

УДК 004.852

DOI: 10.46960/1816-210X\_2026\_1\_32  
EDN XMHBAP

## ИСПОЛЬЗОВАНИЕ ЦИКЛИЧЕСКОГО БУФЕРА ДЛЯ ПОВЫШЕНИЯ ТОЧНОСТИ ВОССТАНОВЛЕНИЯ ИСКАЖЕНИЙ ВОЛНОВОГО ФРОНТА МЕТОДАМИ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ЗАДАЧ УПРАВЛЕНИЯ ДЕФОРМИРУЕМЫМ ЗЕРКАЛОМ

**Ю.А. Родимков**ORCID: 0000-0003-2962-9366 e-mail: [rodimkov@itmm.unn.ru](mailto:rodimkov@itmm.unn.ru)Нижегородский государственный университет им. Н.И. Лобачевского  
*Нижний Новгород, Россия*

Предлагается новый подход обучения нейронной сети для восстановления искажений волнового фронта, основанный на использовании циклического буфера данных. В отличие от традиционных методов, где обучающая выборка фиксируется заранее, предложенный подход предусматривает динамическое обновление данных в процессе обучения. Это позволяет снизить риск переобучения нейронной сети и повысить устойчивость решения задачи восстановления волнового фронта.

**Ключевые слова:** нейронные сети; глубокое обучение; синтетические данные; переобучение; циклический буфер; параллельные вычисления; лазерная физика; оптические системы; искажения волнового фронта; калибровка лазерной установки.

**ДЛЯ ЦИТИРОВАНИЯ:** Родимков, Ю.А. Использование циклического буфера для повышения точности восстановления искажений волнового фронта методами глубокого обучения для задач управления деформируемым зеркалом // Труды НГТУ им. П.Е. Алексеева. 2026. № 1. С. 32-42. EDN XMHBAP  
DOI: 10.46960/1816-210X\_2026\_1\_32

## USING CIRCULAR BUFFER TO IMPROVE ACCURACY OF WAVEFRONT DISTORTION RECONSTRUCTION USING DEEP LEARNING METHODS FOR DEFORMABLE MIRROR CONTROL PROBLEMS

**Yu.A. Rodimkov**ORCID: 0000-0003-2962-9366 e-mail: [rodimkov@itmm.unn.ru](mailto:rodimkov@itmm.unn.ru)Nizhny Novgorod State University n.a. N.I. Lobachevsky  
*Nizhny Novgorod, Russia*

This paper proposes a new approach to training a neural network for wave front distortion reconstruction, based on the use of a circular buffer. Unlike traditional methods, where the training set is fixed in advance, the proposed approach involves dynamic data updating during the training process. This reduces the risk of overfitting the neural network and increases the reliability of the wave front reconstruction solution.

**Keywords:** neural networks; deep learning; synthetic data; overfitting; circular buffer; parallel computing; laser physics; optical systems; wave front distortions; laser calibration.

**FOR CITATION:** Rodimkov Y.A. Using circular buffer to improve accuracy of wavefront distortion reconstruction using deep learning methods for deformable mirror control problems. Transactions of NNSTU n.a. R.E. Alekseev. 2026. № 1. Pp. 32-42. EDN XMHBAP DOI: 10.46960/1816-210X\_2026\_1\_32

## Введение

Для достижения экстремальных интенсивностей в фокальной плоскости лазерных установок, включая современные петаваттные системы [1, 2], требуется устранение искажений волнового фронта. Подобные искажения возникают вследствие оптических aberrаций и технологических несовершенств таких элементов, как линзы и зеркала. Для устранения искажений волнового фронта необходима калибровка адаптивной оптической системы, обычно состоящей из деформируемого зеркала, системы управления им и датчика волнового фронта. Калибровка выполняется с помощью управления сегментами на деформируемом зеркале с целью устранения всех искажений.

Один из методов выбора оптимального управления заключается в измерении искажений волнового фронта. Это позволяет определить и задать с помощью системы управления необходимую кривизну деформируемого зеркала для коррекции волнового фронта. Классический метод калибровки предполагает использование датчика волнового фронта для измерения искажений. Однако существенным ограничением такого подхода является то, что на плотность потока в фокальной плоскости влияют aberrации необщего пути (non-common path aberrations), которые не учитываются датчиком волнового фронта, поскольку они возникают после его расположения [3-5].

Для устранения этой проблемы необходимо задавать управление на основе анализа потока энергии в фокусе. Для этого устанавливается камера с ПЗС-матрицей (прибор с зарядовой связью) [6] в фокальной плоскости, что позволяет получать изображения с распределением энергии в фокусе.

Существуют различные методы управления деформируемым зеркалом, использующие информацию из фокальной плоскости и напрямую управляющие зеркалом, основанные на жадном поиске [7, 8], генетических алгоритмах [8-10], стохастическом градиентном спуске [11-13], а также алгоритме моделирования отжига [14, 15]. К недостаткам этих методов относятся относительно большое время работы и риск застревания в локальных минимумах. Поэтому в последние годы набирает популярность применение методов глубокого обучения [16-20] для восстановления искажений волнового фронта и выбора оптимального управления. Особенностью таких подходов является возможность предварительно обучить нейронную сеть на большом массиве данных, что позволяет быстро и достаточно точно восстанавливать искажения волнового фронта по изображениям, полученным в фокальной плоскости.

