

Применение комплексных полносвязных нейронных сетей для компенсации нелинейных эффектов в волоконно-оптических линиях связи

С.А.Богданов, О.С.Сидельников

Предложена схема обработки оптических сигналов в приёмнике системы связи, основанная на комплексных полносвязных нейронных сетях. Проведено исследование влияния основных характеристик нейронной сети на эффективность компенсации нелинейных искажений. Продемонстрировано значительное преимущество предложенной схемы над нейронными сетями с действительной арифметикой.

Ключевые слова: оптическое волокно, нелинейные эффекты, полносвязные нейронные сети, математическое моделирование.

1. Введение

Проблема компенсации искажений сигналов, вызванных нелинейными воздействиями в оптическом волокне, является одним из ключевых вопросов, требующих решения для дальнейшего увеличения пропускной способности современных систем передачи информации [1–3]. Для достижения этой цели в настоящий момент разрабатываются различные технологии генерации и обработки оптического сигнала. Среди таких подходов следует выделить семейство методов, основанных на использовании функционального ряда Вольтера [4], цифровые методы на основе элементов теории возмущений [5, 6], нелинейный фильтр Шрёдингера и алгоритм приёма в целом с поэтапным принятием решения [7], а также оптические методы с применением фазового сопряжения сигнала [8]. Методы машинного обучения, и нейронные сети (НС) в частности, в настоящее время стали особенно активно применяться для компенсации нелинейности в волоконно-оптических линиях связи благодаря тому, что они обеспечивают высокую точность классификации принятых символов при небольшой вычислительной сложности [9–12]. Кроме того, схемы обработки принятых сигналов на основе методов машинного обучения могут применяться в динамически изменяющихся линиях связи вследствие возможности периодического переобучения.

В настоящей работе предлагается схема компенсации нелинейных эффектов в линиях связи, основанная на комплексных полносвязных нейронных сетях. Предложенная схема сравнивается со схемой с линейной компенсацией и со схемой на основе полносвязных НС с действительной арифметикой.

С.А.Богданов, О.С.Сидельников. Новосибирский государственный университет, Россия, 630090 Новосибирск, ул. Пирогова, 2; e-mail: s.bogdanov@g.nsu.ru, o.s.sidelnikov@gmail.com

Поступила в редакцию 28 декабря 2020 г., после доработки – 27 февраля 2021 г.

2. Схема компенсации нелинейных эффектов на основе полносвязных нейронных сетей

Нейронные сети являются мощным инструментом, который потенциально можно использовать для аппроксимации практически любой нелинейной функции. Однако без какого-либо предварительного знания об аппроксимируемой функции, данная НС может быть довольно громоздкой, а процесс обучения занимать много времени. Поэтому в настоящее время популярным является подход, в котором в архитектуру НС закладываются некоторые предварительные знания о природе решаемой задачи. Впервые такой подход для компенсации нелинейных эффектов в приёмнике линии связи был применён в работе [10], в которой архитектура НС была сконструирована по аналогии с методом обратного распространения сигнала [13]. В настоящей работе мы предлагаем использовать данный подход для разработки схемы компенсации нелинейных искажений в волоконно-оптических линиях связи на основе полносвязных нейронных сетей.

Рассматриваемая нейронная сеть (рис.1) состоит из входного слоя, в котором для учёта эффекта памяти канала одновременно обрабатываются несколько принятых символов, двух скрытых слоёв с одинаковым числом нейронов и выходного слоя, состоящего из одного нейрона, соответствующего предсказываемому (переданному) символу. Структура входного слоя имеет следующий вид: для предсказания символа, отправленного с передатчика, используется соответствующий ему принятый символ, а также значения его N последующих и N предыдущих соседей на приёмнике. Таким образом, для предсказания каждого переданного символа используются $2N + 1$ символов с приёмника.

