

УДК 004.896

Анализ актуальных исследований в области применения машинного обучения для оптимизации процессов в аддитивном производстве

Хохлов Артем Валерьевич

eluna.moonrider@gmail.com

МГТУ им. Н.Э. Баумана, Москва, Россия

Аннотация. Исследовано применение машинного обучения и объяснимого искусственного интеллекта в различных процессах аддитивного производства, таких как фотополимеризация в ванне, сплавление порошка, струйная обработка связующего, струйная печать материалов, направленное энергетическое осаждение и экструзия материалов. Показано, что применение гибридных алгоритмов и моделей, таких как сверточные нейронные сети и байесовская оптимизация, позволяет улучшить механические характеристики и стабильность микроструктурных свойств. В рассматриваемых материалах продемонстрирован потенциал применения искусственного интеллекта и алгоритмов машинного обучения в повышении эффективности и надежности производственных процессов, что подчеркивает его значимость для инноваций в таких отраслях, как аэрокосмическая, биомедицинская и автомобильная промышленность.

Ключевые слова: аддитивное производство, машинное обучение, оптимизация параметров, фотополимеризация в ванне, сплавление порошка, экструзия материалов, прогнозирование дефектов, качество продукции

Analysis of current research of machine learning application for additive production process optimisation

Khokhlov Artem Valerievich

eluna.moonrider@gmail.com

BMSTU, Moscow, Russia

Abstract. This paper explores the application of machine learning and explainable artificial intelligence in various additive manufacturing processes such as vat photopolymerization, powder fusion, binder jetting, material jetting, directed energy deposition, and material extrusion. It is shown that the application of hybrid algorithms and models such as convolutional neural networks and Bayesian optimization can improve mechanical performance and the stability of microstructural properties. The paper demonstrates the potential of using artificial intelligence and machine learning algorithms to improve the efficiency and reliability of manufacturing processes, highlighting its importance for innovation in industries such as aerospace, biomedical, and automotive.

Keywords: additive manufacturing, machine learning, parameter optimization, bath photopolymerization, powder fusion, material extrusion, defect prediction, product quality

Введение. Современные технологии аддитивного производства классифицируются на семь основных категорий: фотополимеризация в ванне, струйная подача связующего, спекание порошка, струйная подача материала, направленное энергетическое осаждение, экструзия материала и ламинирование листа. Эти категории сосредоточены на одношаговых процессах, в то время как системы, объединяющие две или более технологии аддитивного производства (АМ), применяются в многошаговых производственных процессах.

Каждый процесс АМ обладает значительными наборами качеств и факторов, сдерживающих полные способности каждой технологии АМ. Внедрение искусственного интеллекта (ИИ) в данные процессы способно значительно повлиять как на развитие существующих методов производства, так и на появление новых направлений АМ, учитывающих полную интеграцию и синергию с ИИ, а также способствовать принятию машинного обучения в производственных задачах среди специалистов, способствуя мягкой интеграции для оптимизации последующего их развития.

Цель данной работы — анализ актуальных исследований и работ, показывающих применение искусственного интеллекта в области аддитивного производства для внедрения и синергии их в сферы аэрокосмического и автомобильного производств.

Методы применения искусственного интеллекта в процессах аддитивного производства. Фотополимеризация в ванне (VPP) — одна из первых технологий аддитивного производства (АМ), известная своими уникальными процессами нанесения, отверждения и исходным состоянием материала. С 1990-х годов достижения в области фотополимеризации значительно улучшили скорость производства, методы, а также качество и надежность 3D-печатных компонентов. Этот метод использует «жидкость-твердое тело» подход, где твердые модели формируются из ванны с жидкими смолами, которые отверждаются под воздействием света с помощью компьютерно-управляемой фотополимеризации.

В процессе VPP модель формируется в ванне с жидкой фотополимерной смолой. Каждый слой добавляется поочередно, а платформа опускает объект после отверждения каждого слоя. Ультрафиолетовый свет используется для затвердевания смолы, что позволяет создавать структуры на стадии строительства в жидкой среде.

Недавние исследования показали, как методы машинного обучения (ML) могут улучшить результаты и точность прогнозирования в VPP. В недавнем исследовании [1] удалось оптимизировать скорость и затраты 3D-печати. Разработанные ими модели определили пять наборов соотношений мономеров, достигающих оптимальности по Парето для σT и UT , при этом сохраняя соответствующую T_g для приложений с памятью формы и при этом уменьшив количество ошибок с 16 до 3 %.

