

АРХИТЕКТУРА ГЛУБОКОГО РАЗВЕРТЫВАНИЯ С МОДУЛЕМ НЕЙРОСЕТОВОЙ РЕГУЛЯРИЗАЦИИ МНОГОКОМПОНЕНТНОЙ ФУНКЦИИ ПОТЕРЬ В ЗАДАЧЕ ВОССТАНОВЛЕНИЯ СПЕКТРОВ НЕЙТРОНОВ

Акимоchkина Мария Александровна¹, Борщев Дмитрий Сергеевич²,
Чижов Константин Алексеевич³

¹Студент;

Государственный университет «Дубна»;

141980, Россия, Московская обл., г. Дубна, ул. Университетская, 19;

e-mail: amaab.22@uni-dubna.ru.

²Студент;

Государственный университет «Дубна»;

141980, Россия, Московская обл., г. Дубна, ул. Университетская, 19;

e-mail: bds.22@uni-dubna.ru.

³Старший научный сотрудник;

Объединенный институт ядерных исследований;

141980, Россия, Московская обл., г. Дубна, ул. Жолио-Кюри, 6;

e-mail: kchizhov@jinr.ru

Восстановление спектра нейтронов по показаниям многошарового спектрометра Боннера является некорректно поставленной задачей по Адамару. Это приводит к неединственности решений и их неустойчивости при наличии в данных шумов. Предлагается подход на основе архитектуры глубокой развертки (DUN) с модулем нейросетевой регуляризации в виде MLP-блоков. Для соответствия решений физическим условиям задачи используется многокомпонентная функция потерь, содержащая слагаемые, отвечающие за среднеквадратичную и дозовую ошибки, гладкость спектра и соответствия решения показаниям детектора. Тестирование проводилось на 251 спектре из компендиума МАГАТЭ, в данные была внесена 5 % случайная ошибка. Разработанный подход демонстрирует высокую точность восстановления спектра (ошибка дозы составила 6 %) и может быть внедрен на предприятиях с дозиметрическим контролем.

Работа выполнена в рамках государственного задания Министерства науки и высшего образования Российской Федерации (тема № 124092700007-4 Применение объяснительного искусственного интеллекта для интерпретации алгоритмов машинного обучения)

Ключевые слова: восстановление спектра нейтронов, многошаровый спектрометр Боннера, некорректно поставленная задача, глубокая развертка, глубокое обучение, нейросетевая регуляризация, анализ данных, функция потерь, МАГАТЭ, дозиметрический контроль.

Для цитирования:

Акимоchkина М. А., Борщев Д. С., Чижов К. А. Архитектура глубокого развертывания с модулем нейросетевой регуляризации многокомпонентной невязки в задаче восстановления спектров нейтронов // Системный анализ в науке и образовании. 2026. № 2. С. 23-28. EDN: PFBFME. URL : <https://sanse.ru/index.php/sanse/article/view/715>.

DEEP UNROLLING ARCHITECTURE WITH NEURAL REGULARIZATION MODULE BASED ON MULTI-COMPONENT LOSS FUNCTION FOR NEUTRON SPECTRUM UNFOLDING

Akimochkina Maria A.¹, Borshchev Dmitry S.², Chizhov Konstantin A.³

¹Student;

Dubna State University,



Статья находится в открытом доступе и распространяется в соответствии с лицензией Creative Commons «Attribution» («Атрибуция») 4.0 Всемирная (CC BY 4.0) <https://creativecommons.org/licenses/by/4.0/deed.ru>

19 Universitetskaya Str., Dubna, Moscow region, 141980, Russia;
e-mail: amaab.22@uni-dubna.ru.

²Student;
Dubna State University,
19 Universitetskaya Str., Dubna, Moscow region, 141980, Russia;
e-mail: bds.22@uni-dubna.ru.

³Senior Researcher;
Joint Institute for Nuclear Research;
6 Joliot-Curie Str., Dubna, Moscow region, 141980, Russia;
e-mail: kchizhov@jinr.ru.