В данной работе предлагается метод повышения точности калибровки оптической системы за счет использования циклического буфера с обновлением синтетических данных в процессе обучения нейронной сети для восстановления искажений волнового фронта по плотности потока в фокусе. В силу отсутствия размеченных экспериментальных данных для обучения моделей глубокого обучения используются синтетические данные, получаемые с помощью численного моделирования. Целью данной работы является не представление наилучшего метода восстановления искажений волнового фронта, а демонстрация подхода, позволяющего повысить точность за счет использования вычислительных узлов без необходимости дополнительной памяти и ресурсов на хранение и обработку данных.

## Постановка задачи

Процедура калибровки адаптивной оптической системы схематично представлена на рис. 1. Пусть  $N_r, N_\phi$  – количество точек дискретизации по радиусу и углу соответственно. Волновой фронт с искажениями  $p_1 \in R^{N_r \times N_\phi}$  поступает на деформируемое зеркало, после чего сигнал направляется на полупрозрачное зеркало. Одна часть сигнала направляется для фокусировки, а другая поступает на датчик волнового фронта, обычно состоящий из оптических элементов. Датчик волнового фронта способен достаточно быстро и точно измерять искажения волнового фронта. Однако у описанного подхода есть несколько существенных не-

достатков, связанных с абберациями необщего пути. В частности, не учитываются искажения  $p_3 \in R^{N_r \times N_\phi}$ , возникающие в фокусирующем тракте. И наоборот, учитываются искажения  $p_2 \in R^{N_r \times N_\phi}$ , возникающие в тракте датчика волнового фронта, которые не влияют на область в фокусе.

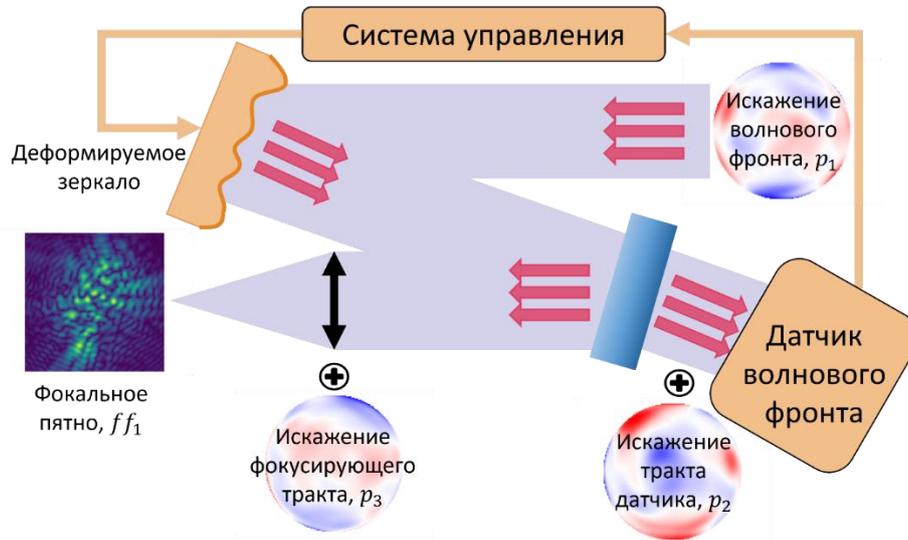


Рис. 1. Схема работы адаптивной оптической системы

Fig. 1. The operating diagram of the adaptive optical system

Для восстановления искажений волнового фронта нейронную сеть можно обучить решать обратную задачу. Прямым процессом является получение изображений в фокальной плоскости  $ff_1 \in R^{b \times c}$  и его окрестности  $ff_2 \in R^{b \times c}$  по искажениям волнового фронта  $p \in R^{N_r \times N_\phi}$ . Здесь  $b, c$  – размеры изображения в фокальной плоскости и его окрестности соответственно. Для этого в данной работе используется численное моделирование, с помощью которого формируется синтетический набор данных. Обратная задача формулируется как восстановление искажений  $p$  с помощью нейронной сети  $NN: NN(ff_1, ff_2) \rightarrow p$ . Распределение энергии в окрестности фокуса используется для устранения неопределенности [21]. В противном случае одной и той же информации в фокальной плоскости могут соответствовать различные искажения волнового фронта.