Другая работа [2] демонстрирует новый и эффективный метод изготовления микроигл (μN) путем объединения фотополимеризации в ванне и машинного обучения (VP-ML). Подход VPML начинается с создания набора

данных для разработки модели машинного обучения, которая прогнозирует необходимые параметры печати для машины VP на основе желаемых размеров. Этот метод позволяет осуществлять точное изготовление путем выборочного отверждения жидкой фотополимерной смолы слой за слоем с использованием цифровой маски.

Технология VP-ML превосходит традиционные методы изготовления, устраняя необходимость в формах и сложных многоступенчатых процессах, что приводит к более быстрому, настраиваемому производству. Она значительно сокращает отходы материала и производственные затраты, производя при этом более острые кончики игл. Интеграция алгоритма обратного распространения байесовой регуляризации с десятью скрытыми слоями (BR10) оптимизирует параметры печати, повышая скорость и качество производства. Экспериментальные результаты показывают, что VP-ML может производить μN с диаметром основания более 150 мкм и высотой более 500 мкм, достигая средней абсолютной процентной погрешности (MAPE) менее 10 % в 32 случаях. Кроме того, тесты на проникновение показывают, что эти μN могут проникать на глубину до 90 % от их общей высоты.

В целом VP-ML демонстрируется как экологически чистое и экономически эффективное решение для производства μN , предлагая значительные улучшения в точности, эффективности производства, гибкости и масштабируемости. Эти исследования подчеркивают потенциал ML для значительного увеличения точности и эффективности процессов VPP. Гибридные алгоритмы, такие как сочетание ANN с генетическими алгоритмами (GA), улучшают оптимизацию, качество и эффективность печати. Другие комбинации, такие как генетическое программирование (GP) и байесовские сети (BN), помогли выявить дефекты в процессе 3D-печати. Эволюционные алгоритмы, включая оптимизацию роя частиц, дифференциальную эволюцию и искусственную колонию пчел, успешно применяются для решения сложных задач оптимизации в процессе AM.

Метод сплавления порошка (PBF) создает детали путем послойного плавления металлического или полимерного порошка, что достигается с помощью лазера (Laser Fusion) или электронного луча (Electron Beam Melting, EBM). Лазерное сплавление порошка (L-PBF), особенно с применением лазеров, является одной из наиболее передовых и широко используемых технологий аддитивного производства (AM) металла. Для обеспечения достаточного плавления и углубления ванны расплава, чтобы слои надежно соединялись, плотность энергии лазера должна быть высокой. Примеры лазерных методов включают прямое лазерное спекание (DMLS) и селективное лазерное плавление (SLM). В отличие от этого, метод электронно-лучевого сплавления требует вакуумной среды для формирования объекта, где металлический порошок нагревается электронным лучом, аналогично роли лазера в SLM, создавая рисунок слой за слоем.

В исследовании [3] были изучены механические и трибологические свойства композитов $Al_2O_3/SS316L$, изготовленных с помощью лазерного сплав-

ления порошкового слоя (LPBF), и оптимизированы параметры процесса для улучшения свойств материала. Анализировались влияние высоты слоя, мощности лазера, скорости сканирования и содержания AlO_3 на характеристики композитов. Модель Gradient Boosting Decision Tree (GBDT) показала высокую точность предсказаний ($R^2 = 0,98$ для обучения и $0,93$ для тестирования). Оптимизация с использованием алгоритма SPEA2 выявила параметры, балансирующие прочность и износостойкость. Анализы SEM и EDS подтвердили, что равномерное распределение AlO_3 при 10 % массы улучшает прочность и износостойкость, тогда как 15 % массы приводит к ухудшению из-за кластеризации. Оптимизированные композиты продемонстрировали прочность на сжатие до 762 МПа, низкий износ (0,012 мг/км) и уменьшенный коэффициент трения (0,231). Это исследование предлагает структуру для оптимизации композитов, изготовленных методом LPBF, для применения в аэрокосмической, биомедицинской и автомобильной отраслях.

В работе [4] показано использование байесовского классификатора для обнаружения дефектов по слоям, достигая 89,5 % истинно положительных и 82 % истинно отрицательных рейтингов, что помогает корректировать параметры процесса.

Струйная обработка связующего (BJT) — это метод аддитивного производства (AM), который включает нанесение жидкого связующего на слои порошка для создания физических объектов путем многократного наложения слоев. Метод успешно адаптируется к различным типам порошков и обеспечивает высокую производительность. Процесс BJT включает осаждение порошка, методы печати, динамическое взаимодействие порошка и связующего, а также методики постобработки с широким спектром материалов, включая металлы, полимеры и керамику. Однако оптимизация производительности деталей остается сложной задачей, требующей идентификации и контроля ключевых параметров для улучшения входно-выходных соотношений и повышения общей эффективности процесса.