Neutron spectrum reconstruction from the readings of a multisphere Bonner spectrometer constitutes an ill-posed problem in the sense of Hadamard. This leads to the non-uniqueness of solutions and their instability in the presence of data noise. We propose an approach based on a Deep Unrolling Network (DUN) architecture with a neural regularization module implemented as MLP blocks. To ensure that the solutions satisfy the physical constraints of the problem, a multi-component loss function is employed, comprising terms for the mean squared error, dose error, spectral smoothness, and consistency of the solution with the detector readings. The method was tested on 251 spectra from the IAEA compendium, with a 5 % random error introduced into the data. The developed approach demonstrates high accuracy in spectrum reconstruction (the dose error was 6 %) and can be implemented at facilities requiring dosimetric monitoring.

This work was supported by the State Assignment of the Ministry of Science and Higher Education of the Russian Federation (Project No. 124092700007-4 "Application of Explainable Artificial Intelligence for Interpretation of Machine Learning Algorithms").

Keywords: neutron spectrum unfolding, Bonner sphere spectrometer, ill-posed problem, deep unrolling, deep learning, neural regularization, data analysis, loss function, IAEA, dosimetric monitoring.

For citation:

Akimochkina M. A., Borshchev D. S., Chizhov K. A. Deep Unrolling architecture with neural regularization module based on multi-component loss function for neutron spectrum unfolding. *System analysis in science and education*, 2026;(2):23-28 (in Russ). EDN: PFBFME. Available from: <https://sanse.ru/index.php/sanse/article/view/715>.

Введение

Восстановление энергетического спектра нейтронов является актуальной задачей в области обеспечения радиационной безопасности и дозиметрического контроля. Биологическая эффективность нейтронного излучения существенно зависит от энергии частиц, а использование лишь интегральных характеристик не позволяет произвести корректные дозиметрические расчеты. Для восстановления нейтронных спектров в широком диапазоне энергий (от тепловых нейтронов до ГэВ) используется многошаровый спектрометр Боннера. Связь показаний спектрометра с искомым энергетическим распределением осуществляется через систему уравнений Фредгольма 1-го рода:

$$Q_j = \int_{E_{min}}^{E_{max}} K_j(E) \cdot \phi(E), \quad j = 1, \dots, M, \quad (1)$$

где Q_j – показание спектрометра Боннера для j -го шара, $K_j(E)$ – функция чувствительности детектора, $\phi(E)$ – полный энергетический спектр нейтронов, M – число шаров, E_{min} , E_{max} – нижняя и верхняя границы энергетического диапазона, определяемые постановкой задачи. В связи с сильной недоопределенностью системы, данная задача является некорректно поставленной по Адамару. Это влечет за собой неединственность и неустойчивость решений, что требует применения специализированных вычислительных методов [1, 3 – 6]. Итерационные методы (*MAXED*, *GRAVEL*) крайне чувствительны к выбору начального приближения [2]. Регуляризационные методы (метод Тихонова) требуют тщательного подбора сглаживающих параметров и могут исказить особенности формы спектра [1, 4, 5]. Нейросетевые подходы, такие как ансамблевые методы (*Random Forest*) и более сложные архитектуры на основе глубокого обучения не содержат априорной информации о постановке задачи, поэтому могут поддерживать физически некорректные решения [3, 6].

Предлагается подход на основе нейросетевой архитектуры глубокого развертывания (*Deep Unrolling Networks*) представляющий из себя гибридный итеративный алгоритм на основе метода Ландвебера и нейросетевой регуляризации с помощью *MLP* блоков [7]. Для коррекции решений используется многокомпонентная функция потерь [8]. Реализация метода выполнена на языке Python с использованием *TensorFlow* и *Keras*.