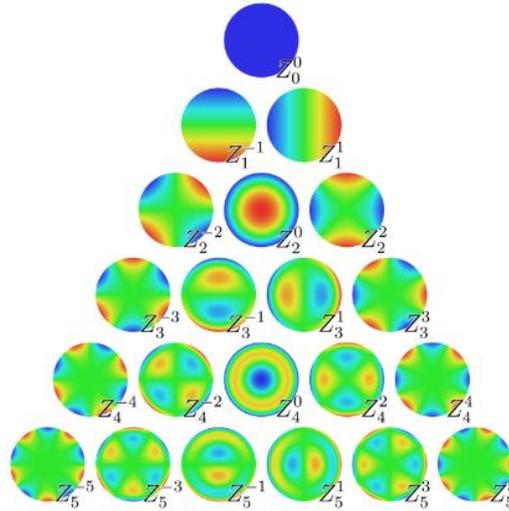
### Математическая модель для сбора синтетических данных

Одним из способов параметризации искажений волнового фронта являются полиномы Цернике [22], которые широко применяются в задачах оптики [23, 24]. Среди их главных преимуществ можно выделить их ортогональность на единичном круге, а также ограниченность значений в диапазоне от  $-1$  до  $1$ . В рамках данной задачи лазерный импульс с искаженным волновым фронтом формировался как сумма ста полиномов Цернике со случайными коэффициентами  $a_i$ . После формирования лазерного импульса с помощью преобразования Фурье рассчитывалось распределение энергии в фокусе и в его окрестности.

Четные и нечетные полиномы задавались следующим образом:  $Z_n^m(p, \varphi) = R_n^m(p) \cos(m\varphi)$  и  $Z_n^{-m}(p, \varphi) = R_n^m(p) \sin(m\varphi)$ , где  $m$  и  $n$  – неотрицательные целые числа, удовлетворяющие условию что  $n \geq m$ ,  $\varphi$  – азимутальный угол,  $p$  – радиальное расстояние,  $0 \leq p \leq 1$ . Радиальные многочлены  $R_n^m$  определяются следующим образом:

$$R_n^m(p) = \sum_{k=0}^{\frac{n-m}{2}} \frac{(-1)^k (n-k)!}{k! \left(\frac{n+m}{2} - k\right)! \left(\frac{n-m}{2} - k\right)!} p^{n-2k}$$

для четных значений  $n - m$ , и равны нулю для нечетных  $n - m$ . Графики значений полиномов Цернике в единичном круге представлены на рис. 2.



**Рис. 2. Пример искажений волнового фронта в единичном круге для разных полиномов Цернике**

**Fig. 2. An example of wavefront distortions in a unit disk for different Zernike polynomials**

Искажения лазерного импульса задавались следующим образом:

$$W(r, \varphi) = \sum_{n=0}^N \sum_{m=-n}^n a_{nm} Z_n^m(r, \varphi)$$

Учитываются первые 100 полиномов.  $a_{nm}$  – коэффициенты, определяющие величину искажения для каждого полинома,  $N$  – максимальный порядок полиномов. Коэффициенты для полиномов  $Z_0^0$ ,  $Z_1^{-1}$  и  $Z_1^1$  были равны нулю. Для расчета распределения энергии в окрестности фокуса к коэффициенту  $Z_0^0$  прибавлялось значение 0.5.

Электрическое поле рассчитывалось следующим образом:

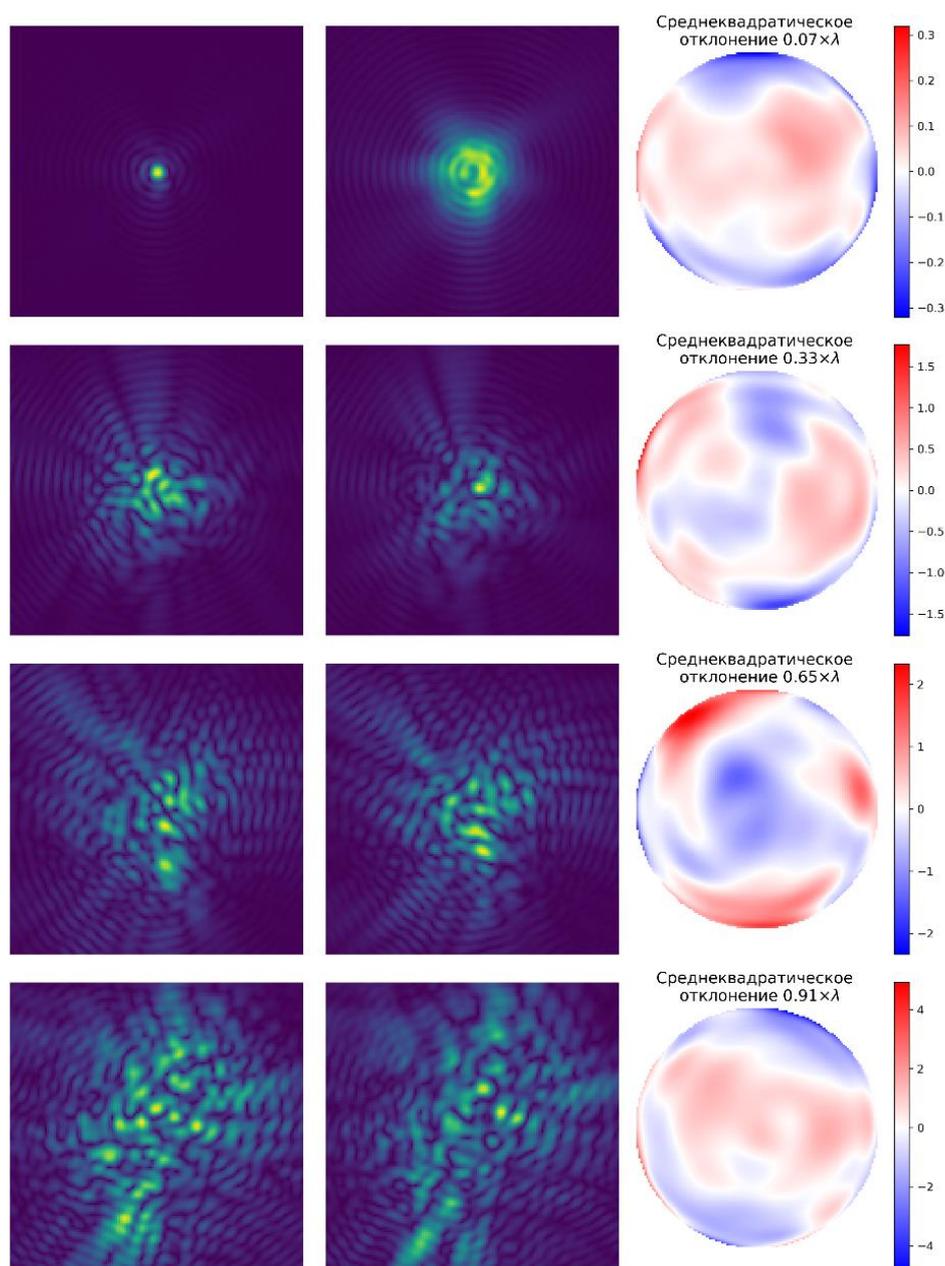
$$E(p, \varphi) = e^{\frac{2\pi i W(p, \varphi)}{\lambda}}$$

