

doi: 10.17586/2226-1494-2026-26-1-35-41

УДК 535.317, 004.942, 004.89, 535.012

Сравнительный анализ современных подходов к автоматизации проектирования оптических систем

Александр Николаевич Чертов¹✉, Демид Денисович Хохлов²

^{1,2} Научно-технологический центр уникального приборостроения РАН, Москва, 117342, Российская Федерация

¹ chertov.an@ntcup.ru✉, <https://orcid.org/0000-0002-2015-0458>

² khokhlov.dd@ntcup.ru, <https://orcid.org/0000-0003-0919-7762>

Аннотация

Введение. Автоматизация проектирования оптических систем является одним из ключевых направлений современной оптической инженерии. Сочетание физически обоснованных симуляторов, методов численной оптимизации и алгоритмов машинного обучения позволяет создавать компактные, энергоэффективные и технологичные оптические системы. Однако многомерность пространства параметров, высокие вычислительные затраты и отсутствие унифицированных критериев верификации требуют анализа применимости различных методов. **Метод.** Представлена систематизация существующих подходов к автоматизации проектирования оптических систем, анализ их ключевых характеристик и оценка перспектив дальнейшего развития. Рассмотрены пять ключевых классов методов: дифференцируемые физические модели, алгоритмы глубокого обучения, эволюционные и метаэвристические оптимизаторы, гибридные схемы, сочетающие методы машинного обучения и физическое моделирование, а также методы обучения в полностью прямом (оптическом) режиме. Рассмотрены вопросы создания унифицированной базы сравнения, позволяющей объективно оценивать скорость, точность, достоверность, робастность, обобщаемость, вычислительную сложность и энергетическую эффективность различных алгоритмов. Предложена классификация методов автоматизированного проектирования оптических систем. Выполнен анализ физических моделей, архитектур нейронных сетей и алгоритмов оптимизации. Приведены сравнительный анализ характеристик по унифицированному набору метрик; качественная и количественная оценки параметров на основе данных известных научных работ за 2019–2025 гг. **Основные результаты.** Показано, что дифференцируемые физические методы обеспечивают наивысшую физическую достоверность и точность. Методы глубокого обучения позволяют достичь максимальной скорости генерации решений. Эволюционные алгоритмы обеспечивают устойчивость к локальным минимумам. Гибридные подходы создают оптимальный баланс между скоростью и физической корректностью. Методы обучения в полностью прямом режиме и оптические нейронные сети позволяют достичь высокой энергоэффективности и потенциально пригодны для аппаратного ускорения процесса проектирования. **Обсуждение.** Результаты исследования могут служить основой выбора стратегии проектирования оптических систем в задачах различной сложности — от предварительного поиска конфигураций до высокоточной оптимизации. Прогресс методов автоматизации проектирования оптических систем связан с дальнейшей стандартизацией наборов данных, интеграцией гибридных подходов и развитием оптических нейронных сетей.

Ключевые слова

автоматизация проектирования, оптические системы, дифференцируемая трассировка, машинное обучение, глубокие нейронные сети, эволюционные методы, оптические нейронные сети, энергоэффективность

Благодарности

Работа выполнена при поддержке Министерства науки и высшего образования Российской Федерации в рамках исследовательской тематики молодежной лаборатории «Оптические зондовые приборы и методы технической и биомедицинской диагностики» (FFNS-2024-0002).

Ссылка для цитирования: Чертов А.Н., Хохлов Д.Д. Сравнительный анализ современных подходов к автоматизации проектирования оптических систем // Научно-технический вестник информационных технологий, механики и оптики. 2026. Т. 26, № 1. С. 35–41. doi: 10.17586/2226-1494-2026-26-1-35-41

Comparative analysis of modern approaches to optical system design automation

Aleksandr N. Chertov¹, Demid D. Khokhlov²

^{1,2} Scientific and Technological Centre of Unique Instrumentation of the Russian Academy of Sciences, Moscow, 117342, Russian Federation

