
ИНФОРМАТИКА, УПРАВЛЕНИЕ И СИСТЕМНЫЙ АНАЛИЗ

УДК 004.852

EDN SUATEQ

**ИТЕРАТИВНАЯ ТОНКАЯ НАСТРОЙКА НЕЙРОННОЙ СЕТИ
ДЛЯ ОБРАБОТКИ ДАННЫХ
ДВУХЭКРАННОГО МАГНИТНОГО СПЕКТРОМЕТРА****Ю.А. Родимков**ORCID: 0000-0003-2962-9366 e-mail: rodimkov@itmm.unn.ruНациональный исследовательский
Нижегородский государственный университет им. Н.И. Лобачевского
*Нижний Новгород, Россия***С.Е. Перевалов**ORCID: 0000-0001-9347-7374 e-mail: perevalov@ipfran.ruИнститут прикладной физики Российской академии наук
*Нижний Новгород, Россия***В.Д. Волокитин**ORCID: 0000-0003-1075-1329 e-mail: volokitin@itmm.unn.ruНациональный исследовательский
Нижегородский государственный университет им. Н.И. Лобачевского
*Нижний Новгород, Россия***А.В. Котов**ORCID: 0000-0002-0454-3403 e-mail: kotov@ipfran.ruИнститут прикладной физики Российской академии наук
*Нижний Новгород, Россия***А.А. Соловьев**ORCID: 0000-0001-8595-5604 e-mail: so_lo@ipfran.ruИнститут прикладной физики Российской академии наук
*Нижний Новгород, Россия***И.Б. Мееров**ORCID: 0000-0001-6905-2050 e-mail: meerov@vmk.unn.ruНациональный исследовательский
Нижегородский государственный университет им. Н.И. Лобачевского
Нижний Новгород, Россия

Предложен метод повышения точности восстановления распределения электронов с использованием тонкой настройки модели машинного обучения. Модель дообучается с помощью экспериментально обоснованного синтетического набора данных: предобученная модель предсказывает физические параметры на экспериментальных данных, которые затем применяются как входные параметры для численного моделирования. Новые генерируемые примеры имеют распределение, близкое к истинным аналогам в экспериментальных данных. Предложенный подход позволяет повысить точность аппроксимации в среднем на 8 %.

Ключевые слова: глубокое обучение; сверточные нейронные сети; тонкая настройка; синтетические данные; численное моделирование лазеров; лазерное кильватерное ускорение; взаимодействие лазера с плазмой; магнитный спектрометр.

ДЛЯ ЦИТИРОВАНИЯ: Родимков, Ю.А. Итеративная тонкая настройка нейронной сети для обработки данных двухэкранного магнитного спектрометра / Ю.А. Родимков, С.Е. Перевалов, В.Д. Волокитин, А.В. Котов, А.А. Соловьев, И.Б. Мееров // Труды НГТУ им. Р.Е. Алексеева. 2026. № 2. С. 7-16. EDN SUATEQ

ITERATIVE FINE-TUNING OF NEURAL NETWORK FOR PROCESSING DATA FROM TWO-SCREEN MAGNETIC SPECTROMETER

Yu.A. Rodimkov

ORCID: **0000-0003-2962-9366** e-mail: **rodimkov@itmm.unn.ru**
National Research Lobachevsky State University of Nizhny Novgorod
Nizhny Novgorod, Russia

S.E. Perevalov

ORCID: **0000-0001-9347-7374** e-mail: **perevalov@ipfran.ru**
Institute of Applied Physics of the Russian Academy of Sciences
Nizhny Novgorod, Russia

V.D. Volokitin

ORCID: **0000-0003-1075-1329** e-mail: **volokitin@itmm.unn.ru**
National Research Lobachevsky State University of Nizhny Novgorod
Nizhny Novgorod, Russia

A.V. Kotov

ORCID: **0000-0002-0454-3403** e-mail: **kotov@ipfran.ru**
Institute of Applied Physics of the Russian Academy of Sciences
Nizhny Novgorod, Russia

A.A. Soloviev

ORCID: **0000-0001-8595-5604** e-mail: **so_lo@ipfran.ru**
Institute of Applied Physics of the Russian Academy of Sciences
Nizhny Novgorod, Russia

