


Применение машинного обучения для моделирования нелинейной динамики оптических импульсов в лазерных системах



Анастасия Беднякова¹

anastasia.bednyakova@gmail.com




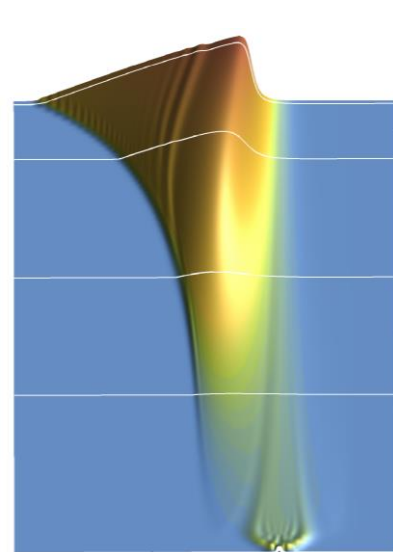
Новосибирский государственный университет



Нелинейность в волоконных лазерах

Волоконные лазеры – физические системы с богатой нелинейной динамикой, играющие важную роль во множестве приложений

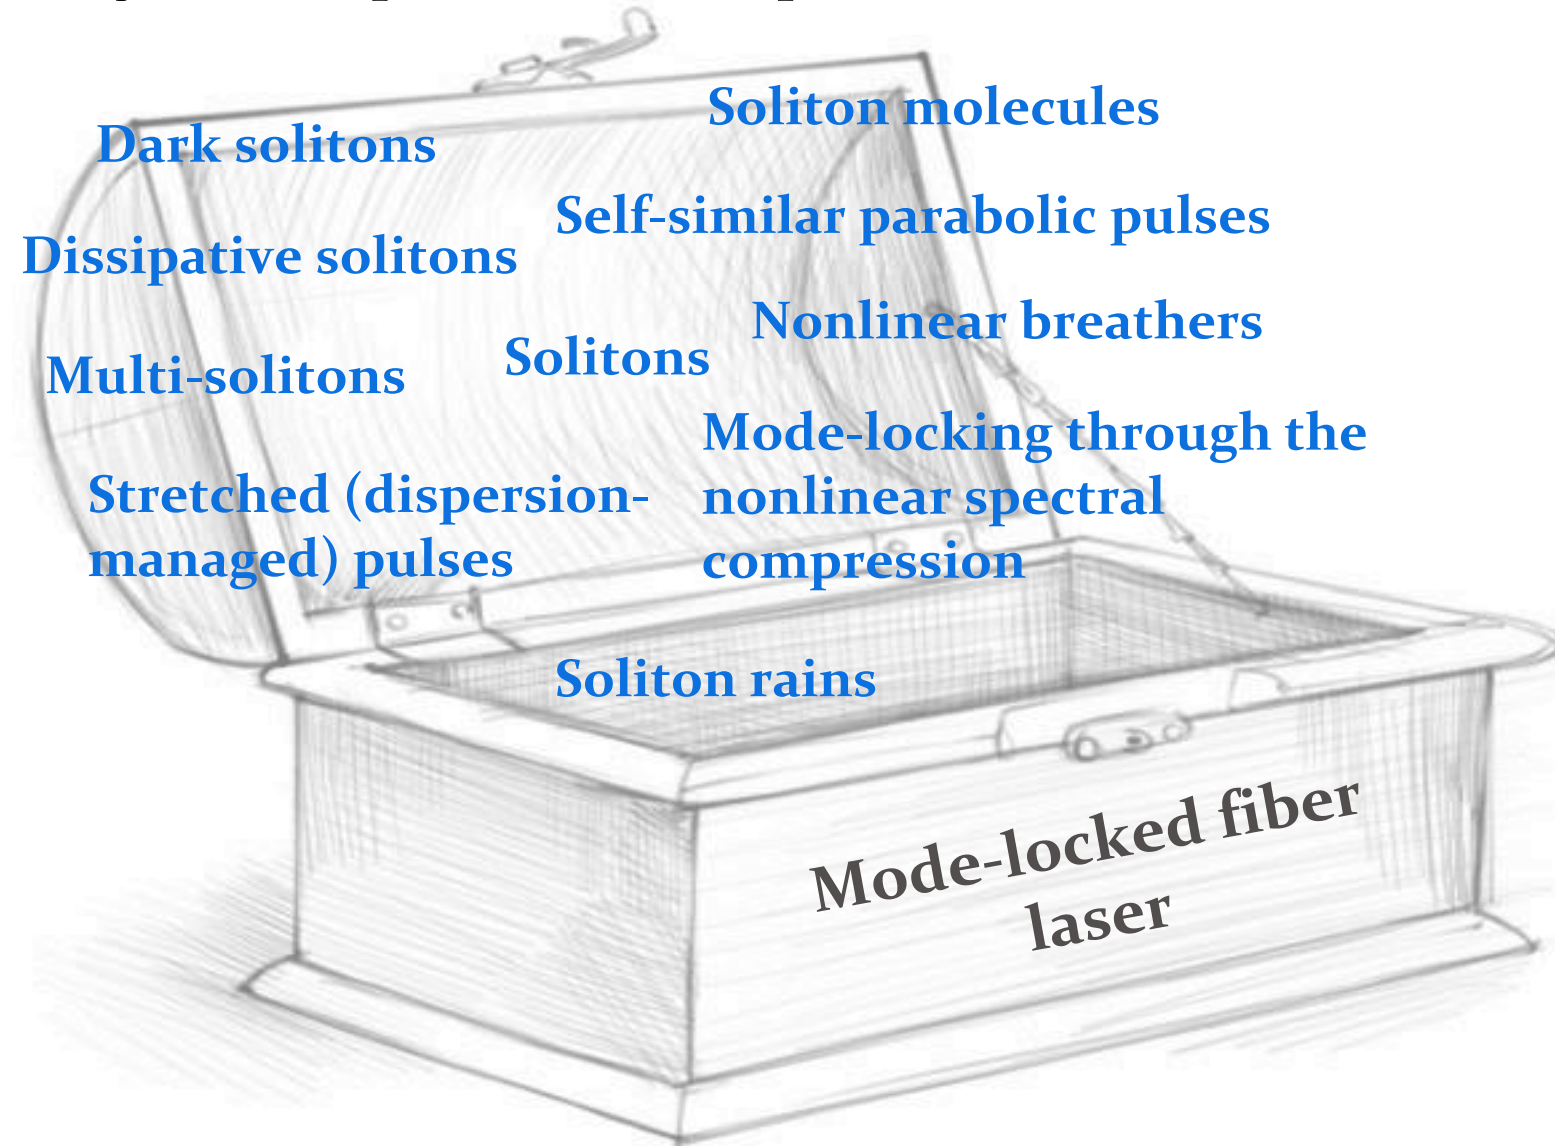
- Нелинейные неустойчивости, образование когерентных структур из шума
- Солитоны, многосолитонная динамика, суперконтинуум
- Нелинейные диссипативные системы
- Самоподобные параболические импульсы
- Вынужденное комбинационное рассеяние
- Бриллюэновское рассеяние
- Нелинейная эволюция поляризации
- Усиленный спонтанный шум в нелинейной системе
- Оптическая волновая турбулентность и хаотическая динамика






