

СОВРЕМЕННЫЕ МЕТОДЫ ИИ-ОПТИМИЗАЦИИ ПАРАМЕТРОВ 3D-ПЕЧАТИ

В.В. Мальцев¹, А.В. Ачкасов¹, И.А. Бунеев¹

¹ФГБОУ ВО «Воронежский государственный лесотехнический университет
имени Г.Ф. Морозова»

Аннотация. В статье проводится анализ методов 3D-печати, в различных сферах производства. Были изучены современные методы ИИ-оптимизации параметров 3D-печати, направленные на решение основных проблем в данной сфере – неоднородность материала, деформация слоев, вызванная термическим напряжением и другие. Также были рассмотрены перспективные направления, включающие адаптацию ИИ-моделей для мультиматериальных систем и ускорение оптимизации за счет квантовых вычислений.

Ключевые слова: аддитивные технологии, 3D-печать, машинное обучение, ИИ, нейронные сети.

MODERN METHODS OF AI-DRIVEN OPTIMIZATION FOR 3D PRINTING PARAMETERS

V.V. Maltsev¹, A.V. Achkasov¹, I.A. Buneyev¹

¹Voronezh State University of Forestry and Technologies named after G.F. Morozov

Abstract. This article analyzes 3D printing methods in various fields of manufacturing. Modern AI-driven optimization methods for 3D printing parameters were studied, aimed at solving key challenges in the field: material inhomogeneity, layer deformation caused by thermal stress, and others. Promising directions were also explored, including the adaptation of AI models for multi-material systems and optimization acceleration through quantum computing.

Keywords: additive manufacturing, 3D printing, machine learning, AI, neural networks.

Введение

В сфере аддитивного производства (АМ), современные организации часто сталкиваются с рядом проблем при обеспечении качества выпускаемой продукции, оптимизации своих производственных процессов, а также принятии решений какие именно детали подходят для производства с применением аддитивных технологий. В современном мире, с увеличением производства, растут и число проблем, с которыми сталкиваются организации – нестабильное качество деталей, барьеры при масштабируемости производства, высокие затраты. Также не маловажный момент – это устаревший стек программного обеспечения, который в свое время был разработан для прототипирования и ему становится сложно справляться с современными процессами АМ. К таким сложностям относятся подготовка сборки, оптимизация проектирования, адаптация системы управления производственными процессами (MES). Для решения данных проблем, подойдут современные методы, такие как искусственный интеллект (ИИ), машинное обучение и машинное зрение.

Архитектура нейросетей моделей.

Модель U-Net, выпущенная в 2015 году, изначально была разработана для медицинского сектора, которая была адаптирована на прогнозирование деформаций изделий в аддитивном производстве [1]. Сохранение пространственных характеристик на всех уровнях обработки данных, происходит за счет U-образной структуры со skip-соединениями. В настоящее же время существует уже несколько модификаций данной модели: GAN-Enhanced U-Net использующая генеративно-состязательные сети для синтеза термограмм, способствующая повышению точности на 12% [2]. MTA-UNet – многозадачная архитектура, позволяет прогнозировать напряжение и деформации с MAE (средняя абсолютная ошибка) = 14мкм [3]. Physics-Informed U-Net – интеграция уравнений теплопередачи в обучаемый конвейер, снижающая ошибку до 15 мкм [4].

Классические сверточные сети (CNN) способны прогнозировать дефекты с точностью до 88%, по сравнению с другими сетями, в то время как сеть долгой краткосрочной памяти (LSTM) способна с высокой точностью анализировать временные ряды данных MeltPool, но при этом требуют больше вычислительных ресурсов. Входные параметры инженерной модели, такие как тепловой градиент, толщина слоя и скорость лазера, дополняются данными от MeltPool-датчиков, которые фиксируют геометрию расплавленной зоны с частотой 500 Гц [5,13].




Рисунок 1 – Архитектура U-Net (пример для 32x32 пикселей в самом низком разрешении) [1].




Рисунок 2 – Структура MTA-UNet [6].

Таблица 1 – Сравнение методов прогнозирования

Метод	Точность (%)	MAE (мкм)	Источник
PINN+ UNet	94	12	[7]
Традиционный FEA	88	18	[8]
Random Forest	85	20	[7]
SVM	82	22	[7]

Исследования показывают, что система AMAIZE (1000 Kelvin) с интегрированным, полностью автоматизированным ИИ-рабочим процессом, при автоматической коррекции термомеханических параметров, способна снижать время подготовки почти на 40% [9]. Цифровые двойники, которые имитируют деформацию на этапе проектирования, способны сократить цикл разработки на 30%.