где  $\lambda$  – длина волны, равная  $10^{-6}$ . Далее с помощью преобразования Фурье электрическое поле распространялось в дальнюю зону,  $F(u, v) = \mathcal{F}(E(r, \varphi))$ . Далее рассчитывалась интенсивность:  $I(u, v) = |F(u, v)|^2$ . Здесь  $u$  и  $v$  – пространственные частоты по двум осям, или координаты в дальней зоне.

Примеры синтетических данных представлены на рис 3. С увеличением силы искажения распределение энергии в фокусе становится все более хаотичным, среднеквадратичное отклонение волнового фронта соответственно увеличивается. Для обучения изображения распределений энергии в фокусе и вне фокуса нормировались на максимум отдельно для каждого изображения, так как в экспериментальных данных отсутствует информация об амплитуде сигнала. Искажения волнового фронта нормировались на тройную длину волны.

### Методология

Одной из ключевых проблем методов глубокого обучения является переобучение. Самым простым решением является увеличение размера выборки. Однако это приводит к ряду других сложностей. Во-первых, вычислительная мощность устройств обычно значительно превосходит возможности устройств хранения данных. Если объем данных превышает объем оперативной памяти, и данные хранятся на жестком диске, скорость загрузки может значительно снизиться. В результате возникает необходимость загружать данные по одному объекту при каждом обращении к конкретному элементу выборки.



**Рис. 3. Примеры синтетических данных**

*Столбцы (слева направо): распределение энергии в фокусе; в окрестностях фокуса; соответствующее искажение волнового фронта*

**Fig. 3. Examples of synthetic data**

*Columns (left to right): energy distribution at the focus; in the vicinity of the focus; corresponding wavefront distortion*

Кроме того, при обучении используется случайный порядок обращения к данным, что делает процесс загрузки непоследовательным и нерегулярным, снижает эффективность использования вычислительных ускорителей. Во-вторых, неудовлетворительные результаты, полученные на выборке малого размера, требуют увеличения объема набора данных. Заранее неясно, какой объем данных необходим для достижения надежных результатов. Воспроизводимость экспериментов и сравнение различных подходов может предполагать обучение модели с нуля при увеличении выборки. В результате необходимо заново проводить обучение модели. В-третьих, при фиксированной выборке могут возникать «перекосы» в распределении данных. Если выборка генерируется один раз, она может закрепить случайные артефак-

ты, что приводит к искажениям в обучении модели. В-четвертых, обновление генератора данных становится сложной задачей. При улучшении генератора требуется заново создавать большие объемы данных, иначе выборка устаревает. Некоторые из этих проблем можно преодолеть, но для этого потребуются значительные изменения в способах обработки и хранения данных, обучение модели, а также последующее профилирование и тестирование.

В данной работе сравниваются два метода обучения. Первый из них – это обучение на выборке фиксированного размера. Второй – обучение с использованием циклического буфера. Он часто применяется в задачах обучения с подкреплением при использовании онлайн-подхода [25]. В таких задачах он используется как буфер опыта (experience buffer) или буфер повторений (replay buffer), куда сохраняются результаты предыдущих взаимодействий агента с окружающей средой. Схожая идея применяется и в данной работе.