Нелинейность в волоконных лазерах

Разнообразие импульсных режимов генерации:





Математическое моделирование



$$\frac{\partial A}{\partial z} = \underbrace{\frac{g_R - \alpha}{2} A}_{\text{net gain}} - \underbrace{\frac{i\beta_2}{2} \frac{\partial^2 A}{\partial t^2}}_{\text{dispersion}} + \underbrace{i\gamma |A|^2 A}_{\text{nonlinearity}}$$

- ☺ Осуществление объёмной оптимизации параметров резонатора
- ☺ Исследование влияния нелинейных процессов на свойства излучения
- ☺ Улучшение понимания принципов работы лазера
- ☺ Создание новых типов волоконных лазеров и усилителей



Методы машинного обучения

Математическое моделирование

- ☹ Ограничения на размер расчетной сетки
- ☹ Высокие временные затраты
- ☹ Вычислительные ресурсы
- ☹ Наличие скрытых параметров в экспериментальной системе

Методы машинного обучения

- ☺ Гибкость в отношении используемых расчетных сеток
- ☺ Способность к обобщению информации
- ☺ Возможность точного описания конкретной экспериментальной системы
- ☺ Высокая скорость вычислений





Цель исследования

Исследование возможностей
использования глубоких нейронных сетей
для прогнозирования нелинейной динамики
ультракоротких импульсов в волоконном световоде



Многослойная нейронная сеть



$$y = \varphi(x \cdot W + b)$$

Функция потерь:

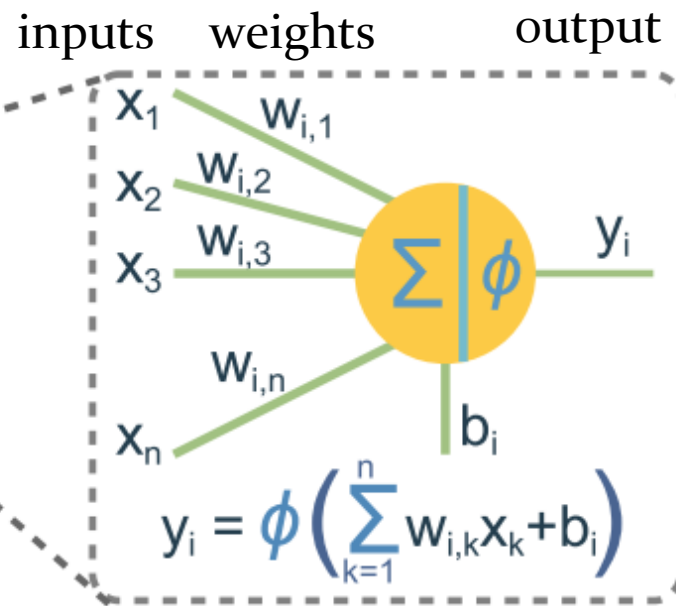

$$L(\theta) = \frac{1}{N} \sum_{i=0}^N (y_i - \hat{y}_i)^2$$

$$\theta = (W_1, W_2, W_3)$$

Нейронная сеть представляет собой комбинацию суперпозиции функций и матричного умножения 7



Многослойная нейронная сеть



$$y = \varphi(x \cdot W + b)$$

Функция потерь:


$$L(\theta) = \frac{1}{N} \sum_{i=0}^N (y_i - \hat{y}_i)^2$$

$$\theta = (W_1, W_2, W_3)$$

Универсальная теорема аппроксимации (теорема Цыбенко, 1989) — искусственная нейронная сеть прямой связи с одним скрытым слоем может аппроксимировать любую непрерывную функцию многих переменных с любой точностью, при условии, что у него достаточно нейронов.



Обучение нейронной сети



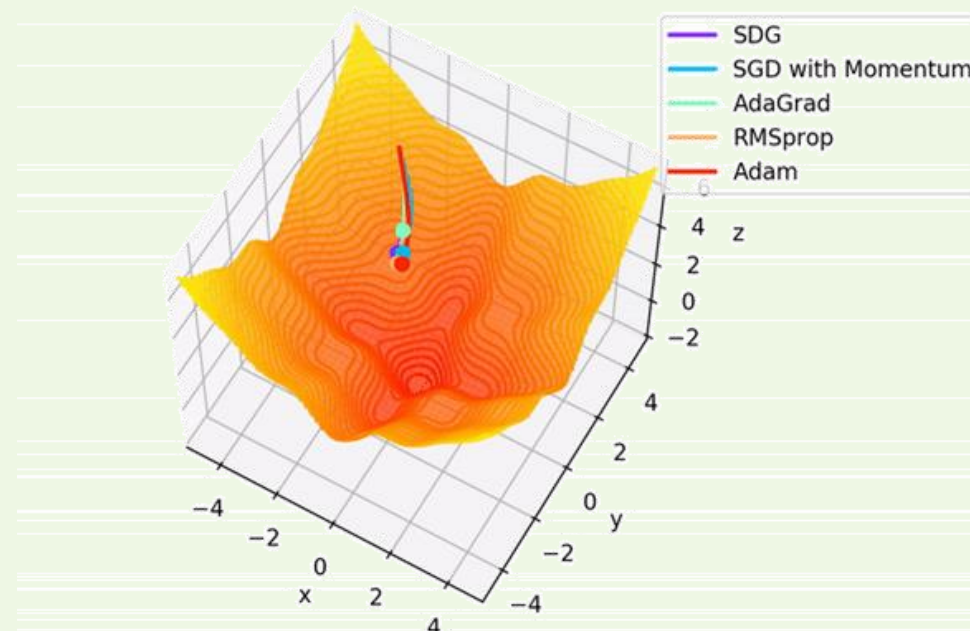
- Стохастический градиентный спуск

$$\vec{w}_1 = \vec{w}_1 - \eta \vec{\nabla}_{w_1} L$$

...