Системы реального времени.

Современная платформа от компании NVIDIA Jetson Xavier NX – способна обеспечивать обработку данных с задержкой 25 мс на слой [10]. Новая интеграция с PrintRite3D способна автоматически корректировать параметры 3D-печати основываясь на термограмму, формируя при этом замкнутый контур управления. В сенсорную систему входит MeltPool-мониторинг с частотой 500 Гц, а также ОСТ-сканеры, которые анализируют структуру слоя в реальном времени с разрешением 10 мкм [11].

Проблемы и решения

При работе с таким материалом как инконель 718, операторы постоянно сталкиваются с проблемами нестабильности моделей, из-за неоднородности термических свойств, а также высокой вязкопластичности материала. Методы борьбы с данными проблемами включают в себя **мультифизическое моделирование** — комбинация данных с FEM-симуляциями улучшает стабильность прогноза, **активное обучение** — оптимизация параметров на малых выборках ($N=50$) с использованием байесовских методов, а также **аугментация данных** — добавление шума и поворотов в обучающую выборку снижает ошибку обобщения [12].

Для других материалов, таких как титан Ti-6Al-4V, применение L1-регуляризации снижает MSE, а для алюминия AlSi10Mg использование Transfer Learning сокращает время обучения в 3 раза.

Заключение

Основными трендами 2025 года будет гибридное производство, которое сочетает 3D-печать с CNC, что позволит улучшать качество поверхности готовой продукции. Байесовская оптимизация, способная минимизировать количество экспериментов для многоцелевых задач – стоимость, скорость, точность. Устойчивость при ИИ оптимизации расхода материалов, позволит сократить углеродный след.

Современные подходы к АМ должны создавать симбиоз гибридных нейросетевых моделей (GAN, U-Net), аппаратных инноваций (MeltPool-датчики, Jetson Xavier), а также методов регуляризации, для повышения производительности.

Будущие исследования в данной сфере должны быть направлены на адаптацию моделей для мультиматериальных систем с градиентными свойствами, изучение ускорения оптимизации параметров в 100 раз, за счет квантовых вычислений, а также создание самообучающихся производственных линий через интеграцию с IoT.

Список литературы

1. Роннебергер О. U-Net: Свёрточные сети для биомедицинской сегментации изображений // Медицинская компьютерная томография и компьютерное вмешательство (MICCAI). 2015. URL: <https://lmb.informatik.uni-freiburg.de/people/ronneber/u-net/> (дата обращения: 13.02.2025).

2. Фюлоп А., Хорват А. Сквозное обучение глубоких нейронных сетей в частотной области // Mathematics. 2022. Т. 10. С. 2132. DOI: 10.3390/math10132132.

3. Лу Х., Хуан Я., Чжан Ч. и др. Достижения в глубоком обучении для микроскопии сверхвысокого разрешения (приглашённый доклад) // Laser & Optoelectronics Progress. 2024. Т. 61, № 16. Ст. 1611002. DOI: 10.3788/LOP6124161002.

4. Машинное обучение для физических наук: воркшоп на NeurIPS 2022 [ML for Physical Sciences Workshop at NeurIPS 2022]. URL: https://ml4physicalsciences.github.io/2022/files/NeurIPS_ML4PS_2022_92.pdf (дата обращения: 13.02.2025).

5. Рудской А.И., Волков К.Н., Соколов Ю.А., Кондратьев С.Ю. Цифровые производственные системы: технологии, моделирование, оптимизация. СПб.: СПбПУ, 2020. 828 с.

6. Маркидис С. Старое и новое: Могут ли физически информированные методы глубокого обучения заменить традиционные линейные решатели? // Mathematics. 2022. Т. 10. С. 603. DOI: 10.3390/math9100603.

7. NVIDIA Solutions. URL: <https://www.macnica.co.jp/en/business/semiconductor/manufacturers/nvidia/products/134046/> (дата обращения: 13.02.2025).

8. Сизая А. Моделирование теплопередачи и напряжений при лазерной сварке с использованием пакета FENICS // Английский язык в сфере профессиональных коммуникаций: Сб. докл. VII Всерос. молодежной науч. конф. Казань, 2021. С. 249-251.

