = 0, \pm 1, \pm 2, \dots$ – орбитальное волновое число. Таким образом, вектор потока энергии будет описывать в пространстве геликоидальную поверхность, и пучки с различным l будут характеризоваться различным распределением фазового волнового фронта. Декодирование информации из пространственного распределения волнового фронта заключается в его разделении на ортогональные моды [1]. Обычно разделение или демультимплексирование осуществляется корреляционными методами [1, 3], точность работы которых может существенно снижаться из-за изменения несущей частоты сигнала, например, за счет эффекта Доплера, в случае если приемник или передатчик движутся. В условиях, когда несущая частота априори неизвестна или меняется, для синтеза демультимплексора волн с ОУМ можно воспользоваться методами машинного обучения.

2. Алгоритм демультимплексирования акустических мод с орбитальным угловым моментом

Расположим R штук приемников волны равномерно по окружности, центр которой располагается на оси пучка, тогда дискретные отсчеты сигнала на выходе r -го приемника при регистрации волны с l -ым ОУМ можно представить в виде:

$$x_{rl}[n] = A_l \sin\left(2\pi f_0 n + \varphi_l + 2\pi \frac{rl}{R}\right).$$

Здесь введены обозначения: $n = 0, 1, 2, \dots, N-1$, N – количество отсчетов в выборке, f_0 – безразмерная частота, нормированная на частоту дискретизации f_d , φ_l – начальная фаза l -ой моды. Амплитуды сигналов A_l нормируются таким образом, чтобы сигнал с несколькими модами имел такую же энергию, что и сигнал с одной модой. Следуя работе [3], для кодирования информационного символа размером в один байт будем использовать сумму геликоидальных волн с моментом l от -4 до 4 . Волна с нулевым орбитальным моментом кодирует нулевое значение байта.

Для демультимплексирования использовалась двухслойная сверточная сеть [5]. Описание ее архитектуры приведено в таблице 1. Первый слой которой содержит 10 сверточных нейронов, которые имеют R входов. Для уменьшения количества связей с выходным слоем и увеличения скорости обучения используется прореживание результатов (пулинг) вычислений входного слоя. Последовательность с выходов нейронов-фильтров разбивается на непересекающиеся интервалы по 5 точек, и на каждом интервале выбирается максимальное значение. Далее эти данные поступают в выходной полносвязный слой, состоящий из 8 нейронов с сигмоидальной функцией активацией. Таким образом, активация отдельного нейрона выходного слоя говорит о наличии моды с заданным угловым моментом.

Таблица 1. Параметры архитектуры сверточной нейронной сети.

	Входной слой	Выходной слой
Тип слоя	Сверточный	Полносвязный
Число нейронов	10	8
Ядро свертки	10×1	–
Пулинг	5×5 (Max)	–
Активация	ReLU	Сигмоида

Настройка весовых коэффициентов сети осуществляется в процессе обучения на множестве, состоящим из 2000 выборок сигналов, соответствующих различным значениям информационных символов, длиной $N = 20$ отсчетов с аддитивным нормальным шумом с нулевым средним и дисперсией σ^2 , выбранной случайно из диапазона 1.0 – 2.0. Начальная фаза и частота сигналов равномерно распределены в диапазоне $0 - 2\pi$ и $0.1 - 0.3$, соответственно.

Обучение проводилось с помощью библиотеки глубокого обучения Keras методом обратного распространения ошибки. В процессе обучения, состоящем из 100 эпох, минимизировалась бинарная перекрестная энтропия с помощью метода Adam. Время обучения на 12-ти ядерном процессоре Intel i7-3930K 3.2 ГГц составляет менее 30 с.

Исследование характеристик сети проводилось на отличном от обучающего множестве, содержащем также 1000 выборок. При относительно невысоком уровне шума ($\sigma^2 = 0.1$) десятки приемников достаточно, чтобы достигнуть 100% точности демультимплексирования (см. рисунок 1а). Аналогичный результат достигается с использованием корреляционного метода. Увеличение дисперсии шума на порядок снижает точность, но она остается на уровне 96%. Важным преимуществом машинного синтеза демультимплексора является то, что в достаточном широком диапазоне частот (0.15 – 0.3), на котором производилось обучение, точность изменяется не более чем на 6% при дисперсии шума равной 1.0 (см. рисунок 1б) в отличие от корреляционного, который при изменении частоты сигнала на 10% существенно проигрывает по точности.