I.B. Meyerov

ORCID: **0000-0001-6905-2050** e-mail: **meerov@vmk.unn.ru**
National Research Lobachevsky State University of Nizhny Novgorod
Nizhny Novgorod, Russia

Abstract. The paper proposes a method for improving the accuracy of electron distribution reconstruction using fine-tuning of a machine learning model. The model is fine-tuned using an experimentally validated synthetic dataset: the pre-trained model predicts physical parameters based on experimental data, which are then used as input parameters for numerical simulation. The newly generated samples have a distribution close to the true analogues in the experimental data. The proposed approach yields an average improvement of 8 % in approximation accuracy.

Key words: deep learning; convolutional neural networks; fine-tuning; synthetic data; lasers numerical simulation; laser wakefield acceleration; laser-plasma interaction; magnetic spectrometer.

FOR CITATION: Yu.A. Rodimkov, S.E. Perevalov, V.D. Volokitin, A.V. Kotov, A.A. Soloviev and I.B. Meyerov. Iterative fine-tuning of neural network for processing data from two-screen magnetic spectrometer. Transactions of NNSTU n.a. R.E. Alekseev. 2026. № 2. Pp. 7-16. EDN SUATEQ

Введение

Развитие петаваттных лазерных систем [1] стимулировало значительный прогресс в исследовании лазерно-плазменного ускорения частиц кивальтерным полем [2, 3]. Данный метод

представляет большой научный интерес благодаря своей уникальной компактности и экономичности по сравнению с традиционными способами ускорения частиц [4, 5]. Для валидации результатов эксперимента необходимы надежные и эффективные методы диагностики [6]. Диагностика пучков ускоренных электронов состоит из двух этапов.

На первом этапе необходимо зарегистрировать всю необходимую информацию, которая позволит восстановить характеристики электронов. Для регистрации пучков обычно применяют магнитные спектрометры, принцип работы которых основан на том, что электроны с разными импульсами и энергиями отклоняются в магнитном поле по-разному; медленные – сильнее. Для регистрации всей информации и восстановления как энергетических, так и угловых характеристик необходимо использовать двухэкранные спектрометры [7], либо ограничивать угловой разброс электронов на входе в спектрометр, что приводит к потере информации об угловом распределении.

На втором этапе осуществляется аналитический или численный поиск конфигурации физических параметров, которая будет обеспечивать соответствие модели и экспериментальных данных. В результате необходимо решать некорректную обратную задачу. Однако существующие методы поиска конфигурации и восстановления характеристики электронов имеют ряд ограничений. Например, подходы, основанные на решении системы уравнений [7-9], или использовании численного моделирования [10, 11] для вычисления траектории электронов требуют значительного времени и ручного вмешательства для выделения и сопоставления паттернов на изображениях с обоих экранов спектрометра. С другой стороны, методы, основанные на оптимизации параметров базисных функций [12], работают эффективно только при малом количестве параметров, однако при большом их числе возникает проблема «проклятия размерности» [13].

Методы машинного обучения позволяют автоматизировать процесс решения обратной задачи и восстановления характеристик электронов из экспериментальных данных [14]. Но из-за отсутствия размеченных экспериментальных данных модель необходимо обучать на синтетических данных, включающих широкий спектр возможных комбинаций физических параметров для формирования репрезентативной выборки. Такой подход обеспечивает универсальность обученной модели, но связан с проблемой противоречия между универсальностью аппроксиматора и работой модели в узком диапазоне физических параметров. Сужение области определения обучающей выборки до окрестностей реальных значений параметров позволяет повысить точность аппроксимации за счет упрощения задачи, однако эти параметры неизвестны заранее. Именно поэтому физические параметры для численного моделирования генерируются в широком диапазоне.

В данной работе предлагается метод тонкой настройки нейронной сети, направленный на повышение точности реконструкции распределения ускоренных электронов. Он основан на итеративной процедуре, комбинирующей классическое обучение на синтетических данных и новой экспериментально обоснованной выборке. Экспериментально обоснованные данные генерируются на основе численного моделирования по информации, предсказанной для них с помощью предобученной модели распределения электронов. В результате модель дообучается восстанавливать не все возможные комбинации параметров задачи, а только характерные для конкретного набора экспериментальных данных.