¹ chertov.an@ntcup.ru, <https://orcid.org/0000-0002-2015-0458>

² khokhlov.dd@ntcup.ru, <https://orcid.org/0000-0003-0919-7762>

Abstract

Automation of optical system design is one of the key directions in modern optical engineering. The combination of physically grounded simulators, numerical optimization techniques, and machine-learning algorithms enables the development of compact, energy-efficient, and manufacturable optical systems. However, the high dimensionality of parameter spaces, significant computational costs, and the lack of unified verification criteria necessitate a systematic analysis of the applicability of different methods. The article presents a systematization of current approaches to optical system design automation, an analysis of their key characteristics, and an assessment of prospects for further development. Five main classes of methods are examined: differentiable physical models, deep-learning algorithms, evolutionary and metaheuristic optimizers, hybrid schemes combining machine learning methods and physics-based modeling, and fully forward (optical) training approaches. Consideration is given to the formation of a unified comparison framework that enables objective evaluation of speed, accuracy, reliability, robustness, generalization capability, computational complexity, and energy efficiency across different algorithms. A classification of automated optical design methods is proposed. The analysis includes physical models, neural-network architectures, and optimization algorithms. A comparative evaluation based on a unified set of metrics is provided, including qualitative and quantitative assessments derived from peer-reviewed publications from 2019 to 2025. The study demonstrates that differentiable physical methods provide the highest level of physical fidelity and accuracy. Deep-learning methods ensure maximal speed of solution generation. Evolutionary algorithms exhibit robustness against local minima. Hybrid approaches offer an effective balance between speed and physical correctness. Fully forward training methods (FFM approaches) and optical neural networks deliver high energy efficiency and show potential for hardware acceleration of the design process. The results can serve as a basis for selecting design strategies for optical systems across tasks of varying complexity — from preliminary configuration search to high-precision optimization. Progress in automated optical system design is linked to further standardization of datasets, integration of hybrid approaches, and the advancement of optical neural networks.

Keywords

design automation, optical systems, differentiable tracing, machine learning, deep neural networks, evolutionary methods, optical neural networks, energy efficiency

Acknowledgements

This study is supported by Ministry of Science and Higher Education of the Russian Federation (project FFNS-2024-0002).

For citation: Chertov A.N., Khokhlov D.D. Comparative analysis of modern approaches to optical system design automation. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2026, vol. 26, no. 1, pp. 35–41 (in Russian). doi: 10.17586/2226-1494-2026-26-1-35-41

Введение

Автоматизация проектирования оптических систем (АПОС) является одним из ключевых направлений современной оптической инженерии. Сочетание физически обоснованных симуляторов, методов численной оптимизации и алгоритмов машинного обучения позволяет создавать компактные, энергоэффективные и технологичные оптические системы. Однако многомерность пространства параметров, высокие вычислительные затраты и отсутствие унифицированных критериев верификации требуют анализа применимости различных методов.

В последние годы наблюдается значительное развитие различных направлений АПОС, что связано с возрастающими требованиями к точности, надежности и эффективности проектных решений. Современные подходы обладают разнообразными преимуществами и ограничениями, которые проявляются в различной степени воспроизведения оптических характеристик, скорости генерации проектных решений, вычислительной нагрузке, устойчивости к вариациям параметров и чувствительности к изменениям условий эксплуатации.

Такое разнообразие методов подчеркивает необходимость их систематической классификации, сопоставления характеристик и анализа практической применимости для обеспечения эффективного выбора стратегий проектирования в конкретных прикладных задачах.

Цель работы заключается в систематизации существующих подходов к АПОС, анализе их ключевых характеристик и оценке перспектив дальнейшего развития. Полученные результаты могут служить фундаментальной основой для специалистов в области оптической инженерии при выборе методов проектирования, обеспечивающих оптимальный баланс между точностью, надежностью, скоростью и технологической реализуемостью создаваемых оптических устройств.

Классификация и характеристика методов АПОС

Современные методы АПОС можно разделить на пять основных групп: дифференцируемые физические модели и градиентная оптимизация; методы глубокого обучения; эволюционные и метаэвристические подходы; гибридные подходы, объединяющие методы машинного обучения (Machine Learning, ML) и традици-

онные физические модели оптики; методы обучения в полностью прямом режиме (Fully Forward Mode, FFM).

Дифференцируемые физические модели [1–7] основаны на вычислении производных оптических характеристик (функции рассеяния точки (ФРТ), модуля оптической передаточной функции (ОПФ)) по параметрам конструкции с использованием дифференцируемой трассировки лучей или волнового фронта. Такие подходы позволяют выполнять точную градиентную оптимизацию параметров оптических элементов, обеспечивая высокую физическую достоверность моделирования. Они наиболее эффективны при проектировании сложных объективов, микроскопических систем и оптических систем с асферическими поверхностями, где требуется строгое соответствие конструктивных параметров теоретическим и экспериментальным данным.

Методы глубокого обучения [8–10] используют нейронные сети для аппроксимации сложных физических зависимостей и обратного проектирования по заданным характеристикам. Они характеризуются высокой скоростью генерации решений и применяются на этапах предварительного проектирования, когда важно быстро получить множество допустимых конфигураций. Основная область применения — разработка миниатюрных систем, адаптивной и интегральной оптики, а также интеллектуальных платформ автоматизированного проектирования для моделирования оптических систем упомянутых типов.