Поскольку уравнение Шрёдингера описывает распространение комплексных сигналов, предложенная НС также является комплекснозначной. В основе комплексных НС лежит описание с помощью комплексных чисел как состояния самих нейронов, так и весовых коэффициен-

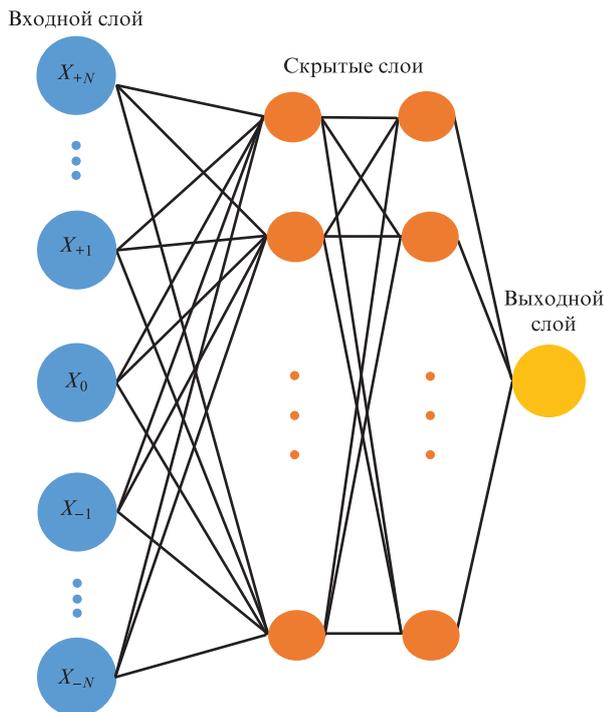


Рис.1. Схема комплексной нейронной сети.

тов. Таким образом, каждый нейрон комплексной нейронной сети представляется в виде отдельной пары действительных чисел, для которых была реализована соответствующая комплекснозначная арифметика. Такой подход представляется более естественным при обработке принятых символов в волоконно-оптических линиях связи, которые по своей природе являются комплексными.

Математически комплексная НС эквивалентна действительнозначной нейронной сети: одному комплексному нейрону соответствует пара вещественных. В то же время, чтобы связать две пары действительнозначных нейронов требуется четыре вещественных весовых параметра (веса), тогда как два комплексных нейрона связываются одним комплекснозначным весом (двумя вещественными числами). Таким образом, действительнозначная НС с числом пар вещественных нейронов, равным числу нейронов комплексной сети, будет иметь вдвое больше вещественных весовых коэффициентов, что значительно усложнит процесс обучения. Однако в силу того, что одно комплексное умножение требует четырёх операций умножения вещественных чисел, итоговая вычислительная сложность обеих сетей одинакова. Кроме того, комплексные НС позволяют использовать комплексные функции активации, соответствующие нелинейным эффектам, воздействующим на сигналы при распространении по оптическому волокну.

Нелинейная функция активации предложенной НС соответствует компенсации фазового сдвига сигнала, вызванного нелинейным взаимодействием сигналов, и имеет следующий вид:

$$f(z) = e^{i\gamma_1 |z|^2 z},$$

где γ_1 – параметр, который оптимизируется в процессе обучения нейронной сети.

Архитектура комплексной НС была реализована с использованием библиотеки TensorFlow 2.0. Для нахождения весов сети использовался алгоритм оптимизации Адам (Adam – adaptive moment estimation), обеспечивающий адаптивную скорость обучения для каждого отдельного параметра. В процессе оптимизации весов скорость обучения изменяется в соответствии с оценками первого и второго моментов градиента. Для инициализации значений весовых коэффициентов использовалось нормальное распределение Ксавье (функция GlorotNormal()) в библиотеке TensorFlow). Следует отметить, что для каждого рассматриваемого набора параметров выполнялось несколько запусков с различными случайными начальными значениями всех весов, а затем наилучшие из полученных результатов отбрасывались. В качестве функции ошибок использовалась среднеквадратичная ошибка между отправленным и принятым символами 16-QAM, и символами, полученными после применения НС к тренировочной выборке.

3. Математическое моделирование

Рассматриваемая в работе система передачи данных схематически изображена на рис.2. Линия связи состоит из передатчика, 20 пролётов стандартного одномодового волокна (SSMF – standard single-mode fiber) по 100 км каждый, эрбиевых оптических усилителей с шум-фактором $NF = 4.5$ дБ, используемых после каждого пролёта для компенсации потерь, и приёмника. На передатчике формируются сигналы 16-QAM с символьной скоростью $R_s = 32$ Гбод. Для придания формы импульсам используется фильтр с характеристикой типа «корень из приподнятого косинуса» (RRC – root raised cosine) с коэффициентом сглаживания 0.1.