В исследовании [5] оптимизировались параметры 3D-печати сплава 2024Al, используя модель искусственной нейросети (ANN). Были проанализированы влияния толщины слоя и разрешения на относительную плотность, изменение размеров и прочность на сжатие напечатанных изделий. Для ограниченного набора данных модель оказалась оптимальным инструментом прогнозирования процесса печати, достигнув значения R^2 , превышающего 0,92. Анализ показывает, что разрешение оказывает наибольшее влияние на качество детали, за которым следует насыщение связующим. Оптимальными параметрами печати, полученными из модели ANN, являются толщина слоя 0,06 мм, разрешение 1000800 и насыщение связующим 35,42 %, что предсказывает относительную плотность 68,98 %, при этом печать в атмосфере N_2 , $T = 600$ °C, значения относительной плотности увеличиваются до ≈ 90 %. Эти оптимизированные параметры близко совпадают с экспериментальными результатами, подтверждая высокую точность прогнозирования модели ANN. Это подчеркивает эффективное применение машинного обучения для опти-

мизации процесса струйной подачи связующего (BJT) для сплава 2024Al и помогает в определении оптимальных параметров печати.

Струйная печать материалов (MJT) — это широко используемый метод аддитивного производства (AM), известный своей способностью создавать сложные структуры из нескольких материалов с высокой точностью размеров и гладкой поверхностью. Этот процесс, напоминающий работу струйного принтера, часто использует УФ-отверждаемые чернила и может применять такие материалы, как воск, для поддержки. MJT классифицируется на два типа: Continuous InkJet (CIJ) и Droplet-on-Demand (DoD), основываясь на методе дозирования капель.

В проведенных исследованиях [6] показано использование Multi-Material Jetting (MMJ), для достижения повышения повторяемости качества деталей в точном процессе аддитивного производства для керамики и твердых металлов. Несмотря на свои преимущества, MMJ сталкивается с проблемами постоянного качества из-за большого разнообразия стратегий сборки. Влияние параметризации перекрытия капель на дефекты качества, подчеркивает необходимость в передовых методах обеспечения качества. Исследование изучает автоматизированную классификацию адекватности параметризации процесса с использованием линейных измерений поверхности, обработанных с помощью машинного обучения, в частности сверточных нейронных сетей (CNN). Обучающие данные были получены путем печати демонстрационной детали с восемью слоями при различных настройках перекрытия, которые затем были отсканированы и помечены инженерами-технологами. Модели CNN с двумя сверточными слоями и размером пула (6, 6) достигли наивысшей точности. Примечательно, что модели, обученные с изображениями только первого слоя, без учета края заполнения, достигли точности проверки 90 %. Это свидетельствует о том, что анализ произвольного участка первого слоя достаточен для прогнозирования качества последующих слоев, что обеспечивает перспективный подход к обеспечению качества в MMJ.

Кроме того, в работе [7] выполнена оценка морфологии капель с использованием сверточной сети тензорных графов (TGCN) для фиксации перекрестно-связанных и пространственных отношений TTS и тензорную рекуррентную нейронную сеть (TRNN) для фиксации временных отношений. Характеристики, извлеченные из TGCN и TRNN, затем обрабатываются многослойным персептроном (MLP) для прогнозирования будущего поведения капель.

Методология проверена как с помощью имитированных (модели на основе физики), так и экспериментальных (наблюдение за печатью MJ с помощью системы машинного зрения) видео эволюции капель. Он демонстрирует способность точно и эффективно прогнозировать поведение капель как для известных (прогнозирование будущих времен), так и для неизвестных (прогнозирование новой последовательности) параметров материалов и процессов, демонстрируя его потенциал для улучшения последовательности и качества процесса MJ.

Направленное энергетическое осаждение (DED), также известное как лазерное формование сетки, лазерное твердотельное формование (LSF), направленное световое изготовление (DLF), электронно-лучевое аддитивное производство (EBAM), прямое осаждение металла (DMD) и проволоочно-дуговое АМ (WAAM), представляет собой категорию методов аддитивного производства (AM). В DED исходный материал, будь то в виде порошка или проволоки, плавится с использованием источника энергии, чаще всего лазера, но также возможно использование электронного луча или дуги. Процесс повторяется до тех пор, пока не будет создана вся деталь, путем нанесения и затвердевания расплавленного материала в нужных местах.