Постановка задачи

Рассматривается физический эксперимент (рис. 1). Электроны с функцией плотности $f(E, \phi, \theta)$, зависящей от энергии E , полярного ϕ и азимутального θ углов, пролетают через два сцинтилляционных экрана I_1 и I_2 . Перед каждым из них установлены дипольные магниты M_1 и M_2 , которые воздействуют на электроны. Пролетая через экран, электроны оставляют световые пятна в соответствующей области. Также задан процесс численного моделирования $H: I_1, I_2 = H(f(E, \phi, \theta))$, который описывает физический эксперимент и сопоставляет функции

распределения электронов с изображением экранов. Необходимо восстановить по изображениям с двух экранов I_1 и I_2 функцию плотности $f(E, \phi, \theta)$, которая будет максимизировать суммарное косинусное сходство $\frac{I_1 \cdot \hat{I}_1}{\|I_1\| \|\hat{I}_1\|} + \frac{I_2 \cdot \hat{I}_2}{\|I_2\| \|\hat{I}_2\|}$ между изображениями с экспериментальных экранов I_1 и I_2 и экранов, полученных в результате численного моделирования в соответствии с восстановленным нейронной сетью распределением $\hat{I}_1, \hat{I}_2 = H(f(E, \phi, \theta))$.




Рис. 1. Схема двухэкранного магнитного спектрометра

Fig. 1. Schematic diagram of a two-screen magnetic spectrometer

Ранее для решения данной задачи использовалась сверточная нейронная сеть [14]. Она была обучена на большом корпусе синтетических данных, полученных с помощью численного моделирования и охватывающих все возможные комбинации параметров. Целью данной работы является повышение точности реконструкции распределения с помощью тонкой настройки модели на основе экспериментально обоснованного синтетического набора данных.

Метод

Предлагаемый метод направлен на повышение точности работы модели машинного обучения на конкретных экспериментальных данных. Для тонкой настройки модели формируется новая выборка синтетических данных, которые приближены по физическим параметрам к экспериментальным данным (рис. 2). Обучение на ней упрощает задачу для модели, так как не требует аппроксимации зависимости для всех возможных комбинаций параметров. Таким образом, акцент делается на точности модели именно на определенном множестве параметров, близких к экспериментальным данным. Изначально создать такую выборку не представляется возможным, так как сложно определить, какие физические параметры соответствуют конкретному экспериментальному примеру.

Для тонкой настройки предложен *Алгоритм 1*. Вначале модель машинного обучения инициализируется предобученными весами, полученными при обучении на исходных синтетических данных. Итеративно выполняются следующие действия. Модель обучается на исходных синтетических данных D_s , чтобы стабилизировать процесс обучения. Затем собираются новые данные D_e на основе предсказаний модели на экспериментальных примерах. Далее модель обучается на новых данных D_e . В конце выбирается модель с наилучшей точностью на тестовых данных.




Рис. 2. Схематичный пример работы алгоритма. Итеративная процедура, в результате которой в обучающую выборку добавляются данные с физическими параметрами, значения которых близки к требуемым для обучения

Fig. 2. Schematic example of the algorithm's operation. An iterative procedure that results in data with physical parameters close to those required for training being added to the training set

Алгоритм 1. Алгоритм тонкой настройки модели с помощью экспериментально обоснованного синтетического набора данных.

Вход: $D_s = (\mathbf{x}, \mathbf{y})$ – набор пар синтетических данных, \mathbf{y}' – экспериментальные данные, $D_e = \emptyset$ – экспериментально обоснованный синтетический набор данных, M_0 – модель машинного обучения, обученная на синтетических данных, $F: \mathbf{y} = F(\mathbf{x})$ – численная модель.

Пока критерий останова не выполнен, **делай:**

Шаг 1. Обучение модели M_i на случайных примерах из D_s с использованием аугментации.

Шаг 2. Предсказание физических параметров \mathbf{x}' с помощью модели $M_i: \mathbf{x}' = M_i(\mathbf{y}')$.

Шаг 3. Численное моделирование: $\mathbf{y}' = F(\mathbf{x}')$.