1. Архитектура DUN+MLP

Гибридная модель глубокого развертывания (*DUN*) строится на основе метода Ландвебера, дополненного обучаемым *MLP*-блоком для нелинейной коррекции остаточных ошибок [9]. Начальное приближение $\phi^{(0)}$ задаётся проекцией псевдообратного решения в область физически допустимых неотрицательных значений:

$$\phi^{(0)} = \text{ReLU}(K^\dagger Q), \quad (2)$$

где K^\dagger – псевдообратная матрица Мура-Пенроуза. На каждом слое развёртки выполняется градиентный шаг с обучаемым параметром α_i :

$$\phi_{\text{grad}}^{(i)} = \phi^{(i)} - \alpha_i K^\top (K \phi^{(i)} - Q), \quad (3)$$

после чего состояние корректируется параметризованным нелинейным оператором Ψ_θ :

$$\delta^{(i)} = s_{\text{mlp}} \cdot \Psi_\theta(\phi_{\text{grad}}^{(i)}), \quad \phi^{(i+1)} = \text{ReLU}(\phi_{\text{grad}}^{(i)} + w_{\text{res}} \delta^{(i)}), \quad (4)$$

где $w_{\text{res}} \in [0,1]$ – коэффициент остаточной связи, определяющий долю нейросетевой коррекции, а s_{mlp} – коэффициент масштаба регуляризации. Итоговое решение формируется как композиция N операторов перехода \mathcal{F}_{θ_i} :

$$\phi^{(N)} = (\mathcal{F}_{\theta_{N-1}} \circ \mathcal{F}_{\theta_{N-2}} \circ \dots \circ \mathcal{F}_{\theta_0})(\phi^{(0)}). \quad (5)$$

Обучение проводится через минимизацию многокомпонентной функции потерь [8]. Она представляет собой линейную комбинацию из четырех взвешенных критериев:

$$\mathcal{L} = \omega_1 \mathcal{L}_{\text{mse}} + \omega_2 \mathcal{L}_{\text{dose}} + \omega_3 \mathcal{L}_{\text{forward}} + \omega_4 \mathcal{L}_{\text{smooth}}, \quad (6)$$

где \mathcal{L}_{mse} контролирует точность воспроизведения формы спектра, $\mathcal{L}_{\text{dose}}$ обеспечивает соответствие дозиметрическим характеристикам, $\mathcal{L}_{\text{forward}}$ отвечает за согласованность решения с экспериментальными данными, а $\mathcal{L}_{\text{smooth}}$ выполняет регуляризирующую функцию, подавляя высокочастотные осцилляции. Для $\mathcal{L}_{\text{dose}}$ мощность эффективной дозы выясняется по выр. 7:

$$\dot{H}_{\text{ISO}} = \int_{E_{\text{min}}}^{E_{\text{max}}} \varphi(E) \cdot h_{\text{ISO}}(E) dE, \quad (7)$$

где $h_{\text{ISO}}(E)$ – дозовый коэффициент для изотропной геометрии облучения [11].

Блок многослойного перцептрона (*MLP*) реализует отображение входного вектора в вектор коррекции идентичной размерности и состоит из пяти последовательных слоёв: входного (60 нейронов соответствующих дискретизированному по шкале от 10^{-9} до 660 МэВ энергетическому спектру), трёх скрытых (64, 128 и 64 нейрона) и выходного (60 нейронов). На первом скрытом слое применяется функция активации *Swish*, обеспечивающая гладкую нелинейность, тогда как последующие скрытые слои дополнены нормализацией по слою (*Layer Normalization*) для стабилизации распределения активаций и операцией Dropout для снижения риска переобучения. Выходной слой использует функцию *tanh*, сжимающую значения корректирующего вектора в интервал $[-1,1]$, что обеспечивает численную устойчивость итерационного процесса. Всего в сети развёртки используется 15 слоёв. В качестве оптимизатора параметров модели используется метод Adam. Предложенная архитектура *DUN+MLP* компенсирует эффекты плохой обусловленности и шума за счёт обучаемой нелинейной регуляризации. Схема алгоритма приведена на рис.1.