Эволюционные и метаэвристические алгоритмы, такие как генетические алгоритмы или «рой частиц» (Particle Swarm Optimization, PSO), реализуют стохастический глобальный поиск без необходимости вычисления градиентов. Они устойчивы к локальным минимумам и эффективны при многокритериальной оптимизации, но характеризуются высокой вычислительной трудоемкостью [11]. Эволюционные и метаэвристические алгоритмы используют преимущественно для задач, где аналитическое описание системы затруднено или отсутствует.

Гибридные подходы [12–15] объединяют машинное обучение и физические симуляции: нейросеть генерирует стартовое решение, а физически обусловленный алгоритм оптимизации уточняет параметры с учетом технологических ограничений. Такая интеграция ускоряет сходимость и повышает надежность проектирования, особенно при создании систем с высокой степенью миниатюризации.

Перспективное направление представляют методы обучения FFM, в которых вычисления и оптимизация выполняются непосредственно в оптической среде. Архитектуры оптических нейронных сетей и режим FFM обеспечивают рекордную энергоэффективность и скорость [16, 17], что открывает возможности для построения аппаратных систем автоматизированного проектирования нового поколения.

Метрики для сравнения методов АПОС

Рассмотрим метрики, на основании которых возможно сопоставить группы методов, описанные в

разделе «Классификация и характеристика методов АПОС».

В большинстве современных научных работ количественные характеристики методов АПОС приводятся в виде сравнительных метрик: скорости работы, точности, достоверности, робастности и обобщаемости, вычислительной сложности, энергетической эффективности.

Скорость работы описывает вычислительную производительность метода и определяется временем выполнения одного элементарного шага моделирования или оптимизации (t_{iter}) и количеством шагов, необходимых для получения решения требуемой точности (N_{iter}). Метрика объединяет локальные характеристики производительности и глобальную динамику сходимости, позволяя сопоставлять методы разных классов в едином формате. Использование параметров t_{iter} и N_{iter} обеспечивает объективную оценку вычислительных затрат и дает возможность корректно сравнивать эффективность алгоритмов в задачах АПОС. Без нее невозможно сделать вывод о масштабируемости метода и о том, подойдет ли он для прототипирования или для массового применения [18].

Точность характеризует степень соответствия сформированной оптической системой отклика заданным физическим и функциональным требованиям и оценивается на двух уровнях. На физическом уровне используются стандартные оптические показатели — ФРТ, ОПФ и число Штреля, отражающие качество формирования волнового фронта, степень аберраций и близость к дифракционному пределу. На функциональном уровне точность определяется совпадением полученного распределения интенсивности с целевым изображением или функцией оптимизации, что количественно оценивается через структурный индекс сходства (Structural Similarity Index, SSIM), пиковое отношение сигнал/шум (Peak Signal-to-Noise Ratio, PSNR) и среднеквадратичную ошибку. В совокупности эти показатели позволяют объективно оценить как физическую корректность оптической системы, так и ее прикладную пригодность для задач визуализации, распознавания или формирования заданного светового поля.

Достоверность определяет степень уверенности в корректности полученного решения и его воспроизводимость при повторных расчетах или экспериментах. Она отражает, насколько результаты метода не зависят от случайных факторов — инициализации, шума данных, колебаний параметров материалов или погрешностей численной схемы — и сохраняются при использовании различных симуляторов, наборов данных и аппаратных конфигураций. Количественно достоверность оценивают через разброс значений ключевых метрик (ФРТ, ОПФ, SSIM, PSNR) при многократных запусках, вариацию результатов при моделировании технологических допусков, согласованность между симуляцией и экспериментом, а также через воспроизводимость решения на независимых аппаратных и программных конфигурациях. Высокая достоверность означает стабильность и повторяемость результатов, что критично для практического применения автоматизированных методов в оптическом проектировании.

Робастность и обобщаемость характеризуют устойчивость метода к изменению условий, при которых он работает, или, иными словами, показывают, насколько сильно падает качество результата, если входные данные, параметры среды или производственные допуски немного отличаются от тех, при которых метод обучался или оптимизировался. При этом робастность определяет устойчивость результатов при малых возмущениях входных данных или параметров модели (например, изменение длины волны на ± 5 нм, шум в измерениях, погрешность в толщине слоя ± 2 %), а обобщаемость — способность метода корректно работать на новых (ранее неизвестных) данных или в новых условиях (например, новые спектральные диапазоны, формы линз, иные условия освещения). Для оценки робастности и обобщаемости различных методов также используют SSIM, PSNR, число Штреля, ОПФ и др. Для сравнения разных групп методов АПОС с помощью метрик можно использовать качественную оценку.