Шаг 4. Добавление новых данных в выборку: $D_e \leftarrow D_e \cup \{\mathbf{x}', \mathbf{y}'\}$.

Шаг 5. Обучение M_i на случайных примерах из D_e с использованием аугментации.

Шаг 6. $i \leftarrow i + 1$.

Конец

Вернуть $M^* \leftarrow$ лучшая модель из $\{M_0, M_1, \dots, M_{i-1}\}$.

Результаты

В работе использовались предобученные модели и синтетические данные D_s , а также методы аугментации и численного моделирования [14]. Для обучения модели, проводившегося в течение 250 эпох, использовался оптимизатор *Adam* [16] со скоростью обучения 2×10^{-5} , без регуляризации. Использовалось многозадачное обучение [17, 18], аналогичное исходной работе. Таким образом, модель предсказывала не только заданное распределение электронов, но и изображения экранов без шума. Архитектура представлена на рис. 3.

Изображения с первого и второго экранов обрабатываются отдельно с использованием одинаковых блоков нейронных сетей, но с разными весами кодировщиков. Выделенные признаки объединяются. Затем применяется дополнительный кодировщик для агрегации и извлечения новых признаков. Далее данные конвертируются в формат, соответствующий 3D-сверткам, и обрабатываются декодировщиком, который предсказывает распределение. Также используются дополнительные декодеры для восстановления исходных изображений без шума, данные на вход принимаются после каждого кодировщика.

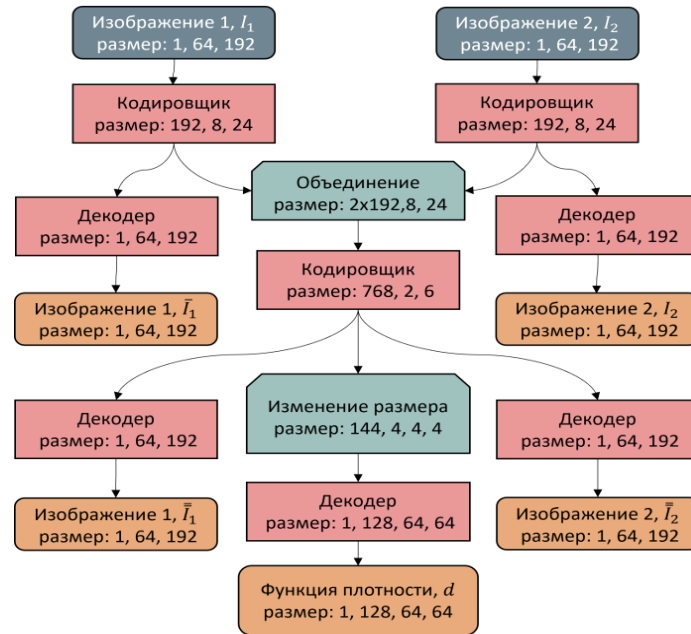


Рис. 3. Архитектура нейронной сети

Fig. 3. Neural network architecture

Общий функционал потерь определялся следующим образом:

$$Loss = Loss_d + 0.33 \times Loss_1 + 0.66 \times Loss_2$$

$$Loss_d = \frac{1}{N} \sum (d_i - f_i(E, \phi, \theta))^2$$

$$Loss_1 = \frac{1}{N} \sum (\bar{I}_{1,i} - I_{1,i}) + \frac{1}{N} \sum (\bar{I}_{2,i} - I_{2,i})$$

$$Loss_2 = \frac{1}{N} \sum (\bar{\bar{I}}_{1,i} - I_{1,i}) + \frac{1}{N} \sum (\bar{\bar{I}}_{2,i} - I_{2,i})$$

где d_i – предсказанная функция плотности, $f_i(E, \phi, \theta)$ – истинная функция плотности, $I_{1,i}$ и $I_{2,i}$ – истинные синтетические изображения экранов, а $\bar{I}_{1,i}, \bar{I}_{2,i}, \bar{\bar{I}}_{1,i}$ и $\bar{\bar{I}}_{2,i}$ – предсказанные изображения экранов.