В работе [8] выполнен контроль развития микроструктуры в аддитивном производстве металлов, сосредоточившись на процессе лазерного сплавления порошкового слоя (LPBF). Метод объединяет физические тепловые модели и машинное обучение для прогнозирования ключевых характеристик микроструктуры, таких как глубина расплава и расстояние между первичными дендритными рукавами в деталях из сплава никеля 718. Эти характеристики важны для определения функциональных свойств, включая предел текучести и усталостную долговечность. Применение интегрированного подхода, сочетающего быстрые тепловые модели и обученные модели машинного обучения, позволяет сократить время разработки и добиться стабильных свойств деталей. Для демонстрации эффективности, на другом наборе образцов, данный метод показал интервал между первичными дендритическими ветвями со среднеквадратической ошибкой в ≈ 110 нм (рис. 1).




Рис. 1. Первичное дендритное расстояние между плечами (λ_1) в шести различных местах, которые используются для подтверждения переносимости моделей машинного обучения. Наблюдаемые PDAS (λ_1) варьировались от малых до больших в зависимости от способа обработки [8]

Данная работа демонстрирует потенциал и будущее для физической оптимизации и контроля развития структуры в LPBF.

Экструзия материалов (МЕХ) — это универсальный метод аддитивного производства (АМ), при котором трехмерная структура формируется путем послойного дозирования материалов через сопло на поверхность. Этот метод использует различные полимеры и полимерные композиты в качестве исходного сырья, обеспечивая широкий выбор материалов.

Материалы в полутвердом состоянии непрерывно выдавливаются из сопла, и по мере их затвердевания они связываются с предыдущими слоями, постепенно формируя твердую структуру. Свойства деталей, изготовленных с помощью МЕХ, зависят от конструкции детали и параметров процесса. Первоначально применявшийся для быстрого прототипирования, МЕХ теперь используется для производства прочных и функциональных деталей конечного использования в таких секторах, как аэрокосмическая, автомобильная и биомедицинская промышленность, что подчеркивает его растущую значимость в современном производстве.

В работе [9] представлен краткий обзор приложений мониторинга в рамках метода МЕХ и рассмотрели альтернативные датчики, которые можно эффективно использовать для мониторинга процесса в реальном времени. Кроме того, в статье рассматривается использование наборов данных, полученных из процесса МЕХ, для разработки модели на основе машинного обучения, направленной на прогнозирование механических свойств биологических каркасов. Алгоритм регрессора градиентного усиления использовался для прогнозирования прочности на сжатие в биологических каркасах, и предложенная модель достигла замечательной точности в 99 % (рис. 2).




Рис. 2. Тренировочные результаты алгоритма градиентного ускорения регрессии (GBR) [9]

В работе [10] показана разработка структуры XAI, использующую модель DNN с нулевым смещением для обнаружения дефектов в реальном времени во время процесса АМ, демонстрируя возможность обнаружения нескольких типов дефектов с высокой точностью без предварительного обучения на дефектных данных.

Можно выделить другое исследование [11], в котором рассмотрена оптимизация процесса производства постоянных магнитов, в частности анизотропных магнитов Nd-Fe-B, что требует точной настройки таких элементов микроструктуры, как размер зерен, кристаллографическая ориентация и формирование межзеренной фазы для достижения высокой коэрцитивной силы.

При фиксированном составе сырья использовалось активное обучение с поддержкой методов машинного обучения и байесовской оптимизации (ALMLBO) для прогнозирования магнитных свойств на основе параметров процесса. Подход ALMLBO помогает определить оптимальные условия, которые обеспечивают высокую коэрцитивную силу ($\mu_0 H_c - 1.7\text{T}$) и остаточную намагниченность ($\mu_0 B_r - 1.4\text{T}$) в магнитах, изготовленных методом прямого горячего экструдирования, что приводит к впечатляющему максимальному энергетическому произведению $(BH)_{\max} - 380\text{ кДж/м}^3$. Полученные результаты показывают, что конвейер ALMLBO является эффективным инструментом для оптимизации процесса производства анизотропных магнитов Nd-Fe-B, повышая как коэрцитивную силу, так и остаточную намагниченность.