$$\vec{w}_n = \vec{w}_n - \eta \vec{\nabla}_{w_n} L$$


- Метод обратного распространения ошибки





Методы машинного обучения

Dataset Structure for The Learning:



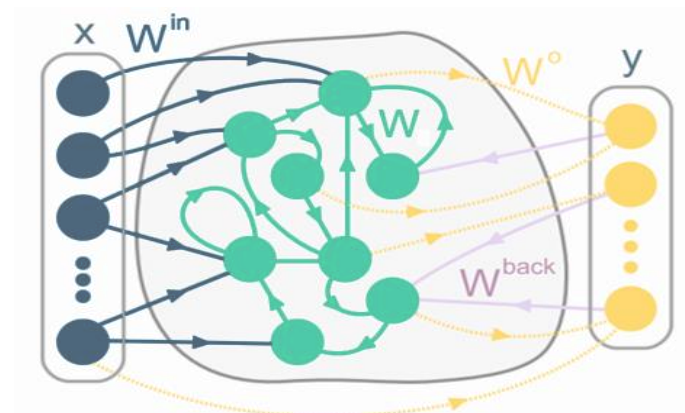



- Only Data Driven Solution (Black Block Approach)
- Model Driven Solutions (Special NN Designs, e.g. solving PDEs)



Методы машинного обучения

Data Driven Solutions


- Multi Layer Perceptron (MLP)
- Convolutional Architectures (1D, 2D, 3D-CNN)
- Recurrent Architectures (RNN, LSTM, GRU, Reservoir computing)





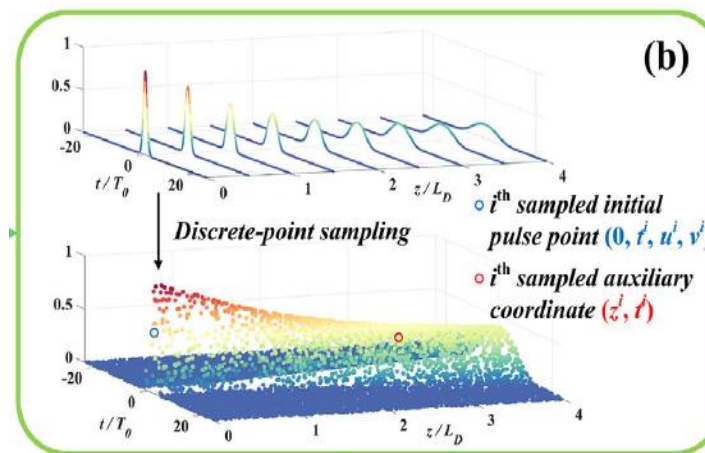
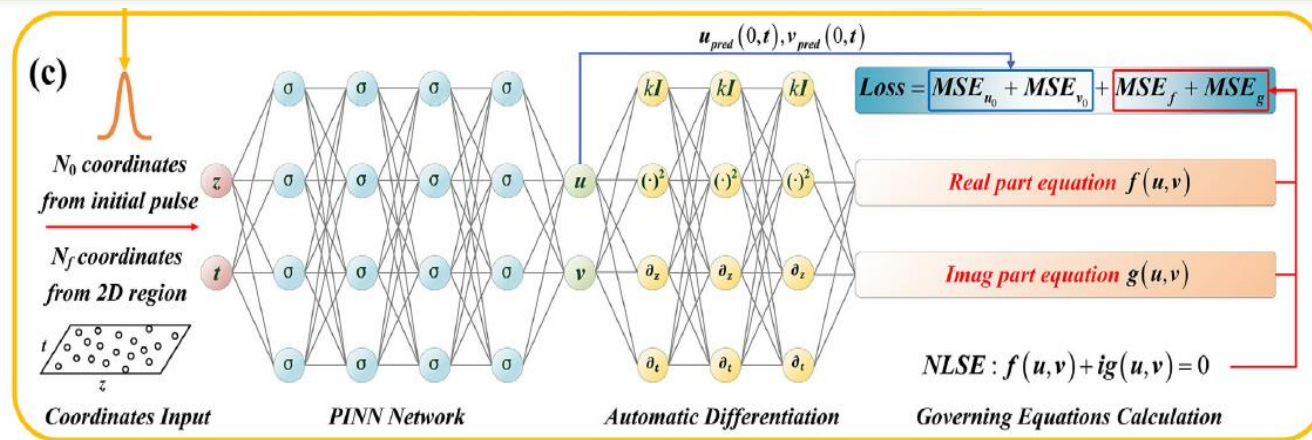
Методы машинного обучения

Model Driven Solutions



- Unusual Activation Functions (taken from physical model) or NN Topology!

O. Sidelnikov et al, "Advanced Convolutional Neural Networks for Nonlinearity Mitigation in Long-Haul WDM Transmission Systems", JLT, V. 39, 8, 2021



- Physics-informed neural networks (PINN)

