

Математическая модель прогнозирования предела прочности сплава AlSi10Mg, изготовленного аддитивным способом, с использованием искусственных нейронных сетей

*Шривастава Сунита К.*¹*, научный сотрудник кафедры машиностроения
Мативанан Н. Раджееш², кандидат наук,
профессор кафедры машиностроения

Общественный университет народного просвещения, Бангалор (Индия)

*E-mail: sunita.shri45@gmail.com

¹ORCID: <https://orcid.org/0009-0005-2174-2067>

²ORCID: <https://orcid.org/0000-0003-1903-2005>

Поступила в редакцию 10.09.2024

Пересмотрена 29.10.2024

Принята к публикации 25.11.2024

Аннотация: Внедрение машинного обучения в аддитивное производство для моделирования реальных результатов может значительно снизить его стоимость за счет селективного производства. В настоящее время существует недостаточно исследований, посвященных разработке модели прогнозирования механических свойств материала. Входные переменные предложенной модели включали ключевые параметры процесса селективной лазерной плавки, такие как мощность лазера, толщина слоя, скорость сканирования и шаг штриховки, на выходе получая предел прочности. Математическая модель на основе искусственной нейронной сети сравнивалась с моделью полиномиальной регрессии второй степени. Надежность обеих моделей дополнительно оценивалась с новыми наборами данных, отличных от тех, которые использовались при разработке математической модели на основе искусственной нейронной сети и модели регрессии. Результаты показали, что предложенная математическая модель на основе искусственной нейронной сети обеспечивает превосходную точность: при прогнозировании прочности сплава AlSi10Mg среднее абсолютное процентное отклонение (MAPE) составило 4,74 %, критерий соответствия $R^2=0,898$. Математический метод на основе искусственной нейронной сети также показал высокую производительность на новых данных – значение регрессии достигало 0,68. Таким образом, разработанную модель возможно рассматривать как перспективный вариант для прогнозирования предела прочности материала.

Ключевые слова: сплав AlSi10Mg; аддитивное производство; искусственная нейронная сеть (ИНС); машинное обучение; селективная лазерная плавка; математическая модель.

Для цитирования: Шривастава С.К., Мативанан Н.Р. Математическая модель прогнозирования предела прочности сплава AlSi10Mg, изготовленного аддитивным способом, с использованием искусственных нейронных сетей // Frontier Materials & Technologies. 2025. № 1. С. 93–110. DOI: 10.18323/2782-4039-2025-1-71-8.

ВВЕДЕНИЕ

Аддитивное производство на протяжении нескольких десятилетий оставалось краеугольным камнем промышленных инноваций и было адаптировано для обработки различных материалов, включая металлы, сплавы, полимеры, композиты и т. д. Чтобы соответствовать производственным требованиям, оно предлагает различные технологии, такие как разбрызгивание связующего вещества, наплавка, спекание или наплавление порошков, послойное ламинирование, струйная 3D-печать и т. д. Производство металлов и композитов в основном выполняется путем селективной лазерной плавки и лазерного осаждения металла. Аддитивное производство является предпочтительной технологией производства алюминиевых сплавов и алюминиевых композитов с металлической матрицей за счет его способности обеспечивать большую точность, меньшее время обработки, экономическую эффективность и лучшее качество деталей по сравнению с традиционными методами получения этого материала [1]. Тем не менее лазерная плавка чистого алюминия сопряжена с трудностями из-за его высокой отражательной спо-

собности, поглощающей только 7 % падающей лазерной энергии. Напротив, кремний имеет высокую поглощательную способность лазерного излучения – около 70 %, что делает алюминиево-кремниевые сплавы идеальным кандидатом для селективной лазерной плавки [2]. Среди алюминиево-кремниевых сплавов AlSi10Mg выделяется как чрезвычайно перспективный за счет своих хороших механических свойств в сочетании с малой плотностью. Сплав очень популярен в автомобильной и аэрокосмической промышленности благодаря своим исключительным механическим свойствам и высокой теплопроводности.

Параметры селективной лазерной плавки, такие как мощность лазера, толщина слоя, скорость сканирования, шаг процесса сканирования поверхности (шаг штриховки) и т. д., оказывают значительное влияние на свойства материала, которые можно регулировать для получения оптимального результата. Например, плотность полученного материала можно контролировать, изменяя поток лазерной энергии, в котором объединены все четыре параметра процесса (мощность лазера, толщина слоя, скорость сканирования и шаг штриховки). Регулировка

помогает достичь желаемых механических свойств металла, таких как прочность на растяжение, прочность на сжатие, твердость и микротвердость и т. д. [3].

