

Солонченко М.Е., Луценко О.В.

Белгородский государственный технологический университет им. В.Г. Шухова, г. Белгород, Россия

РАЗРАБОТКА СИСТЕМЫ ОПЕРАТИВНОГО КОНТРОЛЯ И ОБЕСПЕЧЕНИЯ КАЧЕСТВА ИЗДЕЛИЙ, ПОЛУЧЕННЫХ МЕТОДОМ АДДИТИВНОГО ПРОИЗВОДСТВА (DMLS) С ИСПОЛЬЗОВАНИЕМ КОМПЬЮТЕРНОГО ЗРЕНИЯ И МАШИННОГО ОБУЧЕНИЯ

Аннотация: *С ростом внедрения аддитивного производства, в частности прямого лазерного спекания металлов (DMLS), в высокотехнологичных отраслях промышленности обеспечение стабильного и предсказуемого качества продукции становится важнейшей задачей. Существующие методы контроля, в основном постпроцессные, не позволяют эффективно предотвращать дефекты в режиме реального времени. В данной работе предлагается концепция интегрированной системы операционного контроля качества изделий DMLS. Система основана на сборе высокочастотных сенсорных данных (визуальных, тепловых) в процессе формирования каждого слоя, их последующей интеллектуальной обработке с использованием компьютерного зрения и машинного обучения для автоматического обнаружения аномалий, классификации дефектов и прогнозирования качества. Обоснован потенциал данного подхода для перехода к проактивному управлению качеством, снижению дефектов и оптимизации производственных циклов.*

Ключевые слова: *Аддитивное производство, DMLS, управление качеством, оперативный контроль, компьютерное зрение, машинное обучение, предиктивное качество.*

Solonchenko M.E., Lutsenko O.V.

Belgorod State Technological University named after V.G. Shukhov, Belgorod, Russia

DEVELOPMENT OF A SYSTEM FOR OPERATIONAL CONTROL AND QUALITY ASSURANCE OF PRODUCTS PRODUCED BY ADDITIVE MANUFACTURING (DMLS) USING COMPUTER VISION AND MACHINE LEARNING

Abstract: *With the increasing adoption of additive manufacturing, in particular direct laser sintering of metal (DMLS), in high-tech industries, ensuring stable and predictable product quality is becoming an important task. Existing control methods, mainly post-process, do not allow effective prevention of defects in real time. In this paper, the concept of an integrated system of operational quality control of DMLS products is proposed. The system is based on the collection of high-frequency sensory data (visual, thermal) during the formation of each layer, their subsequent intelligent processing using computer vision and machine learning to automatically detect anomalies, classify defects and predict quality. The potential of this approach for the transition to proactive quality management, defect reduction and optimization of production cycles is substantiated.*

Keywords: *Additive manufacturing, DMLS, quality management, operational control, computer vision, machine learning, predictive quality.*

Введение

Аддитивное производство (АМ), особенно прямое лазерное спекание металлов (DMLS), является парадигмой производства, способной создавать сложные геометрии с уникальными функциональными свойствами. Ее активное внедрение в критических отраслях, таких как аэрокосмическая и медицинская промышленность, подчеркивает актуальность проблемы обеспечения бескомпромиссного качества продукции [1, 2].

Цель исследования - концептуальное обоснование и описание архитектуры системы оперативного контроля и обеспечения качества изделий, полученных методом аддитивного производства (DMLS), базирующейся на применении компьютерного зрения и машинного обучения, с целью обеспечения проактивного управления качеством и повышения эффективности производственного процесса.

Процесс DMLS чрезвычайно чувствителен ко многим переменным, включая параметры лазера, характеристики порошка и условия окружающей среды, что приводит к широкому спектру потенциальных дефектов: от пористости и несплавления до коробления и геометрических отклонений [3]. Традиционные подходы к контролю качества в АМ в основном сосредоточены на постпроцессном контроле (рентгеновский, ультразвуковой контроль), который, хотя и эффективен в обнаружении, не способен предотвратить дефекты и обеспечить оперативную обратную связь. Это приводит к значительным потерям времени и средств из-за высокого уровня брака и длительных циклов отладки процесса [4]. В контексте концепции Industry 4.0 существует острая необходимость перехода от реактивного контроля к проактивному, предиктивному управлению качеством, что возможно благодаря использованию передовых цифровых технологий [5]. Целью данной статьи является концептуальное обоснование и описание архитектуры системы контроля и обеспечения качества для изделий DMLS на основе компьютерного зрения (CV) и машинного обучения (ML). Такая система позволит осуществлять непрерывный мониторинг процесса печати, выявлять аномалии в реальном времени и прогнозировать качество конечного продукта.

Принципы оперативного контроля качества DMLS и архитектура системы

Эффективная система контроля качества в DMLS должна иметь возможность анализировать процесс на каждом этапе формирования слоя, выявляя отклонения, которые могут привести к дефектам. Это достигается путем интеграции оборудования сбора данных с интеллектуальными программными модулями. Предлагаемая система включает три ключевых функциональных блока: сбор и предварительную обработку данных, интеллектуальный анализ данных и принятие решений с обратной связью.