Распространение сигналов по оптическому волокну описывается нелинейным уравнением Шрёдингера [1]:

$$\frac{\partial A}{\partial z} = -\frac{\alpha}{2}A - i\frac{\beta_2}{2}\frac{\partial^2 A}{\partial t^2} + i\gamma|A|^2A,$$

где $A(z, t)$ – медленно меняющаяся огибающая оптического сигнала; $\alpha = 0.2$ дБ/км – потери в волокне; $\beta_2 = -21$ пс²/км – хроматическая дисперсия; $\gamma = 1.3$ Вт⁻¹·км⁻¹ – нелинейный параметр волокна. Уравнения распростра-

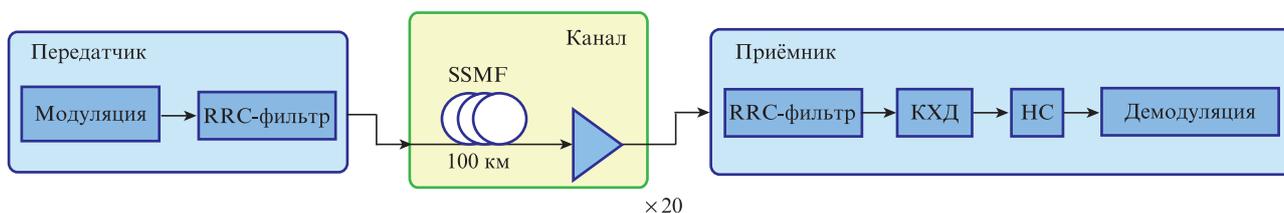


Рис.2. Схема волоконно-оптической линии связи; КХД – компенсация хроматической дисперсии.

нения решались численно с помощью симметричного метода Фурье расщепления по физическим процессам с частотой дискретизации 16 отсчётов на символ.

После распространения по каналу принятый сигнал проходил через согласованный RRC-фильтр. Далее выполнялась идеальная компенсация хроматической дисперсии в частотной области, затем – компенсация нелинейных эффектов с использованием предложенной схемы на основе комплексных полносвязных нейронных сетей. Для этого каждый комплексный символ принятого сигнала подавался на отдельный входной узел комплексной НС. Далее выполнялась демодуляция сигнала и вычисление коэффициента битовых ошибок (BER). Предложенная схема сравнивалась с линейной схемой компенсации, при которой блок с НС не применялся, а происходило только восстановление фазы принятого сигнала, и с методом компенсации нелинейности, основанным на полносвязных НС с действительнзначной арифметикой, предложенным в [11, 12]. Действительнозначная НС также имела два скрытых слоя, но, в отличие от комплексной сети, для неё в качестве нелинейной функции активации использовался гиперболический тангенс (\tanh). Для данной нейронной сети входные узлы соответствуют вещественным числам, поэтому каждый входной комплексный символ разделялся на пару вещественных чисел и подавался в два разных нейрона на входном слое сети; при этом терялось всякое различие между вещественной и мнимой частями исходного символа. Выходной слой такой сети состоит из двух вещественнозначных нейронов, один из которых соответствует действительной части предсказываемого (переданного) символа, а второй – мнимой. Для действительнзначной НС использовались такие же начальное распределение весовых коэффициентов и алгоритм оптимизации, как и для комплексной сети.

4. Результаты применения схемы компенсации нелинейных эффектов на основе комплексных полносвязных нейронных сетей

При исследовании предложенной схемы первым шагом было изучение влияния основных характеристик НС на эффективность компенсации нелинейных искажений. Так, была исследована зависимость коэффициента битовых ошибок после применения комплексной НС от числа подаваемых на вход символов (рис.3).

Видно, что эффективность применения нейронной сети увеличивается с ростом числа используемых входных символов, вплоть до 31 символа; далее BER изменяется незначительно. Этот результат справедлив как для комплексной НС с 32 нейронами на каждом из скрытых слоёв, так и для сети с 24 нейронами. Из рисунка, однако, следует, что нейронная сеть с 32 нейронами на каждом скрытом слое демонстрирует большую эффективность при том же числе используемых соседних символов. На рис.3 приведены также аналогичные зависимости для действительнзначных нейронных сетей (штрих-пунктирные кривые). Для корректного сравнения действительнзначные НС имели вдвое большее число нейронов на каждом скрытом слое, чтобы обеспечить вычислительную сложность, равную таковой для комплексной нейронной сети.

