

Аннотация:

В связи с постоянно возрастающим спросом на пропускную способность оптических каналов возможность конструктивного использования нелинейных эффектов в волоконно-оптических системах с использованием новых концепций, таких как нелинейное преобразование Фурье (nonlinear Fourier transform – NFT), в последнее время стала предметом исследований. Одной из важнейших проблем при использовании NFT для обработки и передачи оптических сигналов является чувствительность систем на основе NFT к отклонениям оптических каналов от идеализированной модели, при этом шум является одной из основных проблем. В данной работе мы предлагаем архитектуру нейронной сети (neural network – NN), которая позволяет прогнозировать непрерывный нелинейный спектр оптических сигналов и выполнять обратное NFT для модуляции сигнала. Среднее значение относительной ошибки предсказания непрерывного спектра нейронной сетью при вычислении прямого NFT составило $2.68e-3$. Для обратного преобразования среднее значение относительной ошибки предсказания сигнала равнялось $1.62e-4$.

Тема работы:

Нейронная сеть для вычисления прямого и обратного нелинейного преобразования Фурье

Состав коллектива:

Седов Егор Валентинович, аспирант ФФ НГУ, м.н.с. лаборатория нелинейной фотоники НГУ.

Чеховской Игорь Сергеевич, к.ф.-м.н., н.с лаборатория нелинейной фотоники НГУ.

Прилепский Ярослав Евгеньевич, Aston Institute of Photonic Technologies, Aston University, Birmingham, United Kingdom.

Информация о гранте:

Исследование выполнено при поддержке фонда Президента РФ для государственной поддержки молодых российских учёных (грант № МК-677.2020.9). Работа Чеховского И.С. была поддержана государственным заданием на проведение фундаментальных исследований FSUS-2020-0034. Работа Прилепского Я.Е. поддержана Leverhulme Trust, project RPG-2018-063.

Научное содержание работы:**1. Постановка задачи.**

В связи с постоянно возрастающим спросом на пропускную способность оптических каналов возможность конструктивного использования нелинейных эффектов в волоконно-оптических системах с использованием новых концепций, таких как нелинейное преобразование Фурье (nonlinear Fourier transform – NFT), в последнее время стала предметом исследований. Одной из важнейших проблем при использовании NFT для обработки и передачи оптических сигналов является чувствительность систем на основе NFT к отклонениям оптических каналов от идеализированной модели, при этом шум является одной из основных проблем. В данной работе мы предлагаем архитектуру нейронной сети (neural network – NN),

которая позволяет прогнозировать непрерывный нелинейный спектр оптических сигналов и выполнять обратное NFT для модуляции сигнала.

2. Современное состояние проблемы.

Прямое и обратное NFT в приложении к фокусирующему НУШ было впервые сформулировано в основополагающей работе Захарова и Шабата. Прямое NFT ставит в соответствие оптическому сигналу его нелинейный спектр, который в общем случае может состоять из дискретной и непрерывной частей, хотя каждая часть может отсутствовать для некоторых конкретных ситуаций.

Набор дискретных собственных значений соответствует солитонной (дискретной) части NFT-спектра сигнала, которая обычно существует при достаточно высоких мощностях сигнала. Однако использование непрерывной части NFT-спектра, соответствующей дисперсионным компонентам, оказалась очень эффективным в оптической передаче данных.

В настоящее время предложено большое количество «традиционных» численных подходов для вычисления нелинейного спектра, и достигнут значительный прогресс в снижении вычислительной сложности алгоритмов (fast NFT – FNFT), а также в повышении их точности. Однако при применении к сложным сигналам с большим количеством нелинейных компонентов часто могут возникать некоторые трудности, связанные с проблемой устойчивости. Кроме того, обработка сложных сигналов на основе NFT в реальном времени является сложной задачей, которая ограничивает возможность эффективно реализовать NFT на аппаратном уровне. В этом случае перспективной областью является использование машинного обучения (machine learning – ML) и, в частности, реализация NFT на основе нейронных сетей (neural network – NN).

В последние годы был совершен большой прорыв в развитии методов ML для решения алгоритмически сложных задач, таких как, например, распознавание и классификация образов. Основными этапами здесь являются обучение модели на основе набора некоторых данных и применение модели для получения предсказания. Первый этап может занять больше времени, но применение обученной модели обычно происходит намного быстрее, что позволяет внедрять системы, основанные на методах машинного обучения, на различных непроизводительных устройствах. Отметим, что методы, связанные с ML, успешно применялись для компенсации нелинейных эффектов.

3. Подробное описание работы, включая используемые алгоритмы.

В этой работе мы используем NN для прогнозирования непрерывного нелинейного спектра сложных оптических сигналов и преобразования спектра обратно в сигнал (обратное NFT). Для исследования здесь мы выбрали примеры сигналов в форме широко используемого формата мультиплексирования с разделением по длине волны (WDM).

Сеть NFT-Net состоит из последовательных слоев свертки и полносвязных выходных слоев. На входе в сеть поступает сложный сигнал, состоящий из 1024 точек. Эта NN предсказывает только одну составляющую непрерывного спектра NF, так что две идентичные NFT-Net должны использоваться для предсказания действительной и мнимой частей. Аналогично, преобразование спектра обратно

в сигнал требует двух отдельных NFT-Net для действительной и мнимой частей сигнала. Каждая из четырех нейронных сетей с одинаковой архитектурой обучалась независимо.