Заключение. В рассматриваемых работах подтвержден значительный потенциал интеграции искусственного интеллекта и машинного обучения в процессы аддитивного производства. Анализ применения ИИ в различных технологиях АМ, таких как фотополимеризация в ванне (VPP), спекание порошка (PBF), струйная подача связующего (BJT), струйная подача материала (MJT), направленное энергетическое осаждение (DED) и экструзия материала (MEX), выявил возможности для значительного повышения производственной эффективности и качества продукции. Внедрение ИИ позволяет оптимизировать параметры печати, улучшить прогнозирование дефектов и обеспечить стабильно высокое качество продукции. Это особенно актуально для аэрокосмической и автомобильной отраслей, где точность и надежность имеют решающее значение. Все текущие результаты исследований и состояние современных тенденций в развитии машинного обучения и необходимости адаптации аэрокосмического и автомобильного производств демонстрирует высокий потенциал для дальнейшего исследования, развития и разработки технологий АМ и создания инновационных производственных решений. Все вышеперечисленные факторы способны привести к созданию новых производственных методик, которые не только улучшат текущие процессы, но и позволят разработать новые продукты и технологии. Это подчеркнет важность адаптации и внедрения современных ИИ-технологий в производственные процессы для достижения устойчивого промышленного роста и инноваций.

СПИСОК ИСТОЧНИКОВ

- [1] Sattari K., Wu Y., Chen Z., Mahjoubnia A., Su Ch., Lin J. Physics-constrained multi-objective bayesian optimization to accelerate 3D printing of thermoplastics. *Additive Manufacturing*, 2024, vol. 86. <https://doi.org/10.1016/j.addma.2024.104204>
- [2] Lestari D.M., Chen P.-Ch., Li Jr.Sh., Shen W.-Y., Rapidly and precisely fabricating solid micro-needle by integrating vat photopolymerization and machine-learning (VP-ML). *Journal of Manufacturing Processes*, 2025, vol. 141. <https://doi.org/10.1016/j.jmapro.2025.02.042>
- [3] Hariharasakthisudhan P., Imteaz N., Logesh K., Safa A., Kannan S., Vijayavenkataraman S., Susantyoko R. Optimization of Al₂O₃/SS316L composites fabricated via laser powder bed fusion using machine learning and multi-objective optimization. *Materials Today Communications*, 2025, vol. 44. <https://doi.org/10.1016/j.mtcomm.2025.112098>
- [4] Aminzadeh M., Kurfess T.R. Online quality inspection using Bayesian classification in powder-bed additive manufacturing from high-resolution visual camera images. *J. Intell. Manuf.*, 2019, vol. 30 (6), pp. 2505–2523. <https://doi.org/10.1007/s10845-018-1412-0>
- [5] Qian Y., Luo X., Wei Q., Huang B., Fan Zh., Huang R., Zhang L., Kurapova O.Yu., Konakov V.G. Printing parameters optimization assisted by machine learning and sintering behavior of binder jetting 3D printed Al alloy. *Journal of Materials Research and Technology*, 2025, vol. 35. <https://doi.org/10.1016/j.jmrt.2025.02.217>
- [6] Reckert A., Lang V., Weingarten S., Robert John, Jan-Hendrik Klein, Steffen Ihlenfeldt, Quality Prediction and Classification of Process Parameterization for Multi-Material Jetting by Means of Computer Vision and Machine Learning. *J. Manuf. Mater. Process*, 2024, vol. 8 (1), art. no. 8. <https://doi.org/10.3390/jmmp8010008>
- [7] Segura L.J., Li Z., Zhou C., Sun H. Droplet evolution prediction in material jetting via tensor time series analysis. *Additive Manufacturing*, 2023, art. no. 103461. <https://doi.org/10.1016/j.addma.2023.103461>
- [8] Riensche A.R., Bevans B.D., King G., Krishnan A., Cole K.D., Rao P. Predicting melt pool depth and primary dendritic arm spacing in laser powder bed fusion additive manufacturing using physics-based machine learning. *Materials & Design, January*, 2024, vol. 237. <https://doi.org/10.1016/j.matdes.2023.112540>
- [9] Tartici I., Bartolo P. *Exploring Materials Extrusion in 3D Printing: real-time monitoring, and machine learning for predicting mechanical properties*, 2024, vol. 130. <https://doi.org/10.1016/j.procir.2024.10.060>
- [10] Kumar D., Liu Y., Song H., Namilae S. Explainable deep neural network for in plain defect detection during additive manufacturing. *RPJ*, 2024, vol. 30 (1), pp. 49–59. <https://doi.org/10.1108/RPJ05-2023-0157>
- [11] Lambard G., Sasaki T.T., Sodeyama K., Ohkubo T., Hono K. Optimization of direct extrusion process for Nd-Fe-B magnets using active learning assisted by machine learning and Bayesian optimization. *Scripta Materialia*, 2022, vol. 209. <https://doi.org/10.1016/j.scriptamat.2021.114341>