9. Appercase News. URL: <https://www.appercase.ru/news/27220/> (дата обращения: 13.02.2025).

10. Assured Systems. URL: <https://www.assured-systems.com/nvidia-jetson-agx-xavier-for-new-era-of-ai-in-robotics/> (дата обращения: 13.02.2025).

11. Sigma Labs News. URL: <https://3dprintingindustry.com/news/sigma-labs-printrite3d-platform-made-compatible-with-polymer-3d-printing-201503/> (дата обращения: 13.02.2025).

12. Николенко, С. Д. Моделирование возникновения внутренних напряжений в сложной структуре материала / С. Д. Николенко, С. П. Козодаев, С. А. Сазонова // Моделирование систем и процессов. – 2024. – Т. 17, № 2. – С. 50-61. – DOI 10.12737/2219-0767-2024-17-2-50-61.

13. Сазонова, С. А. Моделирование процесса диагностики утечек на основе двухальтернативной гипотезы с учетом помех от стохастичности потребления в гидравлической системе / С. А. Сазонова, И. В. Щербакова, Г. И. Сметанкина // Моделирование систем и процессов. – 2024. – Т. 17, № 1. – С. 111-120.

References

1. Ronneberger O. U-Net: Convolutional Networks for Biomedical Image Segmentation // Medical Image Computing and Computer-Assisted Intervention (MICCAI). 2015. URL: <https://lmb.informatik.uni-freiburg.de/people/ronneber/u-net/> (accessed: 13.02.2025).

2. Fülöp A., Horváth A. End-to-End Training of Deep Neural Networks in the Fourier Domain // Mathematics. 2022. Vol. 10. P. 2132. DOI: 10.3390/math10132132.

3. Lu X., Huang Y., Zhang Z. et al. Advances in Deep Learning for Super-Resolution Microscopy (Invited) // Laser & Optoelectronics Progress. 2024. Vol. 61, No. 16. Art. 1611002. DOI: 10.3788/LOP6124161002.

4. Machine Learning for Physical Sciences: Workshop at NeurIPS 2022 [ML for Physical Sciences Workshop at NeurIPS 2022]. URL: https://ml4physicalsciences.github.io/2022/files/NeurIPS_ML4PS_2022_92.pdf (accessed: 13.02.2025).

5. Rudskoy A.I., Volkov K.N., Sokolov Y.A., Kondratyev S.Y. Digital Manufacturing Systems: Technologies, Modeling, Optimization. St. Petersburg: SPbPU, 2020. 828 p.
6. Markidis S. The Old and the New: Can Physics-Informed Deep Learning Replace Traditional Linear Solvers? // Mathematics. 2022. Vol. 10. P. 603. DOI: 10.3390/math9100603.
7. NVIDIA Solutions. URL: <https://www.macnica.co.jp/en/business/semiconductor/manufacturers/nvidia/products/134046/> (accessed: 13.02.2025).
8. Sizaya A. Simulation of Heat Transfer and Stresses in Laser Welding Using the FENICS Package // English in Professional Communication: Proc. VII All-Russian Youth Sci. Conf. Kazan, 2021. P. 249-251.
9. Appercase News. URL: <https://www.appercase.ru/news/27220/> (accessed: 13.02.2025).
10. Assured Systems. URL: <https://www.assured-systems.com/nvidia-jetson-agx-xavier-for-new-era-of-ai-in-robotics/> (accessed: 13.02.2025).
11. Sigma Labs News. URL: <https://3dprintingindustry.com/news/sigma-labs-printrite3d-platform-made-compatible-with-polymer-3d-printing-201503/> (accessed: 13.02.2025).
12. Nikolenko, S.D., Kozodaev, S.P., Sazonova, S.A. Modeling of Internal Stresses Formation in Complex Material Structures // Modeling of Systems and Processes. 2024. Vol. 17, No. 2. Pp. 50-61. DOI: 10.12737/2219-0767-2024-17-2-50-61.
13. Sazonova, S.A., Shcherbakova, I.V., Smetankina, G.I. Modeling of Leakage Diagnostics Process Based on Binary Hypothesis with Consideration of Stochastic Consumption Interference in Hydraulic Systems // Modeling of Systems and Processes. 2024. Vol. 17, No. 1. Pp. 111-120. DOI: 10.12737/2219-0767-2024-17-1-111-120.