Для обучения разработанной модели использовалась синтетическая обучающая выборка, полученная на основе метода *Frascati Unfolding Interactive Tool (FRUIT)* [10]. Состав выборки включает 500 000 спектров, сгенерированных как взвешенная сумма надтепловой, тепловой, быстрой и

высокоэнергетической компонент. Функции отклика для многошарового спектрометра Боннера с детектором $LiI(Eu)$ взяты из компедиума МАГАТЭ [11].

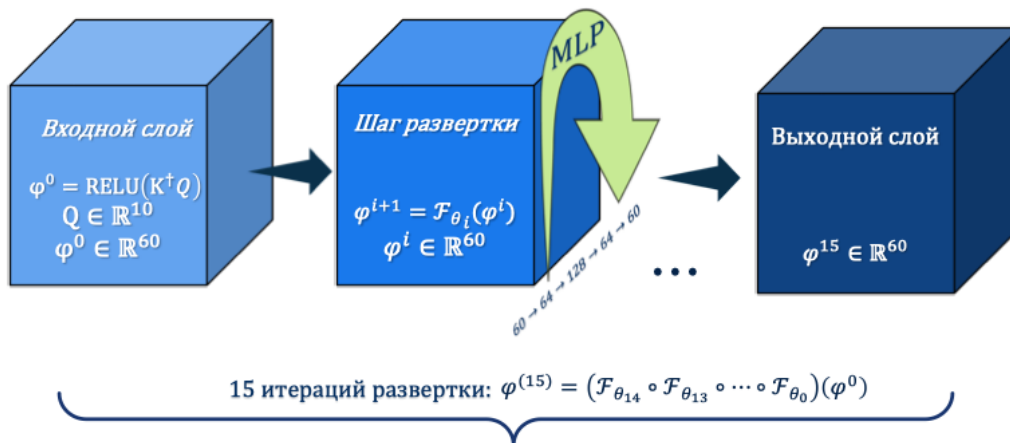


Рис. 1. Схема алгоритма DUN с MLP уточняющими блоками

2. Результаты

Тестирование модели проводилось на 251 спектре компедиума МАГАТЭ, включая 20 спектров, смоделированных методом Монте-Карло [11]. Для оценки устойчивости к погрешностям измерений в показания детекторов вносилась 5 % случайная ошибка. Произведено сравнение трех моделей: *DUN+MLP* с невязкой, *MLP* с невязкой и базовой *MLP*. Используемые метрики для сравнения включают коэффициент детерминации R^2 , корень из среднеквадратичного отклонения *RMSE* и абсолютную дозовую ошибку в процентах. Применение разработанной многокомпонентной функции потерь обеспечило существенное снижение дозовой ошибки: с 32,1 % для базовой модели *MLP* до 12,3 % при использовании той же архитектуры с регуляризацией, и до 6,9 % в полной гибридной конфигурации *DUN+MLP*. Метрики качества $R^2 = 0,89$ и $RMSE = 0,047$ подтверждают высокую точность восстановления формы спектра и близость решения к эталонному распределению даже в условиях зашумлённых данных.

Результат восстановления спектра *IPSN-SDOS* приведен на рис. 2 [11]. Архитектура *DUN+MLP* демонстрирует высокую точность реконструкции. Разработанный алгоритм на основе глубокой развертки позволил снизить дозовую ошибку с 3,0 % (модель *MLP* с невязкой) до 1,21 %. Коэффициент детерминации R^2 увеличился с 0,77 (*MLP* модель) до 0,82, что подтверждает лучшее соответствие восстановленного спектра эталонному распределению. При использовании *DUN+MLP* алгоритма средняя абсолютная ошибка (*MAE*) уменьшилась с 0,03 (*MLP*) до 0,02, а среднеквадратичная ошибка (*RMSE*) с 0,045 (*MLP*) до 0,039, что свидетельствует о повышении точности как глобальной, так и локальной аппроксимации.