В данной работе анализируются два набора экспериментальных данных – TSMS-11 [15] и TSMS-18 [11], полученные в ходе исследований лазерно-плазменного ускорения электронов на установке PEARL. Данные были предварительно центрированы и нормализованы. Также изображения экранов содержат специальные метки – прямые линии, кресты и отверстия. Они использовались в качестве вспомогательной информации для калибровки в процессе проведения натурального эксперимента. Предварительно отверстия были удалены вручную, а соответствующие области – заменены средним значением изображения. Кроме того, для каждого изображения было вычтено среднее значение пикселей, а отрицательные значения были установлены в ноль, чтобы минимизировать влияние шума фона. Дополнительно для набора данных TSMS-18 применялась медианная фильтрация. В качестве синтетических данных D_s использовались две выборки по 50 000 примеров для каждого из наборов экспериментальных данных TSMS-11 и TSMS-18. Однако в процессе обучения использовались только 640 случайно выбранных примеров на каждой эпохе. Для выбора оптимальной модели в процессе обучения рассчитывалось суммарное косинусное сходство на экспериментальных данных.

Результаты работы базовой модели и после тонкой настройки представлены в табл. 1. Точность восстановления для каждого экрана значительно увеличилась, а средний прирост точности составил 8 %. Для первого экрана набора данных TSMS-11 точность возросла более чем на 20 %. В рамках данной задачи точное совпадение с экспериментальными данными невозможно из-за наличия шумов.

Таблица 1.
Точность работы исходной модели и модели после тонкой настройки на двух экспериментальных наборах данных

Table 1.
Accuracy of the original model and model after fine-tuning on two experimental datasets

Косинусное сходство	TSMS-11		TSMS-18	
	Первый экран	Второй экран	Первый экран	Второй экран
Сверточная нейронная сеть	0.658	0.894	0.897	0.731
Сверточная нейронная сеть после тонкой настройки	0.804	0.935	0.957	0.809




Рис. 4. Примеры экспериментальных и численных изображений для набора данных TSMS-11: (a) и (g) – экспериментальные изображения, (b) и (d) – изображения, полученные численным моделированием на основе функции плотности, восстановленной с помощью модели после тонкой настройки, (c) и (e) – изображения, полученные численным моделированием на основе функции плотности, восстановленной с помощью модели после тонкой настройки

Fig. 4. Examples of experimental and numerical images for the TSMS-11 dataset: (a) and (g) are experimental images, (b) and (d) are images obtained by numerical simulation based on the density function reconstructed by the model after fine-tuning, (c) and (e) are images obtained by numerical simulation based on the density function reconstructed by the model after fine-tuning

Примеры экспериментальных и предсказанных изображений с помощью двух разных методов для набора данных TSMS-11 представлены на рис. 4. После тонкой настройки сходство между изображениями значительно улучшилось. Например, на рис. 4 (г) наблюдается пучок с двумя центральными компонентами, что соответствует двум красным пятнам на экспериментальном изображении. На рис. 4 (д) для базовой модели второй пучок отсутствует, однако он появляется после тонкой настройки. Тем не менее, даже после дообучения модель некорректно оценивает амплитуду второй компоненты. Аналогичная информация представлена для набора данных TSMS-18 (рис. 5). После тонкой настройки модель значительно лучше оценивает соотношение амплитуд. Однако положение пучка немного теперь немного смещено вверх относительно верного ответа. Некоторые несоответствия между экспериментальными данными и предсказанными изображениями можно объяснить наличием шума и артефактов. В частности, уровень шума в наборе данных TSMS-18 достаточно высок, что влияет на качество предсказаний.




Рис. 5. Примеры экспериментальных и численных изображений для набора данных TSMS-18:
 (а) – экспериментальные изображения, (б) – изображение, полученное численным моделированием на основе функции плотности, восстановленной с помощью модели после тонкой настройки,
 (в) – изображение, полученное численным моделированием на основе функции плотности, восстановленной с помощью модели после тонкой настройки

Fig. 5. Examples of experimental and numerical images for the TSMS-18 dataset:
 (a) experimental images, (b) image obtained by numerical simulation based on the density function reconstructed by the model after fine-tuning, (c) image obtained by numerical simulation based on the density function reconstructed by the model after fine-tuning

Заключение

Предложен метод повышения точности восстановления распределения электронов с использованием тонкой настройки модели машинного обучения. Модель дообучается с помощью экспериментально обоснованного синтетического набора данных. Для этого предобученная модель предсказывает физические параметры на экспериментальных данных. Полученные предсказания затем применяются как входные параметры для численного моделирования. Новые генерируемые примеры имеют распределение, близкое к истинным аналогам в экспериментальных данных. В результате точность восстановления увеличивается в среднем на 8 %.