Вычислительная сложность отражает объем вычислительных ресурсов, необходимых для выполнения одной итерации оптимизации, обучения или формирования оптического отклика. Для цифровых алгоритмов она оценивается количеством операций с плавающей точкой (Floating-point Operations per Second, FLOPS), памятью, необходимой для хранения данных и промежуточных результатов, а также временем выполнения на конкретном оборудовании. Для оптико-электронных и полностью оптических систем вычислительная сложность учитывает число оптических операций, глубину и конфигурацию оптических схем, скорость прохождения сигнала и требования к синхронизации. Метрика выражается через сложность на итерацию, асимптотику алгоритма (O -нотация) и реальное время расчета, позволяя оценить масштабируемость метода при увеличении размерности параметрического пространства и сложности задачи. Высокая вычислительная эффективность означает минимальные ресурсы и время при сохранении точности и стабильности решения.

Вычислительная сложность напрямую влияет на энергетическую эффективность, которая оценивает объем энергопотребления, необходимый методу или системе для выполнения одного цикла оптимизации, одной итерации обучения или формирования оптического отклика. Для цифровых алгоритмов она определяется совокупностью параметров: энергозатратами на вычислительные операции (FLOPs \rightarrow Дж), эффективностью используемого оборудования, числом итераций до сходимости и затратами на передачу данных. Для оптико-электронных и полностью оптических подходов энергетическая эффективность описывается энергией одного оптического вычисления, потерями в элементах, коэффициентом преобразования и отношением входной и выходной оптических мощностей. Количественно метрика выражается через энергию на итерацию, энергию на операцию (Дж/операцию), мощность в рабочем режиме и удельные энергозатраты на достижение требуемой точности решения. Высокая энергетическая эффективность означает минимальное потребление энергии при сохранении точности и стабильности работы, что особенно важно при масштабировании методов

АПОС к большим параметрическим пространствам и задачам реального времени.

Приведенный набор метрик рационален для сравнения различных классов методов АПОС, поскольку он: универсален и применим для всех рассматриваемых классов методов; охватывает все ключевые измеримые параметры и характеристики; объективен и отражает реальные требования, предъявляемые в практических задачах; обеспечивают возможность количественной валидации — проверяемости и воспроизводимости результатов сравнения.

Сравнительная оценка характеристик методов АПОС

Приведем результаты сравнительного качественного и количественного анализа исследуемых групп методов (таблица), с использованием отобранных сравнительных метрик. Таблица составлена на основании данных из научных работ, опубликованных в рецензируемых журналах (Nature, Optics Express, Scientific Reports, Light: Science & Applications и др.) за 2019–2025 гг.

Наилучший баланс физической достоверности и точности обеспечивают дифференцируемые подходы. При использовании графических процессоров и аналитических градиентов (например, на базе дифференцируемой оптики) достигается ускорение до 10^{\times} по сравнению с классической оптимизацией, но при этом расчет одного набора параметров требует 10^3 – 10^5 с [8, 12]. Методы глубокого обучения после обучения превосходят все прочие по скорости (до 10^3 – 10^4 раз быстрее прямой трассировки [3, 17]), что делает их незаменимыми на этапе поиска и генерации конфигураций. Однако вне обучающего распределения точность падает на 10–15 % [14]. Эволюционные методы остаются важным инструментом при глобальном поиске и многокритериальной оптимизации, но требуют большого количества симуляций; для 10–15 переменных типичный цикл занимает до 100 ч [11]. Гибридные подходы демонстрируют компромиссный результат: использование глубоких нейронных сетей для инициализации параметров позволяет сократить число итераций дифференцируемой оптимизации в 3–5 раз, сохранив физическую точность [12, 14]. FFM-методы обеспечивают радикальное повышение энергоэффективности — эксперименты [17] показывают снижение энергозатрат до 10^{-2} Дж/итерацию и латентность порядка 10^{-9} с/операцию при сопоставимом уровне точности с цифровыми сетями

Таким образом, можно констатировать, что дифференцируемые физические методы обеспечивают наилучшую физическую достоверность и точность, методы машинного обучения — максимальную скорость и масштабируемость, а гибридные схемы — оптимальный компромисс между ними.