Видно, что за исключением случая, когда на входе используется только один символ, комплексные НС обеспе-

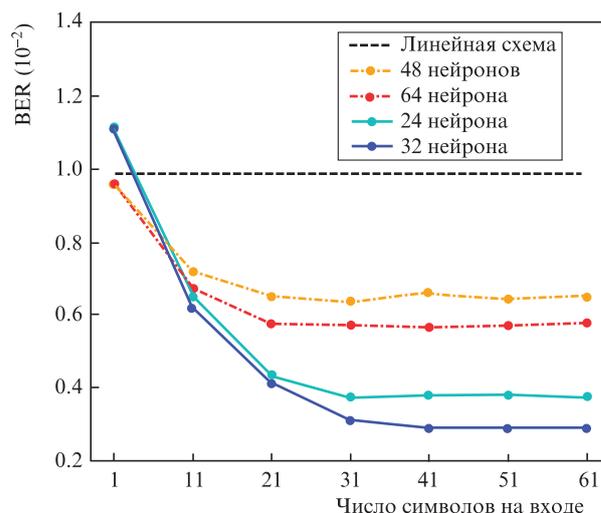


Рис.3. Зависимости коэффициента битовых ошибок от числа символов на входе для комплексных сетей с 32 и 24 нейронами на скрытых слоях (сплошные кривые), а также для действительнзначных сетей с 64 и 48 нейронами на каждом скрытом слое (штрих-пунктирные кривые). Цветной вариант рис.3 помещен на сайте нашего журнала <http://www.quantum-electron.ru>.

чивают значительно меньший коэффициент BER. В случае же использования одного входного символа ухудшение работы комплексной НС может быть связано как с особенностями обратного распространения ошибки через реализованную нелинейную функцию активации, так и с используемой функцией потерь, при которой минимизация среднеквадратичной ошибки не всегда приводит к уменьшению BER. Комплексная НС с одним входным символом была реализована также с функцией активации \tanh (применялась отдельно к реальной и мнимой частям комплексного нейрона); в этом случае её эффективность совпадала с результатом для действительнзначной сети. Более того, при замене последнего слоя комплексной и действительнзначной нейронных сетей на слой классификации (16 классов в соответствии с форматом модуляции 16-QAM) эффективности обеих сетей совпали с результатом для действительнзначной НС на рис.3.

На рис.4 приведены зависимости коэффициента BER от числа нейронов на каждом из скрытых слоёв для нейронных сетей с комплексной и действительнзначной архитектурой. Для действительнзначных НС (верхняя ось) масштаб был подобран таким образом, чтобы на одной вертикальной линии находились сети с одинаковой вычислительной сложностью (например, комплексная НС с 32 нейронами на каждом из скрытых слоёв и действительнзначная сеть с 64 нейронами). При этом в каждом случае число входных символов было равно 21. Видно, что комплексная НС обеспечивает более низкий коэффициент битовых ошибок по сравнению с действительнзначной сетью при той же вычислительной сложности. Кроме того, минимально достижимый коэффициент битовых ошибок для комплексной сети также оказался меньше.

Следует также отметить, что существует некоторый компромисс между эффективностью нейронной сети и её вычислительной сложностью. Это видно, например, из рис.3. Так, принимая на вход 31 символ, комплексная НС с 24 нейронами на каждом скрытом слое обеспечивает меньшую (примерно на 8%) эффективность в терминах BER, чем НС с 32 нейронами, но имеет меньшую вычислительную сложность. Ещё более наглядно это проде-

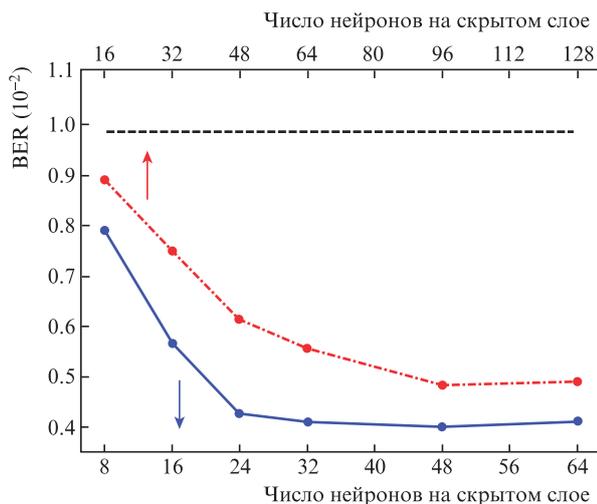


Рис.4. Зависимости коэффициента битовых ошибок от числа нейронов на каждом скрытом слое для комплексной (сплошная кривая) и действительностнозначной (штрих-пунктирная кривая) нейронных сетей (для действительностнозначной сети число нейронов удвоено; в обоих случаях на входе использовалось по 21 символу). Штриховая линия соответствует линейной схеме компенсации.