X. Jiang et al, "Physics-Informed Neural Network for Nonlinear Dynamics in Fiber Optics", Laser & Photonics Reviews




Объект исследования

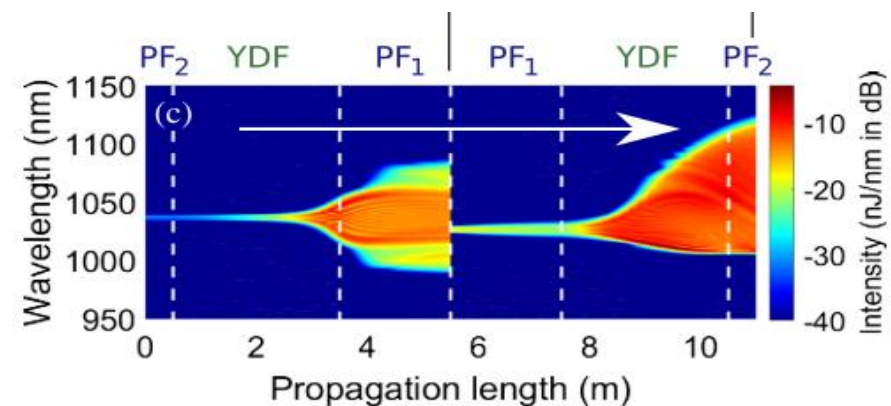


Nonlinear ultrafast fiber amplifiers beyond the gain-narrowing limit

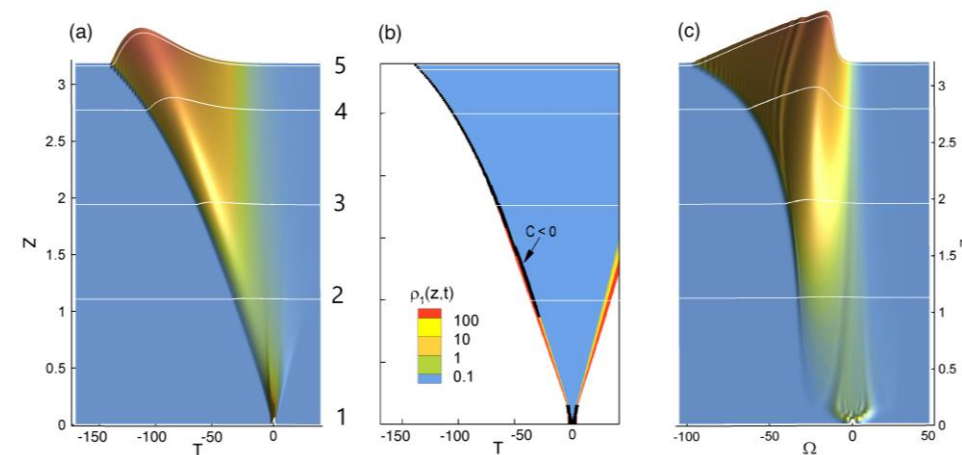
PAVEL SIDORENKO,* WALTER FU, AND FRANK WISE



Осциллятор Мамышева



S. K. Turitsyn, A. E. Bednyakova, and E. V. Podivilov
Phys. Rev. Lett. 131, 2023



Gain-managed nonlinearity (GMN) amplification regime. Несимметричный импульс, формирование которого происходит в усилителе



Численное моделирование

Обобщённое нелинейное уравнение Шрёдингера:

$$\frac{\partial A_s(z, t)}{\partial z} = -i \frac{\beta_2}{2} \frac{\partial^2 A_s(z, t)}{\partial t^2} + \int_{-\infty}^{\infty} \frac{g_s(\omega, z)}{2} \tilde{A}_s(z, \omega) \exp(-i\omega t) d\omega + i\gamma \left(1 + \frac{i}{\omega_0} \frac{\partial}{\partial t} \right) \left(A(z, t) \int_{-\infty}^{\infty} R(t') |A(z, t - t')|^2 dt' \right)$$

дисперсия
усиление
керровская нелинейность и ВКР

$$\frac{\partial P_p(z)}{\partial z} = g_p(z) P_p(z).$$

Эффективная двухуровневая модель усиливающей среды:

$$g_s(\lambda_i, z) = \sigma_{21}^s(\lambda_i) \rho_s(\lambda_i) N_2(z) - \sigma_{12}^s(\lambda_i) \rho_s(\lambda_i) N_1(z), \quad i = 1, \dots, N_\omega$$