Основой системы является высокочувствительный и высокоскоростной сбор данных непосредственно с рабочей зоны установки DMLS. Основными источниками информации являются высокоскоростные камеры, предназначенные для визуализации динамики ванны расплава, включая ее размер, форму, устойчивость, а также обнаружения брызг и неровностей поверхности формирующегося слоя [6, 7]. Дополнительно пирометры или тепловизоры используются для измерения температурного поля расплавленной ванны и окружающего порошка, что позволяет выявлять аномалии нагрева, связанные с дефектами, такими как перегрев или недостаточная энергия [6]. Датчики акустической эмиссии или вибрации могут быть интегрированы для обнаружения микротрещин или неполного сплавления, которые могут генерировать характерные акустические сигналы [8]. Кроме того, система получает системные параметры установки, такие как мощность лазера, скорость сканирования, температура камеры и давление инертного газа, непосредственно с контроллера установки. Все эти исходные данные проходят предварительную обработку, которая для изображений включает калибровку, нормализацию, коррекцию искажений и сегментацию интересующей области, а для всех типов данных - удаление шумов и временную синхронизацию. Предварительно обработанные данные подаются в модуль интеллектуального анализа, где с помощью методов компьютерного зрения и машинного обучения извлекаются значимые признаки, позволяющие оценивать состояние процесса и прогнозировать качество. Из визуальных данных могут быть извлечены геометрические (площадь, периметр расплавленной ванны), текстурные (шероховатость поверхности слоя) и аномальные признаки (наличие брызг, пор). Температурная стабильность и наличие «горячих» или «холодных» точек могут быть извлечены из температурных данных. Эти характеристики вместе с параметрами процесса формируют входной вектор для моделей машинного обучения. Различные алгоритмы машинного обучения используются для интеллектуального анализа. Таким образом, сверточные нейронные сети (CNN) идеально подходят для автоматического распознавания

образов и классификации дефектов на основе изображений расплавленной ванны и поверхности слоя (например, «нормальный», «пористость», «отсутствие сплавления») [7, 9]. Регрессионные модели обучаются прогнозировать показатели качества конечного продукта (например, плотность, прочность) на основе комбинации параметров процесса и характеристик [8], в то время как специализированные алгоритмы обнаружения аномалий идентифицируют нетипичные состояния процесса, которые могут указывать на потенциальные проблемы. Обучение этих моделей основано на больших, предварительно маркированных наборах данных как из лабораторных, так и из производственных испытаний.

На основе результатов интеллектуального анализа система формирует управляющие воздействия, обеспечивающие проактивное управление качеством. При обнаружении или прогнозировании критического дефекта система немедленно информирует об этом оператора, указывая тип и место аномалии. В некоторых случаях, например, при локальных изменениях мощности лазера или скорости сканирования в допустимых пределах, система может автономно корректировать параметры процесса для минимизации риска возникновения дефекта.

При обнаружении неустранимого критического дефекта система способна приостановить или остановить процесс печати, предотвращая дальнейшие потери материала и времени. Также критически важно фиксировать все данные о процессе, обнаруженных аномалиях и принятых решениях, что создает цифровую историю каждого слоя изделия, необходимую для сертификации и прослеживаемости.

Ожидаемые преимущества и вызовы внедрения

Внедрение предлагаемой системы оперативного контроля качества DMLS сулит ряд принципиальных преимуществ. Во-первых, это переход к проактивному управлению качеством, позволяющему предотвращать дефекты, а не просто констатировать их. Во-вторых, это приводит к существенному сокращению брака и, как следствие, снижению себестоимости продукции. В-третьих, система позволяет ускорить цикл разработки за счет мгновенной обратной связи. Наконец, она улучшает повторяемость и воспроизводимость процесса, что критично для масштабирования производства и сертификации продукции, а также минимизирует риски выпуска продукции с дефектами, особенно для критических компонентов.

Однако реализация такого комплексного подхода сопряжена с рядом сложностей. Прежде всего, это необходимость обработки и хранения огромных объемов мультимодальных данных в режиме реального времени, что требует высокопроизводительных вычислительных мощностей. Еще одной значимой задачей является создание качественных и достаточно больших размеченных наборов данных для обучения моделей машинного обучения. Интеграция новых датчиков и интеллектуальных модулей с существующими фирменными системами управления установками DMLS также затруднена. Кроме того, необходимо обеспечить высокую точность и надежность алгоритмов МО, а также их валидацию в реальных промышленных условиях. Разработка и внедрение системы операционного контроля и обеспечения качества изделий, полученных методом DMLS с использованием компьютерного зрения и машинного обучения, является одним из ключевых направлений развития аддитивного производства.

Заключение

Предложенная концепция преодолевает ограничения традиционных методов контроля, обеспечивая непрерывную оценку качества и проактивное предотвращение дефектов. Несмотря на технологические и организационные сложности, потенциальные выгоды в виде значительного сокращения дефектов, сокращения производственных циклов и повышения надежности продукции делают такие системы стратегически важными для машиностроительных компаний.