Набор данных состоял из 94035 сигналов, из которых 9403 использовались для валидации и не участвовали в процессе обучения. Для генерации сигналов использовались случайные последовательности данных, закодированные в формате квадратурной фазовой манипуляции (QPSK). Энергия всех сигналов была одинаковой и выбиралась на таком уровне, чтобы нелинейные эффекты были достаточно сильными. При выбранной энергии некоторые сигналы содержали дискретный спектр, но такие сигналы не попадали в набор данных для обучения. Непрерывный спектр для каждого сигнала был предварительно вычислен с использованием обычных прямых методов NFT. При обучении NFT-Net мы использовали среднеквадратичную ошибку (MSE) в качестве функции потерь, а также алгоритм оптимизации Adam (Adaptive Moment Estimation) с шагом обучения $1e-4$. В среднем, с учетом количества используемых данных, процесс обучения занял 50 000 эпох.

4. Полученные результаты.

Среднее значение относительной ошибки предсказания непрерывного спектра $\langle \eta_r(\xi) \rangle_\xi$ для NN при вычислении прямого NFT составляет $2.68 \cdot 10^{-3}$. Для обратного преобразования среднее значение относительной ошибки предсказания сигнала равняется $\langle \eta_q(t) \rangle_t = 1.62 \cdot 10^{-4}$. Полученные результаты демонстрируют, что нейронные сети могут выполнять прямое и обратное нелинейное преобразование Фурье с высокой точностью. На данный момент практическое применение этих методов далеко от коммерческой реализации, однако уже сейчас в лабораторных условиях продемонстрирован потенциал NFT-методов для передачи информации с рекордными скоростями.

5. Иллюстрации, визуализация результатов (опционально).




Рисунок 1 – Архитектура нейронной сети для прогнозирования непрерывного спектра в нелинейном спектре для сложного сигнала. Та же архитектура использовалась для обратного NFT, преобразующего непрерывный спектр обратно в сложный сигнал. Чтобы предсказать реальную и мнимую части спектра (или сигнала), используются две отдельные NN с одинаковыми структурами, но разными весами

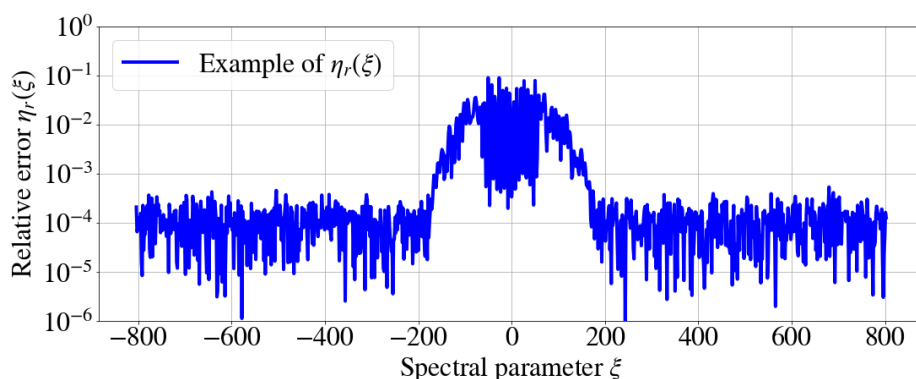


Рисунок 2 – Пример распределения относительной ошибки $\eta_r(\xi)$ между предварительно вычисленным и прогнозируемым непрерывным спектром




Рисунок 3 – Пример распределения относительной ошибки $\eta_q(t)$ между исходным и предсказываемым сигналами

Эффект от использования кластера в достижении целей работы.

Ресурсы кластера использовались для генерации тренировочных наборов данных и для непосредственного обучения и оптимизации архитектуры нейронных сетей.

Перечень публикаций:

1. Sedov, E.V., Chekhovskoy, I.S. and Prilepsky, J.E.E., 2021. Neural network for calculating direct and inverse nonlinear Fourier transform. *Quantum Electronics*, 51(12), p.1118.
2. Sedov, E.V., Chekhovskoy, I.S., Prilepsky, J.E.E. and Fedoruk, M.P., 2020. Application of neural networks to determine the discrete spectrum of the direct Zakharov–Shabat problem. *Quantum Electronics*, 50(12), p.1105.
3. Sedov, E.V., Freire, P.J., Seredin, V.V., Kolbasin, V.A., Kamalian-Kopae, M., Chekhovskoy, I.S., Turitsyn, S.K. and Prilepsky, J.E., 2021. Neural networks for computing and denoising the continuous nonlinear Fourier spectrum in focusing nonlinear Schrödinger equation. *Scientific Reports*, 11(1), p.22857.
4. Sedov, E., Freire, P.J., Chekhovskoy, I., Turitsyn, S. and Prilepsky, J., 2021, September. Neural Networks For Nonlinear Fourier Spectrum Computation. In *2021 European Conference on Optical Communication (ECOC)* (pp. 1-4). IEEE.