Необходимо отметить некоторые ограничения, связанные с предложенным методом. Одним из ключевых является точность предобученной модели. Если предсказанные значения физических параметров существенно отличаются от истинных, это может привести к снижению скорости сходимости алгоритма, а в некоторых случаях алгоритм может не сойтись вовсе.

Также наблюдается ухудшение точности метода на данных, не входящих в область интереса. Алгоритм переобучается под определенные данные, что связано с тем, что новые данные в процессе работы алгоритма сконцентрируются в определенной области. Однако это поведение является ожидаемым и не представляет проблему для практического использования, так как ключевой задачей является восстановление физических параметров именно для экспериментальных данных.

Предложенный метод предположительно может быть применен не только для рассмотренной, но и для других аналогичных задач с доступной численной моделью генерации синтетических данных.

Работа выполнена при финансовой поддержке Министерства образования и науки Российской Федерации, проект FSWR-2026-0007.

Авторы выражают благодарность за использование вычислительных ресурсов, предоставленных Университетом Лобачевского.

Библиографический список

1. **Li, Z.** Further development of the short-pulse Petawatt laser: trends, technologies, and bottlenecks / Z. Li, Y. Leng, R. Li // *Laser & Photonics Reviews*. – 2023. – Vol. 17, No. 1. – P. 2100705.
2. **Tajima, T.** Laser electron accelerator / T. Tajima, J. Dawson // *Physical Review Letters*. – 1979. – Vol. 43, No. 4. – P. 267.
3. **Poder, K.** Multi-GeV electron acceleration in wakefields strongly driven by oversized laser spots / K. Poder [et al.] // *Physical Review Letters*. – 2024. – Vol. 132, No. 19. – P. 195001.
4. **Esarey, E.** Physics of laser-driven plasma-based electron accelerators / E. Esarey, C.B. Schroeder, W.P. Leemans // *Reviews of Modern Physics*. – 2009. – Vol. 81, No. 3. – P. 1229-1285.
5. **Kostyukov I.Y.** Plasma-based methods for electron acceleration: current status and prospects / Kostyukov I.Y., Pukhov A.M. // *Physics-Uspekhi*. – 2015. – Vol. 58, No. 1. – P. 81-88.
6. **Soloviev, A.A.** Research in plasma physics and particle acceleration using the PEARL petawatt laser / A.A. Soloviev [et al.] // *Uspekhi Fizicheskikh Nauk*. – 2024. – Vol. 194, No. 3. – P. 313-335.
7. **Blumenfeld, I.** Energy doubling of 42 GeV electrons in a metre-scale plasma wakefield accelerator / I. Blumenfeld, [et al.] // *Nature*. – 2007. – Vol. 445, No. 7129. – P. 741-744.
8. **Pollock, B.B.** Two-screen method for determining electron beam energy and deflection from laser wakefield acceleration / B.B. Pollock [et al.] // Livermore, CA: Lawrence Livermore National Laboratory (LLNL), 2009. – № LLNL-PROC-412609.
9. Cha, H.J. Absolute energy calibration for relativistic electron beams with pointing instability from a laser-plasma accelerator / H.J. Cha [et al.] // *Review of Scientific Instruments*. – 2012. – Vol. 83, No. 6.
10. **Hojbota, C.I.** Accurate single-shot measurement technique for the spectral distribution of GeV electron beams from a laser wakefield accelerator / C.I. Hojbota [et al.] // *AIP Advances*. – 2019. – Vol. 9, No. 8.
11. **Perevalov, S.E.** Experimental study of strongly mismatched regime of laser-driven wakefield acceleration / S.E. Perevalov [et al.] // *Plasma Physics and Controlled Fusion*. – 2020. – Vol. 62, No. 9. – P. 094004.
12. **Soloviev, A.A.** Two-screen single-shot electron spectrometer for laser wakefield accelerated electron beams / A.A. Soloviev [et al.] // *Review of Scientific Instruments*. – 2011. – Vol. 82, No. 4.
13. **Bellman, R.** Dynamic programming / R. Bellman. – Princeton, New Jersey: Princeton University Press, 1957. – 339 p.
14. Rodimkov et al. 2026
15. Soloviev A.A. Fast electron generation using PW-class PEARL facility / A. A. Soloviev [et al.] // *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*. – 2011. – Vol. 653, No. 1. – P. 35-41.
16. **Kingma, D.P.** Adam: A method for stochastic optimization / D.P. Kingma, J. Ba // arXiv preprint arXiv:1412.6980. – 2014.
17. **Caruana, R.** Multitask learning / R. Caruana // *Machine Learning*. – 1997. – Vol. 28, No. 1. – P. 41-75.
18. **Zhang, Y.** A survey on multi-task learning / Y. Zhang, Q. Yang // *IEEE Transactions on Knowledge and Data Engineering*. – 2021. – Vol. 34, No. 12. – P. 5586-5609.