Дальнейшие исследования и разработки должны быть сосредоточены на практической реализации и масштабировании данной концепции, а также на разработке интерпретируемых

моделей искусственного интеллекта, способных обосновывать свои решения, что является предпосылкой для полного доверия к автоматизированным системам контроля качества.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Луценко О.В. Об оценке эффективности внедрения метода «аутсорсинг» / О.В. Луценко, Д.А. Комаренко // Актуальные вопросы и перспективы развития науки, техники и технологии: материалы Международной научно-практической конференции. – Казань, 2020. – С. 103-109.
2. Wohlers T., Gornet P. Wohlers Report 2020: 3D Printing and Additive Manufacturing State of the Industry. – [Fort Collins, CO] : Wohlers Associates, 2020. – [X] с.
3. Additive manufacturing of metals / D. Herzog, M. Seyda, E. Wycisk, C. Emmelmann // Acta Materialia. – 2016. – Vol. 117. – P. 371–392.
4. Additive manufacturing of metals: With an eye toward the next frontier / T. DebRoy [и др.] // Journal of Manufacturing Science and Engineering. – 2018. – Vol. 140, no. 5. – P. 051011.
5. Artificial intelligence and digital twin for smart manufacturing quality control: A review / L. Wang, R. Li, H. Lv // International Journal of Production Research. – 2021. – Vol. 59, no. 12. – P. 3601–3618.
6. Review of in-situ process monitoring and in-situ metrology for metal additive manufacturing / S. K. Everton [и др.] // Materials & Design. – 2016. – Vol. 95. – P. 431–445.
7. Anomaly detection in melt pool imagery from additive manufacturing via a convolutional neural network / L. Scime, J. Beuth // The International Journal of Advanced Manufacturing Technology. – 2018. – Vol. 95. – P. 1229–1241.
8. Prediction of melt pool dimensions in selective laser melting via a random forest algorithm / G. Tapia, A. Elwany // Journal of Manufacturing Science and Engineering. – 2014. – Vol. 136, no. 6. – P. 061017.
9. Deep Learning for Industrial Visual Inspection: A Survey / Y. Luo, X. Li // IEEE Transactions on Industrial Informatics. – 2020. – Vol. 16, no. 2. – P. 779–792.

REFERENCES

1. Lutsenko O.V. On the evaluation of the effectiveness of the implementation of the outsourcing method / O.V. Lutsenko, D.A. Komarenko // Current issues and prospects for the development of science, technology and technology: proceedings of the International Scientific and Practical Conference. – Kazan, 2020. – pp. 103-109.
2. Wohlers T., Gornet P. Wohlers Report 2020: 3D Printing and Additive Manufacturing State of the Industry. – [Fort Collins, CO] : Wohlers Associates, 2020. – [X] с.
3. Additive manufacturing of metals / D. Herzog, M. Seyda, E. Wycisk, C. Emmelmann // Acta Materialia. – 2016. – Vol. 117. – P. 371–392.
4. Additive manufacturing of metals: With an eye toward the next frontier / T. DebRoy [и др.] // Journal of Manufacturing Science and Engineering. – 2018. – Vol. 140, no. 5. – P. 051011.
5. Artificial intelligence and digital twin for smart manufacturing quality control: A review / L. Wang, R. Li, H. Lv // International Journal of Production Research. – 2021. – Vol. 59, no. 12. – P. 3601–3618.
6. Review of in-situ process monitoring and in-situ metrology for metal additive manufacturing / S. K. Everton [и др.] // Materials & Design. – 2016. – Vol. 95. – P. 431–445.
7. Anomaly detection in melt pool imagery from additive manufacturing via a convolutional neural network / L. Scime, J. Beuth // The International Journal of Advanced Manufacturing Technology. – 2018. – Vol. 95. – P. 1229–1241.
8. Prediction of melt pool dimensions in selective laser melting via a random forest algorithm / G. Tapia, A. Elwany // Journal of Manufacturing Science and Engineering. – 2014. – Vol. 136, no. 6. – P. 061017.
9. Deep Learning for Industrial Visual Inspection: A Survey / Y. Luo, X. Li // IEEE Transactions on Industrial Informatics. – 2020. – Vol. 16, no. 2. – P. 779–792.

Информация об авторах

Солонченко Михаил Евгеньевич – студент второго курса магистратуры кафедры «Управление качеством», Белгородский государственный технологический университет им. В.Г. Шухова, г. Белгород, e-mail: solonchenko.01@mail.ru

Луценко Оксана Витальевна – к. т. н., доцент кафедры «Стандартизация и управление качеством», Белгородский государственный технологический университет им. В.Г. Шухова, г. Белгород, e-mail: lucenko_67@mail.ru

Information about the authors

Solonchenko Mikhail Evgenievich – second-year master's student of the Department of Quality Management, Belgorod State Technological University named after V.G. Shukhov, Belgorod, e-mail: solonchenko.01@mail.ru

Lutsenko Oksana Vitalievna – PhD, Associate Professor of the Department of Standardization and Quality Management, Belgorod State Technological University named after V.G. Shukhov, Belgorod, e-mail: lucenko_67@mail.ru