### Описание метода использования циклического буфера

Процесс обучения и обновление синтетических данных в циклическом буфере происходят асинхронно. Обучение представляет собой классическую процедуру, выполняемую на процессе-мастере. В пакетном режиме обучающие примеры случайным образом, без повторов, выбираются из набора данных. Эта часть выполняется в критической секции. Далее происходит прямой проход по нейронной сети, а затем обратный проход для обновления весов. Буфер в начальный момент хранит заранее собранную выборку. Ее размер может быть равен размеру буфера. Такой подход направлен на борьбу с эффектом холодного старта, при котором модель может переобучаться на небольшой выборке, что замедляет сходимость. После начала обучения запускается множество дополнительных процессов для обновления набора синтетических данных. В каждом из них производится генерация случайных коэффициентов полиномов Цернике, рассчитывается электрическое поле, а затем выполняется численное моделирование. В данной работе для выполнения этих задач использовалось десять процессов.

Для уменьшения накладных расходов, связанных с синхронизацией, в каждом процессе сначала собирается 100 синтетических примеров. Как только пачка данных будет сгенерирована, процессы встают в очередь с процессом-мастера. Далее, в порядке очереди, данные добавляются в массивы с данными. Часть с добавлением данных также находится в критической секции. В среднем, за одну эпоху генерировалось около 25 000 объектов.

Эксперименты проводились на суперкомпьютере «Лобачевский». В качестве вычислительного оборудования использовались процессоры AMD EPYC 7742 64-Core, при запуске выделялось 16 ядер графические процессоры A100 40 Гб. Обучение нейронной сети проводилось с использованием фреймворка PyTorch. Создание процессов осуществлялось с помощью библиотеки multiprocessing. Хранение данных осуществлялось в разделяемой памяти, доступной всем процессам.

### Описание архитектуры и гиперпараметров

Для решения поставленной задачи использовалась архитектура U-Net [26]. В качестве входных данных использовались двухканальные изображения, где первый канал представлял собой изображение в фокусе  $f f_1$ , а второй – изображение в окрестности фокуса  $f f_2$ . Модель обучалась для восстановления изображения искажений волнового фронта. Разрешение всех изображений, как входных, так и выходных, составляло  $128 \times 128$  пикселей. На последнем слое нейронной сети применялась круглая маска, в которой значения вне круга были равны нулю, а внутри и на границе – единице. Для обучения использовалась средняя квадратичная ошибка. В качестве оптимизатора применялся Adam с скоростью обучения 0.0005. Размер пакета (batchsize) составлял 500.

Для сравнительного анализа использовались три выборки, размеры которых составляли 100 000, 200 000 и 400 000 примеров. Обучение проводилось с использованием буфера,

размер которого был равен 100 000 примеров. В качестве исходной выборки для инициализации использовалась выборка размером 100 000 примеров. Каждая конфигурация обучалась в течение 40 000 итераций для обеспечения единообразия. Для валидации и тестирования использовались отдельные выборки, содержащие 5 000 и 2 000 примеров соответственно.

### Результаты

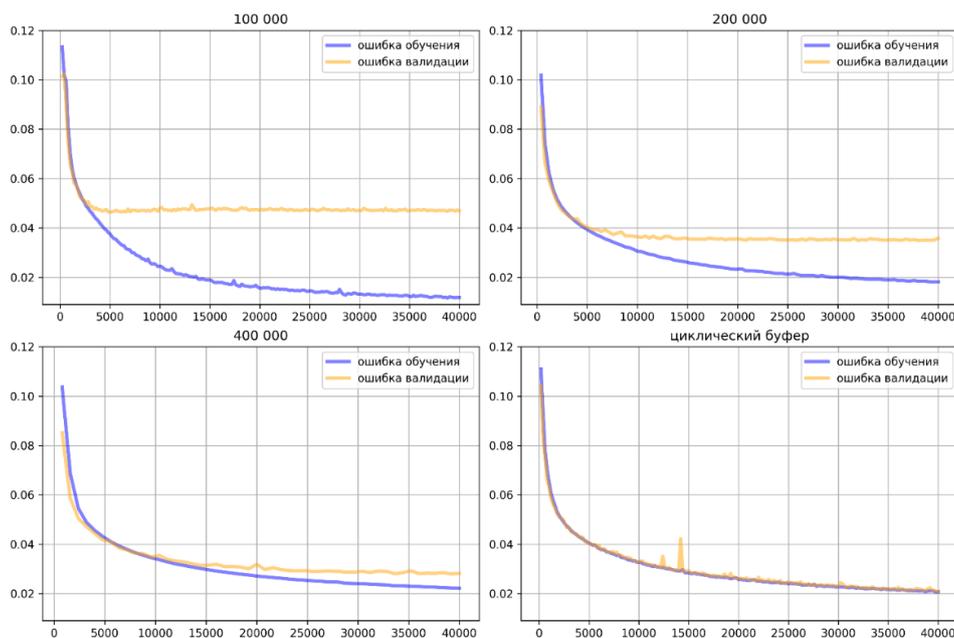
Было проведено сравнение точности нейронных сетей, обученных на различных выборках. Результаты этого сравнения приведены в табл. 1. На тренировочных данных наилучшая точность достигается при использовании наименьшей по размеру выборки. Это связано с тем, что при уменьшении размера выборки модель в большей степени подвержена переобучению. На тестовых данных наилучшая точность демонстрирует нейронная сеть, обученная с использованием циклического буфера. Среди выборок фиксированного размера наилучший результат, как и ожидалось, был достигнут при использовании самой большой выборки, включающей 400 000 примеров. Важно отметить, что точность на тренировочных данных совпадает как для выборки размером 400 000, так и для метода с циклическим буфером. Но на тестовых данных разница между этими двумя подходами значительна. Дальнейшее увеличение размера фиксированной выборки может способствовать повышению точности. Однако это сопряжено с рядом технических сложностей, включая проблемы хранения и обработки данных. Так, для выборки, состоящей из 400 000 примеров, требуется уже около 80 ГБ памяти в одинарной точности.