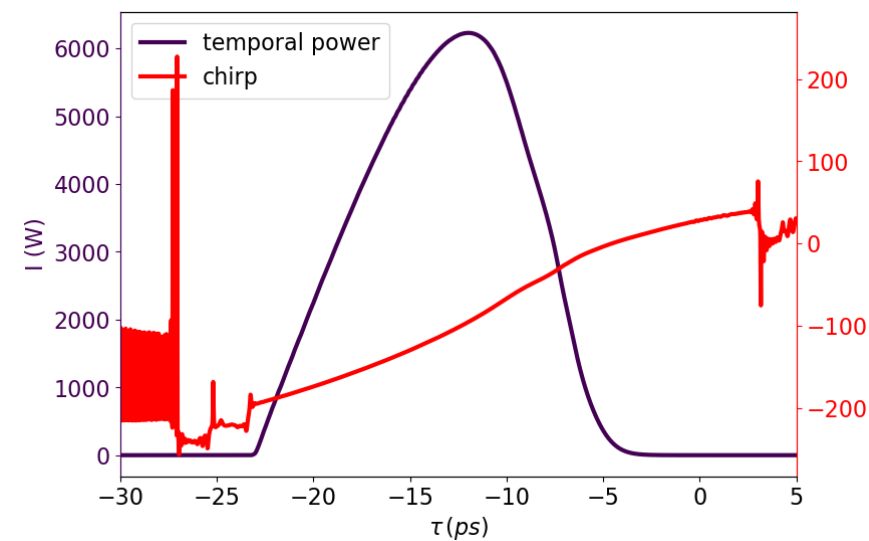
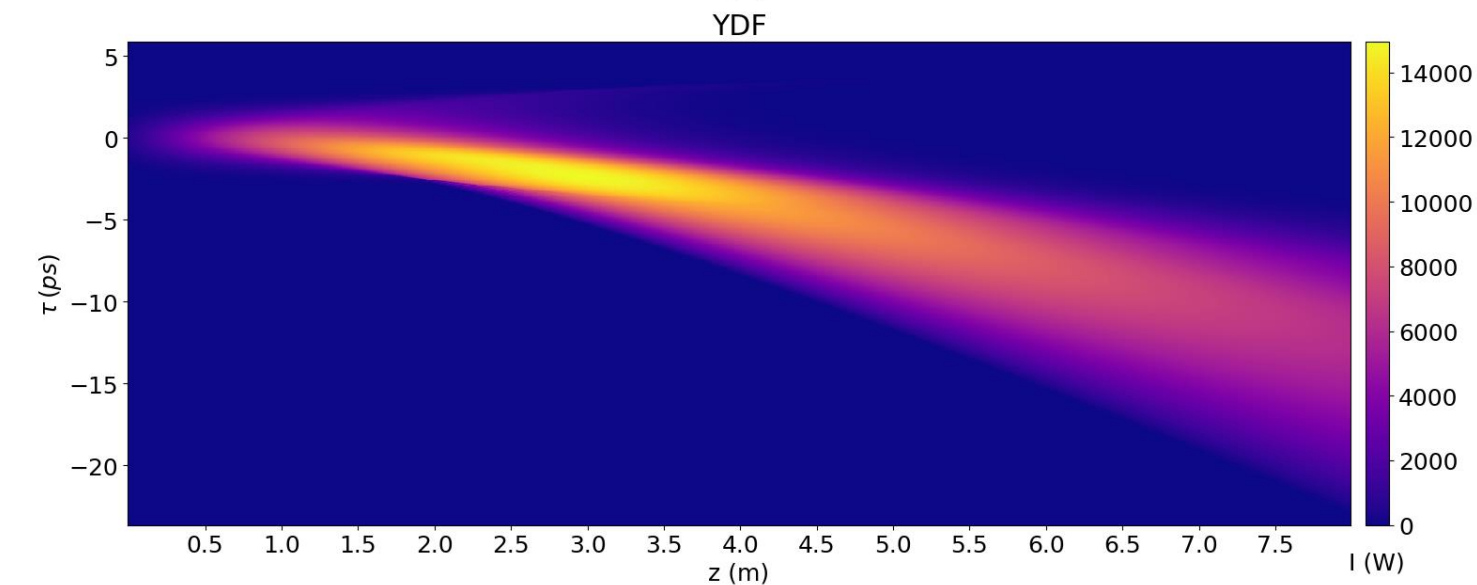
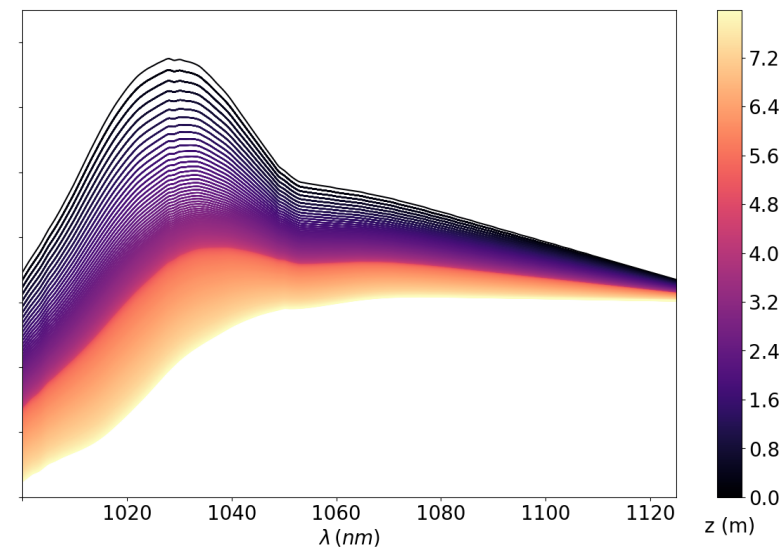
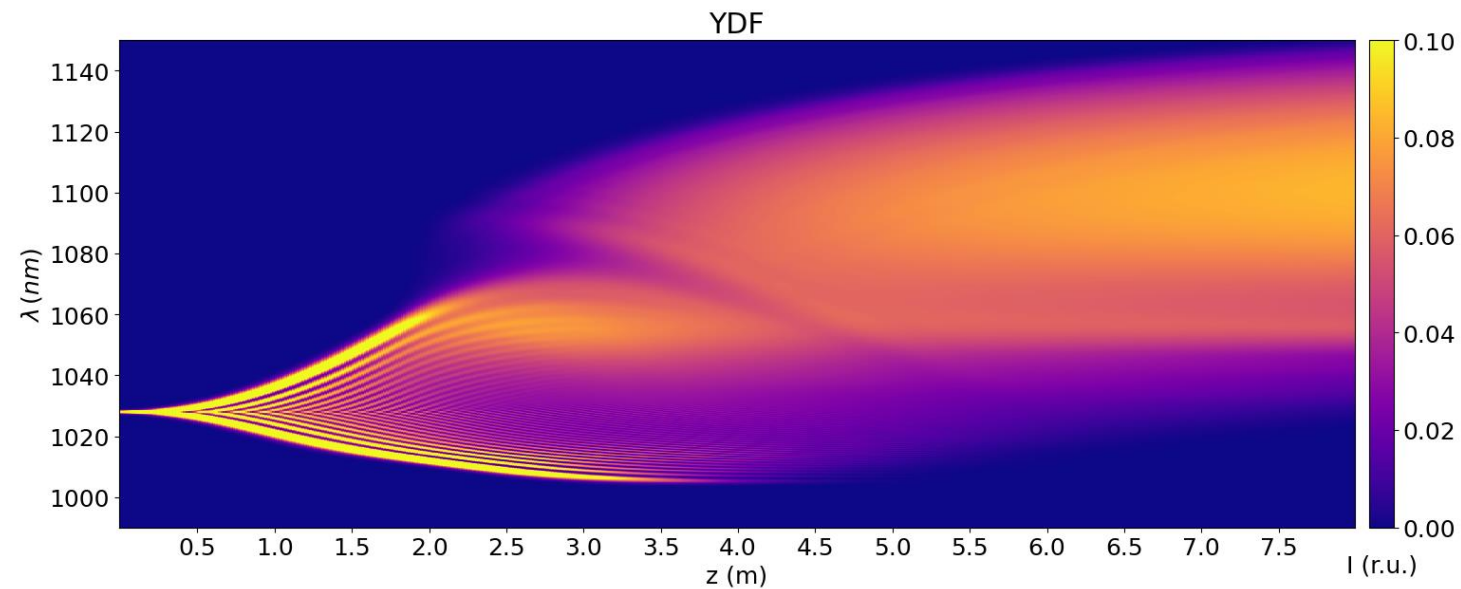
$$g_p(z) = \sigma_{21}^p \rho_p N_2(z) - \sigma_{12}^p \rho_p N_1(z),$$

$$\frac{dN_2(z)}{dt} = \left(\sigma_{12}^p \rho_p \frac{P_p(z)}{h\nu_p} + \sum_{k=1}^k \left(\sigma_{12}^s(\lambda_k) \rho_s(\lambda_k) \frac{P_s(\lambda_k, z)}{h\nu_k} \right) \right) N_1(z) -$$

$$N_1(z) = N - N_2(z) \quad \left(\sigma_{21}^p \rho_p \frac{P_p(z)}{h\nu_p} + \sum_{k=1}^k \left(\sigma_{21}^s(\lambda_k) \rho_s(\lambda_k) \frac{P_s(\lambda_k, z)}{h\nu_k} \right) + \frac{1}{T} \right) N_2(z).$$