Рис. 2. Результат восстановления спектра *IPSN-SDOS* (14 MeV, 20 cm water shield)

Результаты восстановления для спектра *UTR-Kinki* представлены на рис. 3 [11]. Архитектура *DUN+MLP* демонстрирует превосходство над базовой моделью *MLP* по всем ключевым метрикам: ошибка в оценке дозы снизилась с 4,2 % до 2,0 %, коэффициент детерминации R^2 увеличился с 0,88 до 0,95, *MAE* уменьшилась с 0,011 до 0,006, а *RMSE* снизилась с 0,014 до 0,009. Важно отметить, что именно гибридная модель *DUN+MLP* смогла корректнее воспроизвести пиковую структуру в области высоких энергий, тогда как базовая *MLP* модель с невязкой демонстрирует завышение амплитуды основного высокоэнергетического пика.

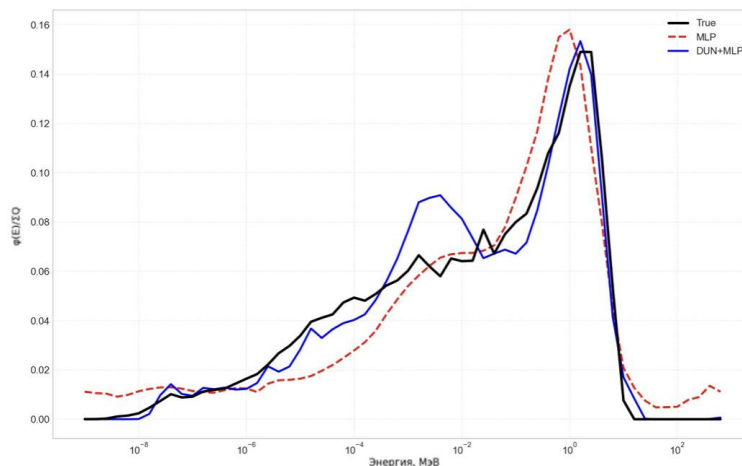


Рис. 3. Результат восстановления спектра *UTR-Kinki facility (in void + fission plate with boron)*

Дополнительно был проведён анализ важности компонент функции потерь для оценки вклада каждого слагаемого в итоговое решение. Результаты показали, что значимость компонент зависит от уровня статистического шума во входных данных. На незашумлённых данных определяющую роль играют \mathcal{L}_{mse} и \mathcal{L}_{dose} . Исключение \mathcal{L}_{mse} снижает коэффициент корреляции на 63 %, что свидетельствует о потере локальных особенностей спектра, тогда как отказ от \mathcal{L}_{dose} приводит к росту дозовой ошибки до 140 %. Компонента \mathcal{L}_{smooth} на незашумлённых данных может избыточно сглаживать узкие пики, однако при наличии 5 % ошибки в показаниях детектора её исключение увеличивает дозовую ошибку на 4,6 %, подтверждая её ключевую регуляризующую функцию, а именно подавление высокочастотных осцилляций и снижение риска переобучения. Компонента $\mathcal{L}_{forward}$, обеспечивающая согласованность с прямой задачей $K\Phi \approx Q$, демонстрирует умеренное влияние на чистых данных, но при зашумлении снижает дозовую ошибку на 2,0 %, предотвращая сходимость к физически некорректному решению. Таким образом, каждая компонента функции потерь вносит свой вклад в обеспечение робастности и высокой точности воспроизведения формы спектра.

Заключение

В работе представлен гибридный алгоритм глубокого развёртывания (*DUN+MLP*) для решения некорректной обратной задачи восстановления энергетических спектров нейтронов по показаниям спектрометра Боннера. Модель *DUN+MLP* демонстрирует устойчивую реконструкцию спектров различной физической природы, обеспечивая близкое соответствие эталонным распределениям и существенное улучшение всех ключевых метрик качества, включая дозовую ошибку. Интеграция итерационной схемы Ландвебера с параметризуемым нейросетевым корректором позволяет эффективно компенсировать эффекты плохой обусловленности матрицы откликов и статистического шума измерений, сохраняя при этом физическую интерпретируемость шагов развёртки.

