

09;10;11

Метод демультимплексирования геликоидального волнового фронта

© Д.А. Станкевич

Волгоградский государственный университет, Волгоград, Россия
E-mail: stankevich@volsu.ru

Поступило в Редакцию 13 ноября 2018 г.

В окончательной редакции 13 ноября 2018 г.

Принято к публикации 19 ноября 2018 г.

С помощью методов машинного обучения построен демультимплексор геликоидального волнового фронта на ортогональные моды. При отношении сигнал/шум -3 dB точность демультимплексирования на восемь мод составляет около 95% в широком диапазоне несущей частоты сигнала. Описываемый демультимплексор превосходит по точности классический корреляционный метод, если параметры сигналов нестационарны.

DOI: 10.21883/PJTF.2019.04.47326.17587

Оптические пучки с геликоидальной формой волнового фронта, иначе называемые закрученными волнами или вихрями, в настоящее время используются для атмосферной лазерной связи, где уже продемонстрирована рекордная плотность передачи данных [1]. Характерным примером являются лаггер-гауссовы пучки, для которых циркулярное движение потока энергии обуславливается экспоненциальным множителем $\exp(il\theta)$, где l — азимутальный индекс лаггер-гауссовой моды, θ — азимутальный угол в поперечном сечении пучка. При обходе по любому замкнутому контуру вокруг оси пучка фаза изменяется на $2\pi l$, поэтому l часто называют топологическим зарядом. Поскольку моды с различным топологическим зарядом ортогональны $\langle \exp(il\theta) | \exp(im\theta) \rangle = \delta_{lm}$, в одном пучке можно мультиплексировать несколько мод, несущих различную информацию.

Закрученные волны исследованы не только в оптике, но и в радиодиапазоне и акустике. В нескольких работах [2,3] предлагается использовать волны с геликоидальным фронтом для гидроакустической связи, где увеличение скорости передачи данных за счет расширения спектра затруднено сильным затуханием звуковых волн в воде.

Декодирование информации из пространственного распределения волнового фронта заключается в его разделении на ортогональные моды [4]. В акустике демультимплексирование осуществляется в основном корреляционными методами [3], точность работы которых может существенно снижаться из-за изменения параметров сигнала. Например, частота может меняться за счет эффекта Доплера в том случае, если приемник или передатчик движутся, а амплитуда и фаза излученной акустической волны зависят от температуры излучателей. Дополнительно оказывает влияние смещение осей приемной и передающей систем. В таких условиях для демультимплексирования геликоидального фронта можно воспользоваться методами машинного обучения.

Рассмотрим простую приемопередающую систему [3], состоящую из R штук точечных излучателей и R точечных приемников, равномерно расположенных на двух концентрических окружностях. Следуя [3], для кодирования информационного символа размером в один

байт будем использовать сумму мод с топологическими зарядами $-4 \leq l \leq 4$. Согласно теореме Найквиста, в этом случае число приемников и передатчиков $R > 9$. Излучатель с номером r возбуждается напряжением

$$U_r(t) = \sum_{l=-4}^4 A_{rl} \sin(2\pi f t + 2\pi l \frac{r}{R}).$$

Здесь f — несущая частота; амплитуды A_{rl} равны нулю, если соответствующий l -й моде бит не установлен. Волна с $l = 0$ кодирует нулевое значение байта, тогда все остальные амплитуды A_{rl} равны нулю; в остальных случаях амплитуды A_{rl} нормируются таким образом, чтобы энергия сигнала с одной модой совпадала с энергией сигнала с несколькими модами.

В результате искажений, о которых говорилось выше, сигналы на выходах приемников примут вид

$$\tilde{U}_r(t) = \sum_{l=-4}^4 \tilde{A}_{rl}(t) \sin\left(2\pi f t + 2\pi l \frac{r}{R} + \varphi_r(t)\right) + \eta_r(t).$$

Здесь амплитуды \tilde{A}_{rl} и фазы φ_r сигнала на выходе r -го приемника теперь медленно меняющиеся случайные функции времени; η_r — аддитивный нормальный шум.

Дискретные отсчеты сигналов с выходов приемников после оцифровки имеют вид

$$\begin{aligned} u_r[n] &= \sum_{l=-4}^4 a_{rl}[n] \sin(\psi_r[n]) + \eta_r[n] \\ &= \sum_{l=-4}^4 a_{rl}[n] \sin\left(2\pi F n + 2\pi l \frac{r}{R} + \varphi_r[n]\right) + \eta_r[n]. \end{aligned}$$

Здесь введены следующие обозначения: $n = 0, 1, \dots, N-1, N$ — количество отсчетов в выборке; $\psi_r[n]$ — полные фазы сигналов; F — безразмерная частота, нормированная на частоту дискретизации $F = f_0/f_d$. Далее будем предполагать, что каждый информационный символ передается в течение времени не менее N/f_d . В итоге по имеющимся выборкам $u_r[n]$ требуется определить, какие моды содeржал исходный сигнал.

В такой постановке задача демультимплексирования схожа с задачей классификации, для решения которой часто применяют искусственные нейронные сети. Использовалась двухслойная сверточная сеть [5]. Ее первый слой содержит $K = 10$ нейронов-фильтров (имеющих $R = 10$ входов), которые представляют собой цифровые фильтры с конечной импульсной характеристикой длиной $M = 15$. Входные нейроны имеют простую активационную функцию типа ReLU: $y(x) = \max(0, x)$ [6]. Для уменьшения количества связей с выходным слоем и увеличения скорости обучения результат вычислений входного слоя усредняется. Последовательность с выходов нейронов-фильтров разбивается на непересекающиеся интервалы по пять точек, и на каждом интервале вычисляется среднее значение. Далее эти данные поступают в выходной полносвязный слой [7], состоящий из восьми нейронов с активацией в виде логистической функции: $g(x) = 1/(1 + \exp(-x))$ [5]. Таким образом, активация отдельного нейрона выходного слоя указывает на наличие моды с заданным угловым моментом.