Численное моделирование


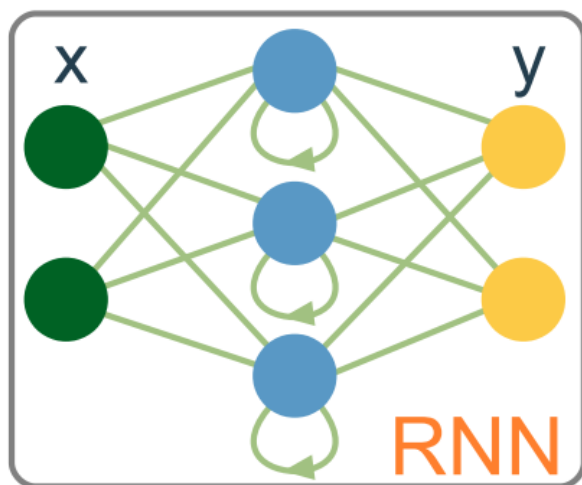




Рекуррентная нейронная сеть

Почему рекуррентные нейронные сети?

- Задача моделирования распространения импульсов **аналогична** задаче прогнозирования временных рядов
- Наличие внутренней памяти **с учетом контекста**

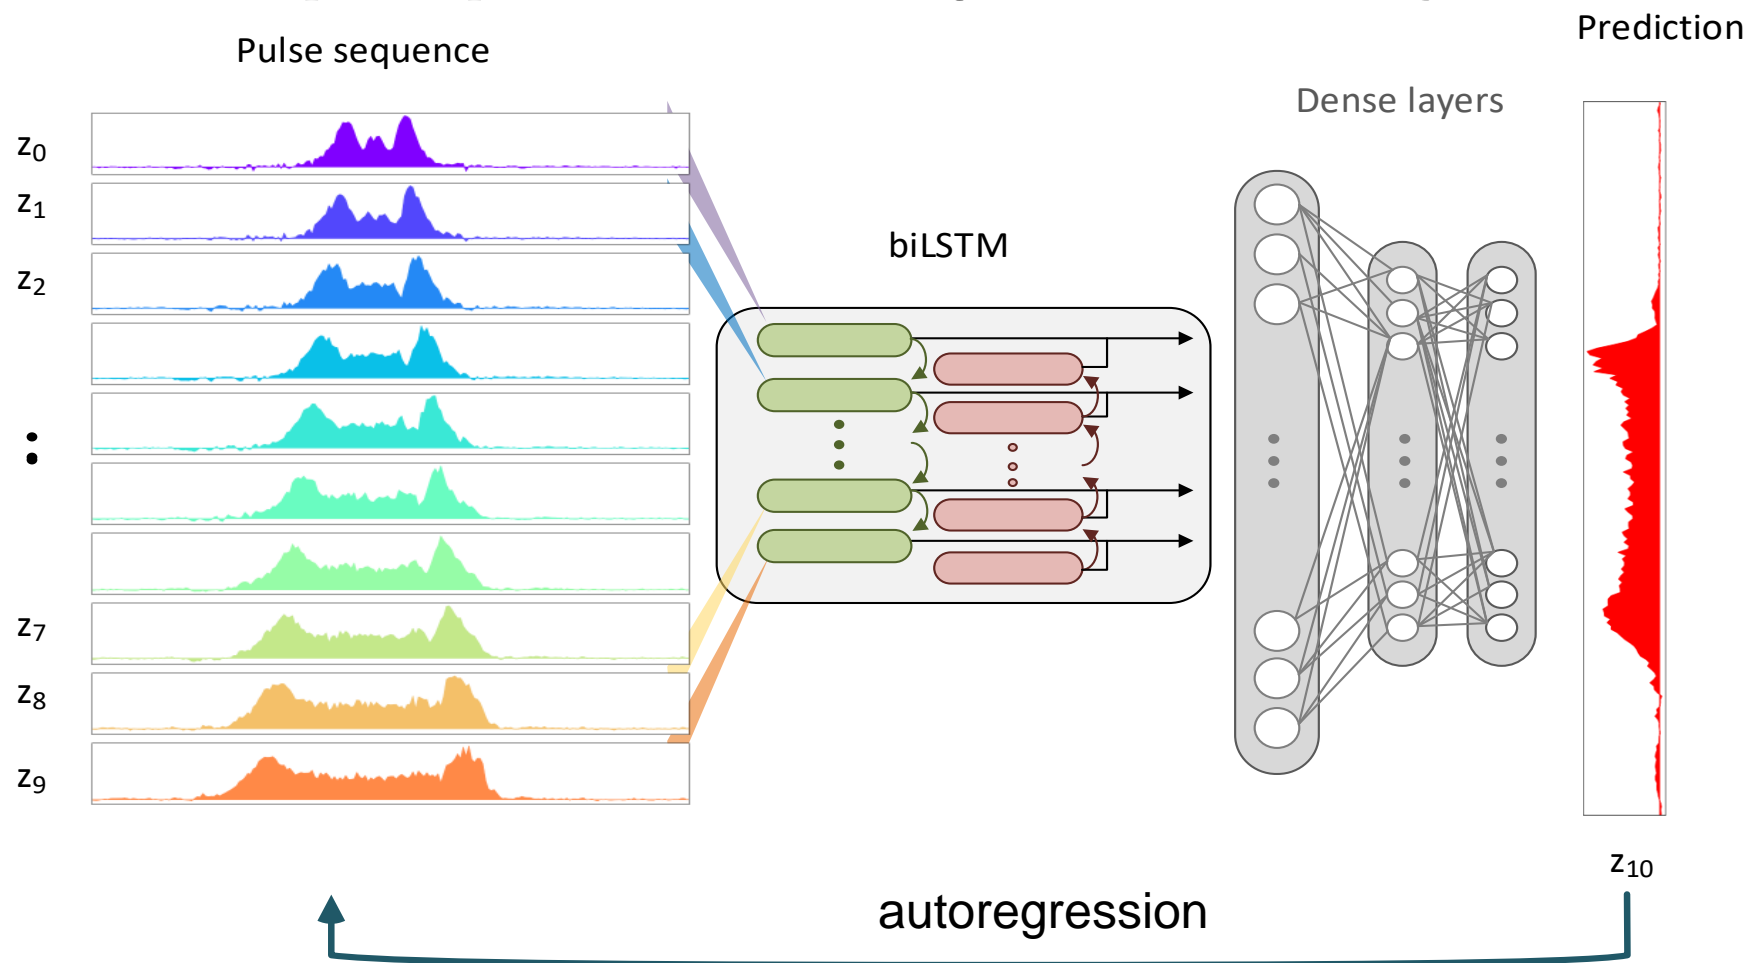


$$h_t = \varphi(W_{in}x_t + Wh_{t-1})$$



LSTM: архитектура

Нейронная сеть долгой краткосрочной памяти (long short-term memory, LSTM):



Salmela, Lauri, et al. "Predicting ultrafast nonlinear dynamics in fibre optics with a recurrent neural network." Nature machine intelligence 3.4 (2021): 344-354.