Важным фактором, определяющим эффективность метода, выступает физически мотивированная регуляризация, реализованная через многокомпонентную функцию потерь. Сбалансированное сочетание слагаемых, отвечающих за точность воспроизведения локальной формы спектра, интегральные дозиметрические характеристики, согласованность с прямой задачей и гладкость решения, позволяет одновременно достигать высокой спектральной точности и надёжной оценки дозы. Абляционный анализ компонентов невязки продемонстрировал вклад каждой части в стабилизацию решений, которая наиболее ярко проявляется в условиях зашумлённых входных данных.

Следует отметить, что при изменении типа детектора, геометрии измерительной установки или материалов защиты модель требует обязательного переобучения на выборке, сгенерированной с учётом актуальных параметров системы. Это обусловлено изменением матрицы откликов и статистических характеристик шума, что ограничивает прямое применение обученных весов без адаптации к новым условиям эксплуатации.

Разработанный подход применим для обработки результатов измерений многошаровым спектрометром Боннера высокоэнергетических нейтронных полей. Дальнейшие исследования будут направлены на расширение обучающей выборки, модификацию архитектуры для повышения метрик и адаптацию кода для применения на аппаратных платформах для оперативного мониторинга радиационной обстановки.

Список источников

1. Chizhov K., Beskrovnaya L., Chizhov A.. Neutron Spectrum Unfolding Method Based on Shifted Legendre Polynomials, Its Application to the IREN Facility // *Physics of Particles and Nuclei Letters*. 2025. Vol. 22(2). Pp. 337–340.
2. Reginatto M., Goldhagen P. MAXED, A Computer Code For The Deconvolution Of Multisphere Neutron Spectrometer Data Using The Maximum Entropy Method. – New York: Environmental Measurements Laboratory, U.S. Department of Energy, 1998.
3. Восстановление энергетического спектра потока нейтронного излучения с помощью алгоритма машинного обучения «случайный лес» / К. А. Chizhov, А. А. Bely, М. D. Starikovskaia, Е. N. Volkov // *Современные информационные технологии и ИТ-образование*. 2024. Т. 20, № 4.
4. Chizhov K., Chizhov A. Optimization of the Neutron Spectrum Unfolding Algorithm Using Shifted Legendre Polynomials Based on Weighted Tikhonov Regularization // *Physics of Particles and Nuclei*. 2025. Vol. 56, № 6. Pp. 1395–1399.
5. Chizhov K., Beskrovnaya L., Chizhov A. Neutron Spectra Unfolding from Bonner Spectrometer Readings by the Regularization Method Using the Legendre Polynomials // *Physics of Particles and Nuclei*. 2024. Vol. 55. № 3. Pp. 532–534.
6. Chizhov K. A., Bely A. A. Neutron Spectrum Unfolding Using Deep Learning Models for Tabular Data // *Moscow University Physics Bulletin*. 2025. Vol. 80, № S3. Pp. S987–S995.
7. Monga V., Li Y., Eldar Y. C. Algorithm Unrolling: Interpretable, Efficient Deep Learning for Signal and Image Processing // *IEEE Signal Processing Magazine*. 2021. Vol. 38(2). Pp. 18–44.
8. Акимочкина М. А., Борщев Д. С., Чижов К. А. Нейросетевое восстановление спектра нейтронов с физически информированной функцией потерь // *Физико-технические интеллектуальные системы : сборник тезисов V Научно-практической конференции (ФТИС–2026), 10–12 февраля 2026 г., Москва / сост. И. Г. Кулло, С. П. Масленников, Е. В. Рябева. Тамбов : ООО «Издательство Юлис», 2026. С. 14.*
9. Engl H. W., Hanke M., Neubauer G. *Regularization of Inverse Problems*. Dordrecht: Springer Netherlands, 1996.
10. FRUIT: An operational tool for multisphere neutron spectrometry in workplaces / R. Bedogni, C. Domingo, A. Esposito, F. Fernández // *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*. 2007. Vol. 580(3). Pp. 1301–1309.
11. *Compendium of neutron spectra and detector responses for radiation protection purposes: technical reports series No. 318*. Vienna: International Atomic Energy Agency, 2001. 288 p.