References

1. Li Z., Leng Y., Li R. Further development of the short-pulse Petawatt laser: trends, technologies, and bottlenecks. *Laser & Photonics Reviews*. 2023; 17(1): 2100705.
2. Tajima T, Dawson JM. Laser electron accelerator. *Physical Review Letters*. 1979; 43(4): 267.
3. Poder K., et al. Multi-GeV electron acceleration in wakefields strongly driven by oversized laser spots. *Physical Review Letters*. 2024; 132(19): 195001.
4. Esarey E., Schroeder C.B., Leemans W.P. Physics of laser-driven plasma-based electron accelerators. *Reviews of Modern Physics*. 2009; 81(3): 1229-1285.
5. Kostyukov I.Y., Pukhov A.M. Plasma-based methods for electron acceleration: current status and prospects. *Physics-Uspekhi*. 2015;58(1):81-88.
6. Soloviev A.A., et al. Research in plasma physics and particle acceleration using the PEARL petawatt laser. *Uspekhi Fizicheskikh Nauk*. 2024; 194(3): 313-335.
7. Blumenfeld I., et al. Energy doubling of 42 GeV electrons in a metre-scale plasma wakefield accelerator. *Nature*. 2007; 445(7129): 741-744.
8. Pollock B.B., et al. Two-screen method for determining electron beam energy and deflection from laser wakefield acceleration. Livermore (CA): Lawrence Livermore National Laboratory (LLNL); 2009. Report No.: LLNL-PROC-412609.
9. Cha H.J., et al. Absolute energy calibration for relativistic electron beams with pointing instability from a laser-plasma accelerator. *Review of Scientific Instruments*. 2012; 83(6).
10. Hojbota C.I., et al. Accurate single-shot measurement technique for the spectral distribution of GeV electron beams from a laser wakefield accelerator. *AIP Advances*. 2019; 9(8).
11. Perevalov S.E., et al. Experimental study of strongly mismatched regime of laser-driven wakefield acceleration. *Plasma Physics and Controlled Fusion*. 2020; 62(9):094004.
12. Soloviev A.A., et al. Two-screen single-shot electron spectrometer for laser wakefield accelerated electron beams. *Review of Scientific Instruments*. 2011; 82(4).
13. Bellman R. *Dynamic programming*. Princeton (NJ): Princeton University Press; 1957. 339 p.
14. Rodimkov et al. 2026
15. Soloviev AA, et al. Fast electron generation using PW-class PEARL facility. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*. 2011; 653(1): 35-41.
16. Kingma D.P., Ba J. Adam: a method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. 2014.
17. Caruana R. Multitask learning. *Machine Learning*. 1997; 28(1): 41-75.
18. Zhang Y., Yang Q. A survey on multi-task learning. *IEEE Transactions on Knowledge and Data Engineering*. 2021; 34(12): 5586-5609.

*Дата поступления
в редакцию: 03.03.2026*

*Дата принятия
к публикации: 07.04.2026*