Обсуждение

Проведенный анализ показывает, что развитие АПОС определяется комбинированием физически обоснованных моделей, алгоритмов оптимизации и

Таблица. Сравнительные характеристики современных подходов к АПОС
Table. Comparative characteristics of the modern approach to OSDA

Группа методов	Типичная скорость работы ¹	Средняя точность (по ФРТ/ОПФ/целевой функции) ²	Достоверность (учет физических и технологических факторов)	Робастность (к локальным минимумам/обобщаемость)	Вычислительная сложность	Энергетическая эффективность ³
Дифференцируемая трассировка лучей и градиентные оптимизаторы	$t_{iter} = 10^{-3} - 10^{-1}$ с $N_{iter} \approx 10^2 - 10^4$	0,98–0,995	Высокая (учет реальных параметров, оптики, дифракции)	Средняя (зависит от начального приближения)	Растет линейно по числу поверхностей, лучей и итераций ($N \cdot M \cdot k$)	Средняя (требует высоких вычислительных мощностей)
Методы глубокого обучения (суррогатные модели, обратное проектирование)	$t_{iter} = 10^{-6} - 10^{-4}$ с $N_{iter} = 1$	0,80–0,97 (0,90–0,97 на обучающих данных; 0,80–0,90 вне распределения)	Средняя; требует регуляризации и верификации	Высокая при близких данных; падает вне распределения	Растет линейно по объему данных и глубине сети ($M \cdot L$); inference ⁴ значительно быстрее	Высокая при inference (до $100 \times$ быстрее трассировки)
Эволюционные / метаэвристические методы (GA, PSO)	$t_{iter} = 10^{-2} - 1$ с $N_{iter} \approx 10^4 - 10^6$	0,85–0,95	Средняя; нет встраиваемой физической модели	Высокая (поиск глобальных максимумов)	Растет линейно по числу особей и поколений ($P \cdot G$)	Низкая
Гибридные ML-физические методы	$t_{iter} \approx 10^{-3} - 10^{-1}$ с $N_{iter} \approx 2 \times 10^1 - 3 \times 10^3$	0,95–0,99	Высокая (учет физики и технологичности)	Высокая; комбинирует глобальный и локальный поиск	Суммарно: обучение ML — растет линейно по объему данных (M), физическая оптимизация — растет линейно по поверхностям и итерациям ($N \cdot k$)	Средняя–высокая
FFM-методы	$t_{iter} \approx 10^{-11} - 10^{-9}$ с $N_{iter} \approx 1 - 10$	0,95–0,98	Высокая (обучение на физически реализованной оптической системе исключает рассогласование)	Средняя (чувствительна к шуму, дрейфу)	Растет линейно по числу оптических элементов	Очень высокая ($> 100 \times$ цифровых реализаций)

¹ Приведенные значения t_{iter} и N_{iter} относятся к системам среднего уровня сложности (5–10 поверхностей, апертура до 20 мм), что обеспечивает сопоставимость методов.

² Точность приведена в нормализованной шкале относительно эталонной оптической модели или целевой функции качества изображения (например, ОПФ, ФРТ). Значение 1 соответствует идеальному совпадению с эталоном, а меньшие значения отражают отклонение от него. Такая нормировка позволяет сравнивать методы с разными критериями оптимизации и различными единицами измерения.

³ Энергетическая эффективность — усредненная относительная оценка, показывающая порядок превосходства или отставания от традиционных цифровых реализаций.

⁴ Inference — процесс применения уже обученной модели для расчета результатов на новых данных. В отличие от обучения, требует значительно меньше вычислительных ресурсов и времени.

методов машинного обучения. Дифференцируемые физические подходы остаются эталоном точности и физической достоверности, обеспечивая возможность прямой оптимизации характеристик изображения и аберраций в рамках единой модели. Однако высокая вычислительная трудоемкость и чувствительность к локальным минимумам ограничивают их применение в задачах, требующих быстрой итеративной настройки параметров. Методы глубокого обучения демонстрируют значительное преимущество по скорости и масштабируемости, позволяя за доли секунды формировать стартовые решения и прогнозировать оптические характеристики с точностью до 90–97 % на распределениях данных, близких к обучающим. Их слабым местом остается необходимость в обширных и репрезентативных обучающих выборках, а также важность встроенного контроля физической реализуемости и технологичности получаемых решений.

Эволюционные и метаэвристические подходы сохраняют актуальность при решении задач глобального поиска в сильно многомодальных пространствах параметров, особенно в случаях, когда функция цели не имеет аналитических градиентов. При этом их вычислительная стоимость остается самой высокой среди всех рассмотренных групп методов, что делает их преимущественно исследовательским инструментом.

Наиболее перспективным направлением развития на сегодняшний день являются гибридные схемы, объединяющие преимущества нейросетевых генераторов и дифференцируемой физической оптимизации. Они обеспечивают устойчивость к локальным минимумам, сокращая время сходимости и позволяют учитывать технологические ограничения на всех этапах проектирования. Такие подходы уже продемонстрировали эффективность при создании миниатюрных объективов и микроскопических систем.