*Таблица 1.*  
Средняя абсолютная ошибка восстановления искажений волнового фронта с помощью моделей нейронной сети, обученных на разных наборах данных

*Table 1.*  
Mean absolute error of wavefront distortion reconstruction using neural network models trained on different datasets

	Обучение на наборе данных из 100 тысяч примеров	Обучение на наборе данных из 200 тысяч примеров	Обучение на наборе данных из 400 тысяч примеров	Обучение с использованием циклического буфера
Ошибка на тренировочных данных	0.012	0.018	0.022	0.021
Ошибка на тестовых данных	0.046	0.035	0.028	0.021

На рис. 4 представлены графики зависимости ошибки от числа итераций обучения для различных выборок. Для выборок размером 100 000 и 200 000 примеров ошибка модели достаточно быстро выходит на плато. Для выборки размером 400 000 примеров, начиная с середины процесса обучения, наблюдается небольшая разница между ошибками на тренировочных и валидационных данных. Однако модель продолжает обучаться и обобщать. Ошибка на тренировочных и валидационных данных совпадает на всем протяжении обучения для нейронной сети, обученной с помощью циклического буфера. Это связано с постоянным обновлением, что предотвращает переобучение и является хорошим результатом.



**Рис. 4. Графики средней абсолютной ошибки обучения нейронной сети для различных выборок**  
**Fig. 4. Graphs of the mean absolute error of neural network training for different samples**

### Заключение

Предложен метод обновления синтетических данных в процессе обучения с использованием циклического буфера. Целью данного подхода является предотвращение переобучения в задаче восстановления искажений волнового фронта и повышение точности калибровки адаптивной оптической системы. Такой подход более эффективен по сравнению с классическим вариантом, при котором выборка синтетических данных формируется один раз. По сравнению с выборкой аналогичного размера точность модели возросла в два раза. Кроме того, точность метода улучшилась примерно на 30 % по сравнению с выборкой, размер которой в четыре раза превышал размер циклического буфера.

Метод упрощает борьбу с переобучением при работе с синтетическими данными, особенно в случаях, когда возможно быстро генерировать новые синтетические примеры. Он может представлять интерес в условиях, когда ограничены ресурсы хранения данных, необходимо использовать выборки большого размера или разные выборки для различных конфигураций эксперимента. Предложенный подход демонстрирует значительное улучшение качества обучения за счет динамического обновления данных.

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

*Автор выражает благодарность за использование вычислительных ресурсов, предоставленных ННГУ им. Н.И. Лобачевского.*

### Библиографический список

1. **Danson, C.N.** Petawatt and exawatt class lasers worldwide / C.N. Danson [et al]. // High Power Laser Science and Engineering. – 2019. – Т. 7. – С. 54.
2. **Соловьев, А.А.** Исследования в области физики плазмы и ускорения частиц на петаваттном лазере PEARL / А.А. Соловьев [и др.] // Успехи физических наук. – 2024. – Т. 194. – № 3. – С. 313-335.