Настройка весовых коэффициентов сети осуществляется в процессе обучения на множестве, состоящем из $2 \cdot 10^3$ выборок сигналов, соответствующих различным значениям информационных символов, длиной $N = 30$ отсчетов с аддитивным нормальным шумом с нулевым средним и дисперсией σ^2 , выбранной случайно из диапазона 1.0–2.0. Частота сигналов F равномерно распределена в диапазоне 0.2–0.3. Начальные фазы φ_r содержат две составляющие: регулярную, одинаковую для всех приемников (в диапазоне 0– 2π), и случайную для каждого отдельного приемника (в диапазоне от –0.1 до 0.1). Амплитуды сигналов полагались постоянными в пределах N отсчетов, но для различных выборок амплитуды отличались на случайный множитель $a_{r,l} = b_r/\sqrt{L}$, где b_r — случайный множитель в диапазоне 0.8–1.0, L — количество мод в сигнале ($L = 1-8$).

Обучение производилось с помощью библиотеки глубокого обучения Keras [7] методом обратного распространения ошибки. В процессе обучения, состоящем из 50 эпох, минимизировалась бинарная перекрестная энтропия [5,7] с помощью метода Adam [8]. Время обучения на 12-ядерном процессоре Intel i7-3930K 3.2 GHz составляет менее 30 с.

Исследование характеристик сети проводилось на отличном от обучающего множестве, содержащем 10^3 выборок сигналов с частотами в диапазоне 0.225–0.275. При уровне шума $\sigma^2 = 1.0$ точность демультимплексирования составляет $95.1 \pm 0.4\%$, при этом точность корреляционного метода примерно на 11% ниже. Важным преимуществом машинного синтеза демультимплексора является то, что в диапазоне частот, в котором производилось обучение, точность изменяется не более чем на 2% при дисперсии шума, равной 1.0.

Поскольку нейросетевой демультимплексор менее чувствителен к изменению параметров сигнала, объем передаваемой информации можно дополнительно увеличить за счет частотной или фазовой модуляции.

На вход уже обученной сети подавались частотно-модулированные сигналы, полная фаза которых имела вид $\psi_{lr}[n] = 2\pi F n + \Delta F \sin(2\pi F_m n)/F_m + 2\pi l r/R + \varphi_r$ с параметрами $F = 0.25$, $\Delta F = 0.05$, $F_m = 0.02$, начальные фазы φ_r выбирались произвольно в диапазоне 0– 2π . Точность демультимплексирования при дисперсии шума $\sigma^2 = 1.0$ ухудшилась не более чем на 1%.

Обычно нейронные сети не позиционируются как высокопроизводительные системы, однако малое количество нейронов и процедура усреднения после входного слоя снижают необходимые вычислительные затраты. Так, для демультимплексирования с помощью сети требуется выполнить $RKM(N - M + 1) + 16K$ умножений с накоплением (при $R = 10$, $N = 30$, $M = 15$, $K = 10$ получаем 24 160 инструкций) и восемь раз вычислить значения логистической функции, которую после обучения можно заменить более простой аппроксимацией [9]. Таким образом, задача нейросетевого демультимплексирования под силу сравнительно простому сигнальному процессору. Безусловно, корреляционный метод превосходит предложенный по скорости счета (требуется как минимум $16RN = 4800$ умножений с накоплением), но лишь в случае, когда известна частота сигнала и она постоянна.

Следует отметить, что методы машинного обучения могут упростить синтез квазиоптимальных алгоритмов обнаружения и различения и для более сложных сигналов. Например, сравнительно недавно искусственные нейронные сети использовались для детектирования сигналов в гравитационно-волновом эксперименте [10].

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

Список литературы

- [1] Li L., Zhang R., Zhao Z., Xie G., Liao P., Pang K., Song H., Liu C., Ren Y., Labroille G., Jian P., Starodubov D., Lynn B., Bock R., Tur M., Willner A.E. // Sci. Rep. 2017. V. 7. P. 17427. DOI: 10.1038/s41598-017-17580-y
- [2] Hefner B.T., Marston P.L. // J. Acoust. Soc. Am. 1999. V. 106. P. 3313–3316. DOI: 10.1121/1.428184
- [3] Shi C., Dubois M., Wang Y., Zhang X. // PNAS. 2017. V. 114. P. 7250–7253. DOI: 10.1073/pnas.1704450114
- [4] Djordjevic I.B. // IEEE Access. 2017. V. 5. P. 16416–16428. DOI: 10.1109/ACCESS.2017.2735994
- [5] Николенко С.И., Кадурын А.А., Архангельская Е.О. Глубокое обучение. СПб.: Питер, 2018. 480 с.
- [6] Agarap A. arXiv: 1803.08375 (2018).
- [7] Шолле Ф. Глубокое обучение на Python. СПб.: Питер, 2018. 400 с.
- [8] Kingma D., Ba J. arXiv: 1412.6980 (2014).
- [9] Basterretxea K., Tarela J.M., del Campo I. // IEE Proc. Circ. Dev. Syst. 2004. V. 151. P. 18–24. DOI: 10.1049/ip-cds:20030607
- [10] Gabbard H., Williams M., Hayes F., Messenger C. // Phys. Rev. Lett. 2018. V. 120. P. 141103. DOI: 10.1103/PhysRevLett.120.141103