Подготовка данных




Диапазон параметров начального импульса:

P_0 от 100 Вт до 1 кВт (линейная шкала)

T_0 от 0,1 пс до 10 пс (логарифмическая шкала)



L_D/L_{NL} от 0,25 до 250 => разнообразие режимов усиления

Длина усилителя – 7 м





Анализ предсказаний


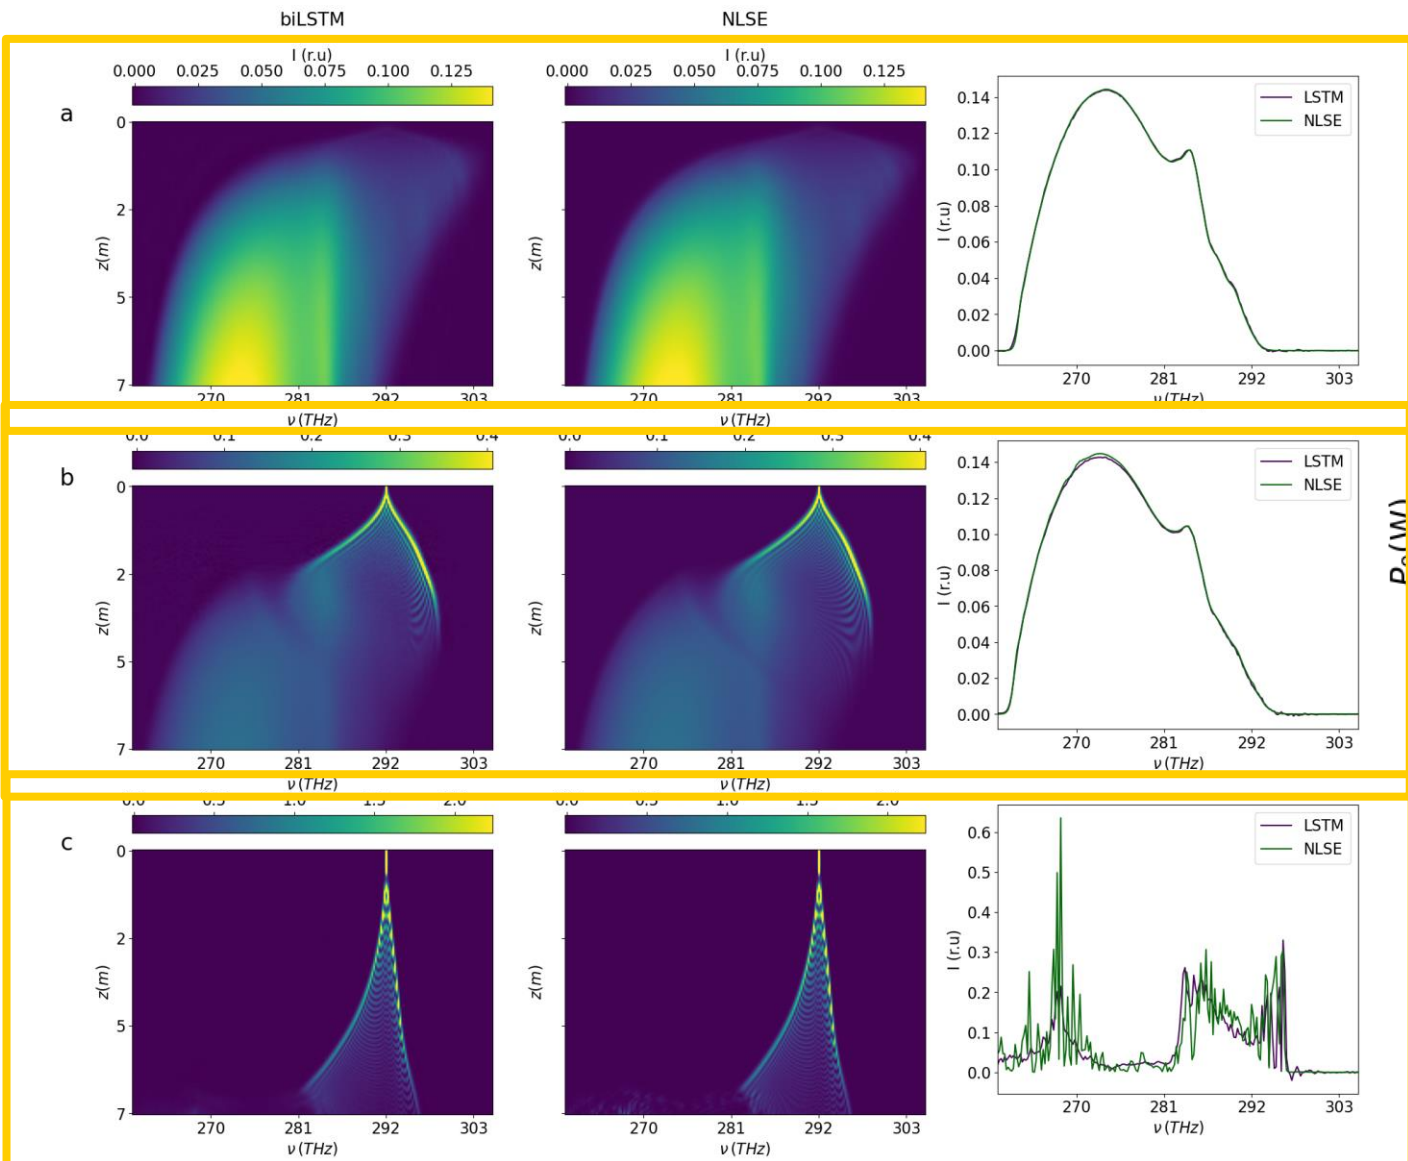


$$NRMSE(I, \hat{I}) = \sqrt{\frac{\sum_{i=1}^{N_{domain}} (I_i - \hat{I}_i)^2}{\sum_{i=1}^{N_{domain}} (\hat{I}_i)^2}}$$

$$PSNR(I_{map}, \hat{I}_{map}) = 20 \cdot \log_{10} \left(\frac{\max(\hat{I}_{map})}{\sqrt{MSE(I_{map}, \hat{I}_{map})}} \right)$$