3. **Sauvage, J.F.** Calibration and precompensation of noncommon path aberrations for extreme adaptive optics / J.F. Sauvage [et al]. // *Journal of the Optical Society of America A*. – 2007. – Т. 24. – № 8. – С. 2334-2346.
4. **Zhang, Q.** Adaptive optics for optical microscopy / Q. Zhang [et al] // *Biomedical Optics Express*. – 2023. – Т. 14. – №. 4. – С. 1732-1756.
5. **Radhakrishnan, V.M.** Estimating non-common path aberrations with an adaptive coronagraph / V.M. Radhakrishnan [et al] // *Astronomy & Astrophysics*. – 2023. – Т. 670. – С. A137.
6. **Соловьев, А.А.** Адаптивная система коррекции волнового фронта лазерного комплекса PEARL / А.А. Соловьев [и др.] // *Квантовая электроника*. – 2020. – Т. 50. – № 12. – С. 1115-1122.
7. **Yang, P.** 19-element sensorless adaptive optical system based on modified hill-climbing and genetic algorithms / P. Yang [et al]. // *3rd International Symposium on Advanced Optical Manufacturing and Testing Technologies: Optical Test and Measurement Technology and Equipment*. – SPIE, 2007. – Т. 6723. – С. 36-42.
8. **Sheldakova, J.V.** Genetic and hill-climbing algorithms for laser beam correction / J.V. Sheldakova, A.L. Rukosuev, A.V. Kudryashov // *Laser Resonators and Beam Control VII*. – SPIE, 2004. – Т. 5333. – С. 106-111.
9. **Poland, S.P.** Evaluation of fitness parameters used in an iterative approach to aberration correction in optical sectioning microscopy / S.P. Poland, A. J. Wright, J.M. Girkin // *Applied optics*. – 2008. – Т. 47. – №. 6. – С. 731-736.
10. **Planchon, T.A.** Adaptive correction of a tightly focused, high-intensity laser beam by use of a third-harmonic signal generated at an interface / T.A. Planchon [et al]. // *Optics letters*. – 2006. – Т. 31. – № 14. – С. 2214-2216.
11. **Ma, H.** Full-field unsymmetrical beam shaping for decreasing and homogenizing the thermal deformation of optical element in a beam control system / H. Ma [et al]. // *Optics Express*. – 2011. – Т. 19. – №. S5. – С. A1037-A1050.
12. **Piatrou, P.** Beaconless stochastic parallel gradient descent laser beam control: numerical experiments / P. Piatrou, M. Roggemann // *Applied optics*. – 2007. – Т. 46. – №. 27. – С. 6831-6842.
13. **Котов, А.В.** Адаптивная система коррекции оптических aberrаций излучения мощных лазеров с динамическим определением эталонной формы волнового фронта / А.В. Котов [и др.] // *Квантовая электроника*. – 2021. – Т. 51. – №. 7. – С. 593-596.
14. **Zommer, S.** Simulated annealing in ocular adaptive optics / S. Zommer [et al] // *Optics letters*. – 2006. – Т. 31. – №. 7. – С. 939-941.
15. **El-Agmy, R.** Adaptive beam profile control using a simulated annealing algorithm / R. El-Agmy [et al] // *Optics Express*. – 2005. – Т. 13. – №. 16. – С. 6085-6091.
16. **Котов, А.В.** Восстановление волнового фронта лазерного пучка на основе анализа распределения интенсивности в фокусе и вне фокуса с использованием сверточной нейронной сети / А.В. Котов, [и др.] // *Известия вузов. Радиофизика*. – 2024. – Т. 67. – №. 11-12. – С. 1013-1019.
17. **He, Y.** Deep learning wavefront sensing method for Shack-Hartmann sensors with sparse sub-apertures / Y. He [et al]. // *Optics Express*. – 2021. – Т. 29. – №. 11. – С. 17669-17682.
18. **Ju, G.** Feature-based phase retrieval wavefront sensing approach using machine learning / G. Ju [et al] // *Optics express*. – 2018. – Т. 26. – №. 24. – С. 31767-31783.
19. **Guo, Y.** Adaptive optics based on machine learning: a review / Y. Guo [et al] // *Opto-Electronic Advances*. – 2022. – Т. 5. – №. 7. – С. 200082-1-200082-20.
20. **Guo, H.** Improved machine learning approach for wavefront sensing / H. Guo [et al] // *Sensors*. – 2019. – Т. 19. – №. 16. – С. 3533.
21. **Gonsalves, R.A.** Phase retrieval and diversity in adaptive optics / R.A. Gonsalves // *Optical Engineering*. – 1982. – Т. 21. – №. 5. – С. 829-832.
22. **Zernike, F.** Diffraction theory of the knife-edge test and its improved form, the phase-contrast method / F. Zernike // *Monthly Notices of the Royal Astronomical Society*, Vol. 94, p. 377-384. – 1934. – Т. 94. – С. 377-384.
23. **Wyant, J.C.** Basic wavefront aberration theory for optical metrology / J.C. Wyant, K. Creath // *Applied optics and optical engineering*. – 1992. – Т. 11. – №. part 2. – С. 28-39.
24. **Liu, Y.** Hill-climbing algorithm based on Zernike modes for wavefront sensorless adaptive optics / Y. Liu, [et al] // *Optical Engineering*. – 2013. – Т. 52. – №. 1. – С. 016601-016601.
25. **Lapan, M.** Deep reinforcement learning hands-on. – Birmingham: Packt Publishing, 2018. – Т. 6.

26. **Ronneberger, O.** U-net: Convolutional networks for biomedical image segmentation / O. Ronneberger, P. Fischer, T. Brox // International Conference on Medical image computing and computer-assisted intervention. – Cham: Springer international publishing, 2015. – С. 234-241.