Отдельного внимания заслуживают методы FFM и оптические нейронные сети. Они открывают путь к созданию энергосберегающих систем автоматизации проектирования, способных выполнять обучение и оптимизацию непосредственно в оптическом домене. Хотя на текущем этапе эти решения находятся на уровне лабораторных прототипов, опубликованные результаты исследований демонстрируют потенциал

снижения энергопотребления более чем на два порядка при сопоставимой точности оптимизации. Дальнейшее развитие аппаратных платформ, стабилизация параметров и совершенствование процедур калибровки могут сделать такие системы ключевым направлением в энергоэффективной оптической инженерии.

Заключение

В работе проведен сравнительный анализ современных подходов к автоматизации проектирования оптических систем. Рассмотрены пять основных групп методов: дифференцируемые физические модели, методы глубокого обучения, эволюционные и метаэвристические алгоритмы, гибридные подходы, а также методы обучения в полностью прямом режиме. Для оценки их эффективности использованы унифицированные метрики: скорость работы, точность, достоверность, робастность и обобщаемость, вычислительная сложность и энергетическая эффективность.

Анализ показал, что дифференцируемые физические методы обеспечивают наибольшую точность и физическую достоверность, методы глубокого обучения — максимальную скорость и масштабируемость, а гибридные подходы позволяют достичь оптимального баланса между этими характеристиками. Эволюционные алгоритмы остаются эффективными для глобального поиска в сложных многомодальных пространствах, а методы в полностью прямом режиме и оптические нейронные сети демонстрируют уникальные возможности для аппаратных решений с высокой энергетической эффективностью.

В целом, дальнейшее развитие методов автоматизации проектирования оптических систем будет определяться интеграцией гибридных подходов, сочетанием машинного обучения и физического моделирования, а также созданием стандартизованных наборов данных и процедур верификации, необходимых для обеспечения воспроизводимости результатов. Решение этих задач позволит перейти от разрозненных исследовательских прототипов к промышленным программно-аппаратным системам проектирования, обеспечивающим баланс между скоростью и точностью процесса проектирования, а также технологической реализуемостью создаваемых оптических устройств.

Литература

1. Wu C.-M., Tang X.-X., Xia Y.-Y., Yang H.-X., Xu F.-J. High precision ray tracing method for space camera in optical design // *Acta Physica Sinica*. 2023. V. 72. N 8. P. 084201. <https://doi.org/10.7498/aps.72.20222463>
2. Liu X.B., Zhang X.X., Fu T.J., Wang K.Z., Sun F.K., Bai T.Z., Wang D. Global information selectively guided gradient descent for ab initio optical design // *Optics and Laser Technology*. 2025. V. 184. P. 112497. <https://doi.org/10.1016/j.optlastec.2025.112497>
3. Zhang W., Ren Z., Zhou J., Chen S., Feng H., Li Q., Xu Z., Chen Y. End-to-end automatic lens design with a differentiable diffraction model // *Optics Express*. 2024. V. 32. N 25. P. 44328–44345. <https://doi.org/10.1364/oe.540590>
4. Иванова Т.В., Романова Г.Э., Жукова Т.И., Калинин О.С. Автоматизация синтеза атермализованного склеенного компонента // Научно-технический вестник информационных технологий,

References

1. Wu C.-M., Tang X.-X., Xia Y.-Y., Yang H.-X., Xu F.-J. High precision ray tracing method for space camera in optical design. *Acta Physica Sinica*, 2023, vol. 72, no. 8, pp. 084201. (in Chinese). <https://doi.org/10.7498/aps.72.20222463>
2. Liu X.B., Zhang X.X., Fu T.J., Wang K.Z., Sun F.K., Bai T.Z., Wang D. Global information selectively guided gradient descent for ab initio optical design. *Optics and Laser Technology*, 2025, vol. 184, pp. 112497. <https://doi.org/10.1016/j.optlastec.2025.112497>
3. Zhang W., Ren Z., Zhou J., Chen S., Feng H., Li Q., Xu Z., Chen Y. End-to-end automatic lens design with a differentiable diffraction model. *Optics Express*, 2024, vol. 32, no. 25, pp. 44328–44345. <https://doi.org/10.1364/oe.540590>
4. Ivanova T.V., Romanova G.E., Zhukova T.I., Kalinkina O.S. Automation of athermal cemented doublet synthesis. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*,