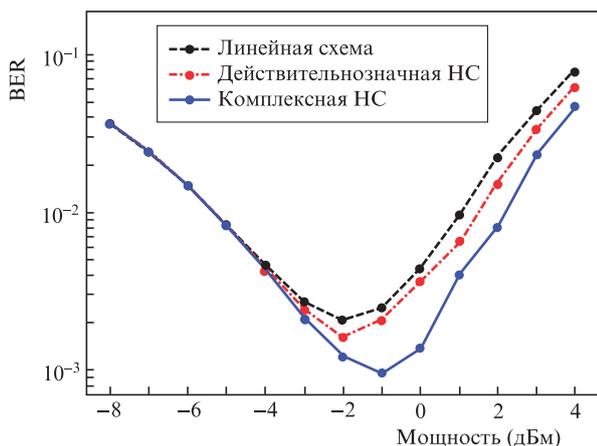


Рис.5. Зависимости BER от начальной мощности сигнала для линейной схемы компенсации (штриховая кривая), комплексной (сплошная кривая) и действительностнозначной (штрих-пунктирная кривая) нейронных сетей (для действительностнозначной сети использовалось 64 нейрона на каждом скрытом слое, для комплексной сети – 32 нейрона; на входе – по 31 символу).

монстрировано на рис.4, где для фиксированного числа входных символов наблюдается увеличение эффективности НС с ростом числа нейронов на скрытых слоях, что соответствует росту вычислительной сложности.

На рис.5 представлены зависимости коэффициента битовых ошибок от начальной мощности сигнала для различных схем компенсации нелинейности. Видно, что за счёт эффективной компенсации нелинейных эффектов использование комплексной НС позволяет снизить BER при оптимальной мощности на 53% по сравнению с линейной схемой компенсации и на 40% по сравнению с действительностнозначной НС. Следует отметить, что обе рассматриваемые нейронные сети имели одинаковую вычислительную сложность.

5. Заключение

В работе предложена схема обработки оптических сигналов в приёмнике системы связи, основанная на комплексных полносвязных нейронных сетях. Для данной схемы проведено исследование эффективности компенсации нелинейных эффектов в зависимости от параметров НС – числа обрабатываемых символов на входе и числа нейронов на скрытых слоях. Проведено сравнение эффективности обработки сигналов при использовании предложенной схемы и схемы на основе действительностнозначных НС и продемонстрировано существенное преимущество комплексных нейронных сетей.

Работа выполнена при поддержке гранта Президента РФ (МК-915.2020.9).

1. Agrawal G. *Nonlinear Fiber Optics* (Cambridge: Academic Press, 2012).
2. Temprana E. et al. *Science*, **348**, 1445 (2015).
3. Жителев А.Е. и др. *Квантовая электроника*, **47**, 1135 (2017) [*Quantum Electron.*, **47**, 1135 (2017)].
4. Liu L. et al. *J. Lightwave Technol.*, **30**, 310 (2012).
5. Sorokina M. et al. *Opt. Express*, **24**, 30433 (2016).
6. Редюк А.А. и др. *Прикладная фотоника*, **5**, 265 (2018).
7. Бурдин В.А. и др. *Квантовая электроника*, **47**, 1144 (2017) [*Quantum Electron.*, **47**, 1144 (2017)].
8. Ellis A.D. et al. *Opt. Express*, **23**, 20381 (2015).
9. Wang D. et al. *IEEE Photon. Technol. Lett.*, **28**, 19 (2016).
10. Häger C. et al. *Proc. Opt. Fiber Commun. Conf. (OFC)* (San Diego, USA, 2018, paper W3A.4).
11. Сидельников О.С. и др. *Квантовая электроника*, **47**, 1147 (2017) [*Quantum Electron.*, **47**, 1147 (2017)].
12. Sidelnikov O. et al. *Opt. Express*, **26**, 25 (2018).
13. Ip E. *J. Lightwave Technol.*, **28**, 6 (2010).