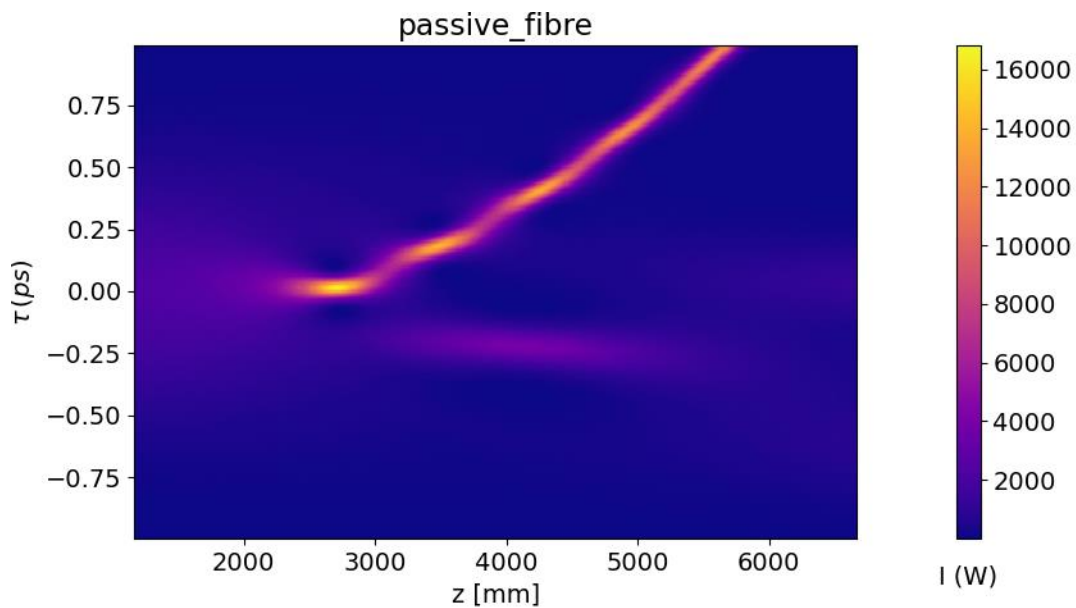



Предсказание спектральной мощности






Перспективы: моделирование Er-усилителя



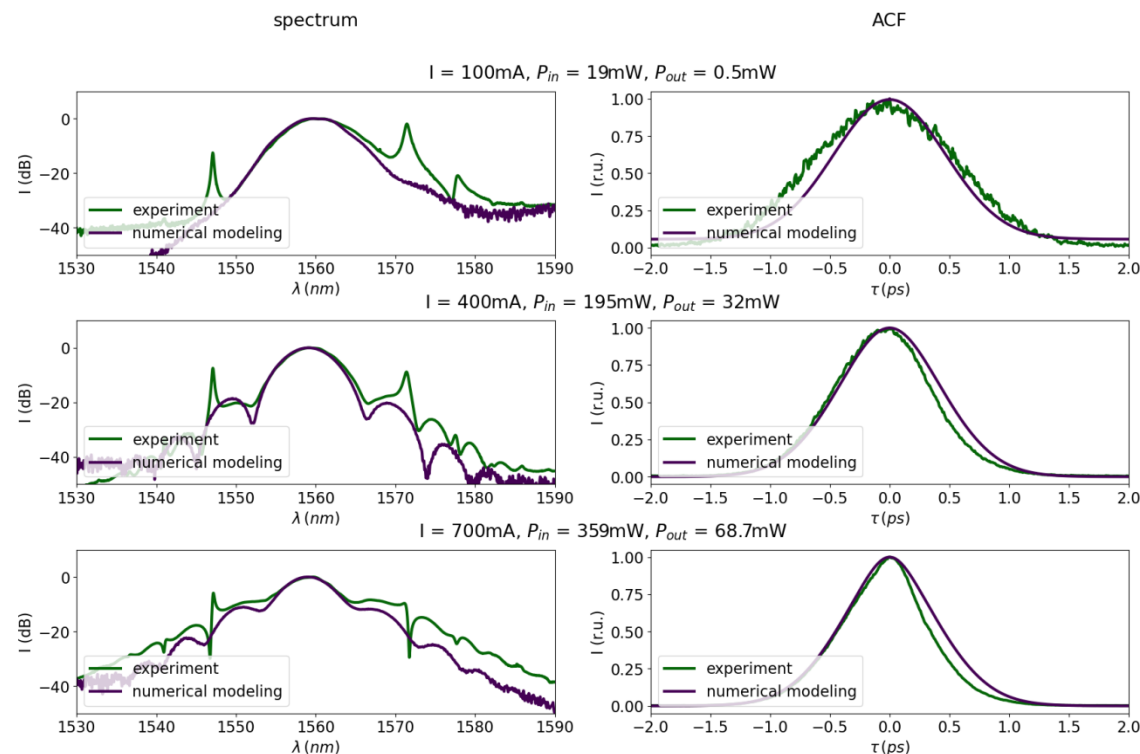


Оптимизация $\rightarrow P_{\text{sat}} I_{\text{sat}}$





Перспективы: моделирование Er-усилителя

Качественное согласование при разных длинах
пассивного световода



$$L_{\text{passive}} = 47 \text{ cm}$$



Спасибо!

Анастасия Беднякова




Карина Сараева



Алексей Редюк



Юрий Гладуш



Михаил Мишевский




Арам Мкртчян





Заключение

- Реализованы и исследованы две архитектуры нейронной сети для предсказания динамики электромагнитного поля в волоконном усилителе: BiLSTM и Transformer-decoder.
- Нейросеть обеспечивает быстрое и точное предсказание эволюции импульса в оптическом усилителе, значительно превосходя традиционные численные методы по скорости.



**Спасибо за
ВНИМАНИЕ!**

anastasia.bednyakova@gmail.com