- механики и оптики. 2019. Т. 19. № 4. С. 594–601. <https://doi.org/10.17586/2226-1494-2019-19-4-594-601>
5. Нгуен З.Х., Бахольдин А.В. Автоматизация синтеза и ранжирование склеенного и расклеенного двухлинзовых объективов // Компьютерная оптика. 2022. Т. 46. № 1. С. 83–90. <https://doi.org/10.18287/2412-6179-CO-923>
 6. Носов П.А., Павлов В.Ю., Пахомов И.И., Ширанков А.Ф. Аберрационный синтез оптических систем, предназначенных для преобразования лазерных пучков // Оптический журнал. 2011. Т. 78. № 9. С. 34–44.
 7. Лившиц И.Л., Точилина Т.В., Фаенле О., Волкова С.Л. Стратегия проектирования и управление процессом коррекции аберраций объектива с высоким индексом сложности // Научно-технический вестник информационных технологий, механики и оптики. 2021. Т. 21. № 1. С. 40–51. <https://doi.org/10.17586/2226149420212114051>
 8. Côté G., Lalonde J.-F., Thibault S. Deep learning-enabled framework for automatic lens design starting point generation // Optics Express. 2021. V. 29. N 3. P. 3841–3854. <https://doi.org/10.1364/oe.401590>
 9. Luo M., Lee S.-S. Inverse design of optical lenses enabled by generative flow-based invertible neural networks // Scientific Reports. 2023. V. 13. N 1. P. 16416. <https://doi.org/10.1038/s41598-023-43698-3>
 10. Fu T., Zhang J., Sun R., Huang Y., Xu W., Yang S., Zhu Z., Chen H. Optical neural networks: progress and challenges // Light Science and Applications. 2024. V. 13. N 1. P. 263. <https://doi.org/10.1038/s41377-024-01590-3>
 11. Höschel K., Lakshminarayanan V. Genetic algorithms for lens design: a review // Journal of Optics. 2019. V. 48. N 1. P. 134–144. <https://doi.org/10.1007/s12596-018-0497-3>
 12. Yang X., Fu Q., Heidrich W. Curriculum learning for ab initio deep learned refractive optics // Nature Communications. 2024. V. 15. N 1. P. 6572. <https://doi.org/10.1038/s41467-024-50835-7>
 13. Zhao J., Liang K., Van Vleck A., Du L., Winetraub Y., Peng Y.F., de la Zerda A. Extending depth-of-field of arbitrary diffractive optics with needle-shaped beam modulation // ACS Photonics. 2024. V. 11. N 9. P. 3481–3490. <https://doi.org/10.1021/acsp Photonics.4c00260>
 14. Yow A.P., Wong D., Zhang Y., Menke C., Wolleschensky R., Török P. Artificial intelligence in optical lens design // Artificial Intelligence Review. 2024. V. 57. N 8. P. 193. <https://doi.org/10.1007/s10462-024-10842-y>
 15. Нестеров Г.В., Хохлов Д.Д., Батшев В.И. Автоматизация проектирования двухлинзового склеенного объектива с использованием методов машинного обучения // Физические основы приборостроения. 2024. Т. 13. № 4 (54). С. 57–63. <https://doi.org/10.25210/jfop-2404-INGPBM>
 16. Volatier J.-B., Beaussier S.J., Druart G., Jouglu P., Keller F. Implementation of FORMIDABLE: a generalized differential optical design library with NURBS capabilities // Journal of the European Optical Society-Rapid Publications. 2024. V. 20. N 1. P. 2. <https://doi.org/10.1051/jeos/2023043>
 17. Xue Z., Zhou T., Xu Z., Yu S., Dai Q., Fang L. Fully forward mode training for optical neural networks // Nature. 2024. V. 632. N 8024. P. 280–286. <https://doi.org/10.1038/s41586-024-07687-4>
 18. Wang Z., Peng Y., Fang L., Gao L. Computational optical imaging: on the convergence of physical and digital layers // Optica. 2025. V. 12. N 1. P. 113–130. <https://doi.org/10.1364/OPTICA.544943>
 - 2019, vol. 19, no. 4, pp. 594–601. (in Russian). <https://doi.org/10.17586/2226-1494-2019-19-4-594-601>
 5. Nguyen DH, Bakholdin AB. Automation of synthesis and ranking of cemented and air-spaced doublets. *Computer Optics*, 2022, vol. 46, no. 1, pp. 83–89. (in Russian). <https://doi.org/10.18287/2412-6179-CO-923>
 6. Nosov P.A., Pavlov V.Yu., Pakhomov I.I., Shirankov A.F. Aberrational synthesis of optical systems intended for the conversion of laser beams. *Journal of Optical Technology*, 2011, vol. 78, no. 9, pp. 586–593. <https://doi.org/10.1364/JOT.78.000586>
 7. Livshits I.L., Tochilina T.V., Faehnle O., Volkova S.L. Design strategy and management of aberration correction process for lens with high complexity index. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2021, vol. 21, no. 1, pp. 40–51. (in Russian). <https://doi.org/10.17586/2226-1494-2021-21-1-40-51>
 8. Côté G., Lalonde J.-F., Thibault S. Deep learning-enabled framework for automatic lens design starting point generation. *Optics Express*, 2021, vol. 29, no. 3, pp. 3841–3854. <https://doi.org/10.1364/oe.401590>
 9. Luo M., Lee S.-S. Inverse design of optical lenses enabled by generative flow-based invertible neural networks. *Scientific Reports*, 2023, vol. 13, no. 1, pp. 16416. <https://doi.org/10.1038/s41598-023-43698-3>
 10. Fu T., Zhang J., Sun R., Huang Y., Xu W., Yang S., Zhu Z., Chen H. Optical neural networks: progress and challenges. *Light Science and Applications*, 2024, vol. 13, no. 1, pp. 263. <https://doi.org/10.1038/s41377-024-01590-3>
 11. Höschel K., Lakshminarayanan V. Genetic algorithms for lens design: a review. *Journal of Optics*, 2019, vol. 48, no. 1, pp. 134–144. <https://doi.org/10.1007/s12596-018-0497-3>
 12. Yang X., Fu Q., Heidrich W. Curriculum learning for ab initio deep learned refractive optics. *Nature Communications*, 2024, vol. 15, no. 1, pp. 6572. <https://doi.org/10.1038/s41467-024-50835-7>
 13. Zhao J., Liang K., Van Vleck A., Du L., Winetraub Y., Peng Y.F., de la Zerda A. Extending depth-of-field of arbitrary diffractive optics with needle-shaped beam modulation. *ACS Photonics*, 2024, vol. 11, no. 9, pp. 3481–3490. <https://doi.org/10.1021/acsp Photonics.4c00260>
 14. Yow A.P., Wong D., Zhang Y., Menke C., Wolleschensky R., Török P. Artificial intelligence in optical lens design. *Artificial Intelligence Review*, 2024, vol. 57, no. 8, pp. 193. <https://doi.org/10.1007/s10462-024-10842-y>
 15. Nesterov G.V., Khokhlov D.D., Batshev V.I. Automation of cemented doublet design using machine learning methods. *Physical Bases of Instrumentation*, 2024, vol. 13, no. 4 (54), pp. 57–63. (in Russian). <https://doi.org/10.25210/jfop-2404-INGPBM>
 16. Volatier J.-B., Beaussier S.J., Druart G., Jouglu P., Keller F. Implementation of FORMIDABLE: a generalized differential optical design library with NURBS capabilities. *Journal of the European Optical Society-Rapid Publications*, 2024, vol. 20, no. 1, pp. 2. <https://doi.org/10.1051/jeos/2023043>
 17. Xue Z., Zhou T., Xu Z., Yu S., Dai Q., Fang L. Fully forward mode training for optical neural networks. *Nature*, 2024, vol. 632, no. 8024, pp. 280–286. <https://doi.org/10.1038/s41586-024-07687-4>
 18. Wang Z., Peng Y., Fang L., Gao L. Computational optical imaging: on the convergence of physical and digital layers. *Optica*, 2025, vol. 12, no. 1, pp. 113–130. <https://doi.org/10.1364/OPTICA.544943>