### References

1. Danson C.N., et al. Petawatt and exawatt class lasers worldwide. *High Power Laser Sci Eng.* 2019; 7: e54.
2. Solov'ev A.A., et al. Issledovaniya v oblasti fiziki plazmy i uskoreniya chastits na petavattnom lazere PEARL [Research in the field of plasma physics and particle acceleration at the PEARL petawatt laser]. *Uspekhi fizicheskikh nauk [Physics-Uspekhi]*. 2024;194(3):313-335 (in Russian)/
3. Sauvage J.F., et al. Calibration and precompensation of noncommon path aberrations for extreme adaptive optics. *J Opt Soc Am A Opt Image Sci Vis.* 2007;24(8):2334-2346.
4. Zhang Q., et al. Adaptive optics for optical microscopy. *Biomed Opt Express.* 2023;14(4):1732-1756.
5. Radhakrishnan V.M., et al. Estimating non-common path aberrations with an adaptive coronagraph. *Astron Astrophys.* 2023;670:A137.
6. Solov'ev A.A., et al. Adaptivnaya sistema korrektsii volnovogo fronta lazernogo kompleksa PEARL [Adaptive wavefront correction system of the PEARL laser facility]. *Kvantovaya elektronika [Quantum Electronics]*. 2020;50(12):1115-1122 (in Russian).
7. Yang P., et al. 19-element sensorless adaptive optical system based on modified hill-climbing and genetic algorithms. In: 3rd International Symposium on Advanced Optical Manufacturing and Testing Technologies: Optical Test and Measurement Technology and Equipment. Vol. 6723. Bellingham: SPIE; 2007. p. 36-42.
8. Sheldakova J.V., Rukosuev A.L., Kudryashov AV. Genetic and hill-climbing algorithms for laser beam correction. In: *Laser Resonators and Beam Control VII*. Vol. 5333. Bellingham: SPIE; 2004. p. 106-11.
9. Poland SP, Wright AJ, Girkin JM. Evaluation of fitness parameters used in an iterative approach to aberration correction in optical sectioning microscopy. *Appl Opt.* 2008;47(6):731-736.
10. Planchon TA, et al. Adaptive correction of a tightly focused, high-intensity laser beam by use of a third-harmonic signal generated at an interface. *Opt Lett.* 2006;31(14):2214-2216.
11. Ma H., et al. Full-field unsymmetrical beam shaping for decreasing and homogenizing the thermal deformation of optical element in a beam control system. *Opt Express.* 2011;19(S5): A1037-A1050.
12. Piatrou P., Roggemann M. Beaconless stochastic parallel gradient descent laser beam control: numerical experiments. *Appl Opt.* 2007;46(27):6831-6842.
13. Kotov A.V., et al. Adaptivnaya sistema korrektsii opticheskikh aberratsii izlucheniya moshchnykh lazerov s dinamicheskim opredeleniem etalonnnoy formy volnovogo fronta [Adaptive system for correcting optical aberrations of high-power laser radiation with dynamic determination of the reference wavefront shape]. *Kvantovaya elektronika [Quantum Electronics]*. 2021;51(7):593-596 (in Russian).
14. Zommer S., et al. Simulated annealing in ocular adaptive optics. *Opt Lett.* 2006;31(7):939-41.
15. El-Agmy R., et al. Adaptive beam profile control using a simulated annealing algorithm. *Opt Express.* 2005;13(16):6085-6091.
16. Kotov A.V., et al. Vostanovlenie volnovogo fronta lazernogo puchka na osnove analiza raspredeleniya intensivnosti v fokuse i vne fokusa s ispol'zovaniem svertochnoi neironnoi seti [Laser beam wavefront reconstruction based on in-focus and out-of-focus intensity distribution analysis using a convolutional neural network]. *Izvestiya vuzov. Radiofizika [Radiophysics and Quantum Electronics]*. 2024;67(11-12):1013-1019 (in Russian).
17. He Y., et al. Deep learning wavefront sensing method for Shack-Hartmann sensors with sparse sub-apertures. *Opt Express.* 2021;29(11): 17669-17682.
18. Ju G., et al. Feature-based phase retrieval wavefront sensing approach using machine learning. *Opt Express.* 2018;26(24):31767-31783.
19. Guo Y., et al. Adaptive optics based on machine learning: a review. *Opto-Electron Adv.* 2022;5(7):200082.
20. Guo H., et al. Improved machine learning approach for wavefront sensing. *Sensors.* 2019;19(16):3533.
21. Gonsalves R.A. Phase retrieval and diversity in adaptive optics. *Opt Eng.* 1982;21(5):829-32.
22. Zernike F. Diffraction theory of the knife-edge test and its improved form, the phase-contrast method. *Mon Not R Astron Soc.* 1934; 94: 377-384.

23. Wyant J.C., Creath K. Basic wavefront aberration theory for optical metrology. In: Applied optics and optical engineering. Vol. 11. 1992. p. 28-39.
24. Liu Y., et al. Hill-climbing algorithm based on Zernike modes for wavefront sensorless adaptive optics. Opt Eng. 2013;52(1):016601.
25. Lapan M. Deep Reinforcement Learning Hands-On. Birmingham: Packt Publishing; 2018.
26. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation. In: International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer International Publishing; 2015. p. 234-41.

*Дата поступления  
в редакцию: 14.11.2025*

*Дата принятия  
к публикации: 31.01.2026*