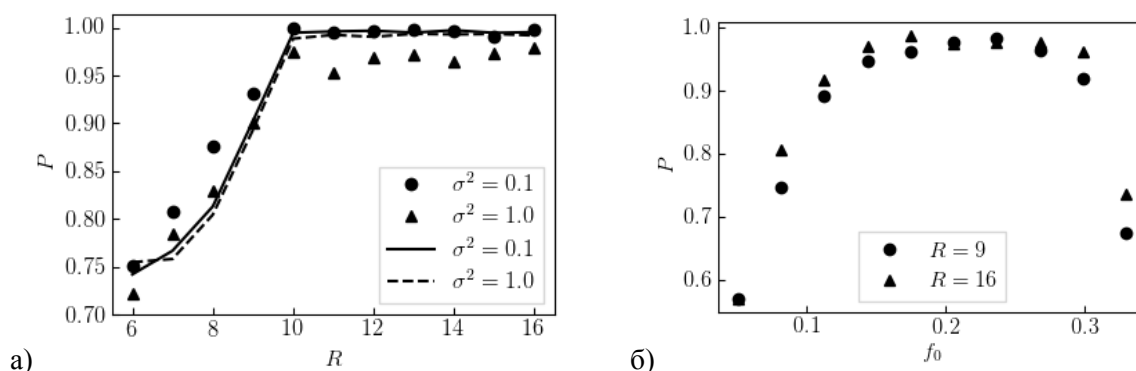


Рисунок 1. а) зависимости точности демультимплексирования P от числа приемников R для нейросетевого метода (кружки и треугольники) и корреляционного метода (линии); б) зависимости точности демультимплексирования нейросетевого метода P от несущей частоты сигнала.

3. Заключение

В заключении стоит отметить, что малые (не более 10%) медленные изменения амплитуды сигнала в сочетании с малыми (около 5%) и медленными изменениями несущей частоты еще сильнее влияют на точность демультимплексирования с помощью корреляционного метода. При этом точность нейросетевого демультимплексора остается на том же уровне. В дальнейшем планируется провести исследования нейросетевого демультимплексора на устойчивость к фазовым искажениям волнового фронта при распространении волны через неоднородную среду.

4. Литература

- [1] Djordjevic, I.B. Multidimensional OAM-Based Secure High-Speed Wireless Communications // IEEE Access. – 2017. – Vol. 17140317. – P. 16416–16428. DOI: 10.1109/ACCESS.2017.2735994.
- [2] Li, L. High-Capacity Free-Space Optical Communications Between a Ground Transmitter and a Ground Receiver via a UAV Using Multiplexing of Multiple Orbital-Angular-Momentum Beams / L. Li, R. Zhang, Z. Zhao, G. Xie, P. Liao, K. Pang, H. Song, C. Liu, Y. Ren, G. Labroille, P. Jian, D. Starodubov, B. Lynn, R. Bock, M. Tur, A.E. Willner // Scientific Reports. – 2017. – Vol. 7. – P. 17427. DOI: 10.1038/s41598-017-17580-y.
- [3] Shi, C. High-speed acoustic communication by multiplexing orbital angular momentum / C. Shi, M. Dubois, Y. Wang, X. Zhang // PNAS. – 2017. – Vol. 114(28). – P. 7250-7253. DOI: 10.1073/pnas.1704450114.
- [4] Hefner, B.T. An acoustical helicoidal wave transducer with applications for the alignment of ultrasonic and underwater systems / B.T. Hefner, P.L. Marston // J. Acoust. Soc. Am. – 1999. – Vol. 106(6). – P. 3313-3316. DOI: 10.1121/1.428184.
- [5] Николенко, С. Глубокое обучение / С. Николенко, А. Кадури, Е. Архангельская. – СПб.: Питер, 2018. – 480 с.

Благодарности

Исследование выполнено за счет гранта Российского научного фонда (проект № 18-79-00080).

Orbital angular momentum acoustic modes demultiplexing by machine learning methods

D.A. Stankevich¹

¹Volgograd State University, Universitetskiy pr. 100, Volgograd, Russia, 400062

Abstract. Orbital angular momentum (OAM) multiplexing is a promising method for MIMO multiplexing strategy. OAM multiplexing has previously been demonstrated for underwater acoustic communication, where data transmission was carried out within a single acoustic beam. Inner-product method is most often used for OAM demultiplexing, but it's sensitive to changes of signal parameters. For example, parameters changes can be associated with wave propagation through heterogeneous medium. I propose and demonstrate an approach using of machine learning methods to increase demultiplexing accuracy to 96% for a non-stationary signals.