Авторы

Чертов Александр Николаевич — кандидат технических наук, доцент, старший научный сотрудник, Научно-технологический центр уникального приборостроения РАН, Москва, 117342, Российская Федерация, [sc 55303364600](https://orcid.org/0000-0002-2015-0458), <https://orcid.org/0000-0002-2015-0458>, chertov.an@ntcup.ru

Хохлов Демид Денисович — кандидат технических наук, заведующий лабораторией, Научно-технологический центр уникального приборостроения Российской академии наук, Москва, 117342, Российская Федерация, [sc 57188552491](https://orcid.org/0000-0003-0919-7762), <https://orcid.org/0000-0003-0919-7762>, khokhlov.dd@ntcup.ru

Authors

Aleksandr N. Chertov — PhD, Associate Professor, Senior Researcher, Scientific and Technological Centre of Unique Instrumentation of the Russian Academy of Sciences, Moscow, 117342, Russian Federation, [sc 55303364600](https://orcid.org/0000-0002-2015-0458), <https://orcid.org/0000-0002-2015-0458>, chertov.an@ntcup.ru

Demid D. Khokhlov — PhD, Head of Laboratory, Scientific and Technological Centre of Unique Instrumentation of the Russian Academy of Sciences, Moscow, 117342, Russian Federation, [sc 57188552491](https://orcid.org/0000-0003-0919-7762), <https://orcid.org/0000-0003-0919-7762>, khokhlov.dd@ntcup.ru

Статья поступила в редакцию 16.10.2025
Одобрена после рецензирования 05.12.2025
Принята к печати 22.01.2026

Received 16.10.2025
Approved after reviewing 05.12.2025
Accepted 22.01.2026



Работа доступна по лицензии
Creative Commons
«Attribution-NonCommercial»