Машинное обучение, в частности искусственный интеллект, играет важную роль в создании модели/системы, поскольку обеспечивает обучение на основе предоставленных данных и повышает ее точность без дополнительного написания программного кода [4].

Искусственная нейронная сеть (ИНС), реализуя один из вариантов глубокого обучения, имитирует принцип работы человеческого мозга. В ее архитектуре присутствуют взаимосвязанные узлы, которые имитируют биологические нейроны. Архитектура ИНС состоит из входных слоев (содержащих независимые переменные), скрытых слоев (содержащих одну или несколько переменных) и выходных слоев (содержащих зависимые переменные). Каждый узел слоя соединен со следующим набором узлов через веса, смещения и передаточную функцию для отправки сигнала. ИНС использует обучающие данные для установления связи между входом и выходом. Она обучается и настраивает точность модели с помощью итеративного обучения, что делает ее очень мощным инструментом в области искусственного интеллекта [5]. Базовая архитектура ИНС, использованная в этом исследовании, представлена на рис. 1.

Эта модель может использоваться для поиска неизвестных или оптимальных решений путем анализа влияния входных параметров на результат. Однако исследований в этой области проведено недостаточно.

В работе [6] проанализировали шесть различных моделей машинного обучения: глубокое обучение, пакетирование, дерево решений, линейную регрессию, случайный лес и гребневую регрессию, чтобы оценить влияние производственных параметров, таких как мощность лазера, скорость сканирования, пространство сканирования и размер зоны, на предел прочности сплава AlSi10Mg. Был сделан вывод, что деревья решений и глубокое обучение имеют точность прогнозирования до 89 и 99 % соответственно. Мощность лазера оказалась наиболее влияющим параметром среди четырех рассмотренных. В исследовании [7] машинное обучение использовали для оптимизации параметров сварки трением с перемешиванием алюминиевых пластин. Рассматриваемыми входными параметрами сварки являются скорость вра-

щения инструмента, скорость сварки, диаметр кромки инструмента и осевое усилие. Была разработана модель ИНС с использованием алгоритма обратного распространения для прогнозирования предела прочности при заданных параметрах процесса. Результаты показали хорошее соответствие модели экспериментальным значениям и могут быть использованы в качестве альтернативного способа расчета предела прочности.

В [8] разработана модель ИНС на основе экспериментальных данных сплава Al-Si, изготовленного методом литья с перемешиванием. Модель применялась для прогнозирования влияния содержания кремния на предел прочности, твердость и потерю на износ. Результаты показали, что прогнозируемые значения удовлетворительно согласуются с экспериментальными данными, среднеквадратическая погрешность равна 0,0335, 0,0023 и 0,014 для испытаний на растяжение, твердость и потерю на износ соответственно. В [9] прогнозировали качество детали, включая оценку относительной плотности, шероховатости поверхности и твердости в зависимости от мощности лазера, расстояния между штрихами, скорости сканирования и толщины слоя сплава AlSi10Mg, изготовленного методом селективной лазерной плавки. Для сравнения результатов использовались пять различных алгоритмов контролируемого обучения: ИНС, регрессия опорных векторов, гребневая регрессия ядра, случайный лес и регрессия Лассо. По результатам сравнения ИНС превзошла другие модели. Кроме того, мощность лазера и скорость сканирования оказались параметрами, наиболее влияющими на относительную плотность и твердость, в то время как толщина слоя и скорость сканирования больше всего влияют на шероховатость поверхности.

Учитывая ограниченное количество существующих исследований, нами разработан новый подход к внедрению математической модели на основе ИНС и регрессионной модели для прогнозирования предела прочности сплава AlSi10Mg, изготовленного аддитивным способом (селективной лазерной плавкой), на основе имеющихся данных.

Основное внимание в исследовании уделяется установлению корреляции между пределом прочности и селективными параметрами лазерной плавки, такими как мощность лазера, толщина слоя, скорость сканирования




Рис. 1. Архитектура искусственной нейронной сети
Fig. 1. Architecture of an artificial neural network

и шаг штриховки. Исследование дает ценную информацию об использовании модели машинного обучения для прогнозирования свойств материалов без необходимости проведения реальных экспериментов.

Цель исследования – уточнение прогноза и оптимизация свойств материала на основе экспериментальных данных для лучшего контроля производственного процесса с помощью надежной прогностической модели. Работа направлена на поддержку более экономичного и эффективного по времени подхода к оценке материалов.

МЕТОДИКА ПРОВЕДЕНИЯ ИССЛЕДОВАНИЯ

Сбор данных для ИНС и регрессионной модели

Входной набор данных для ИНС и регрессионных моделей был собран из существующей литературы для образца AlSi10Mg в исходном состоянии, полученного с помощью селективной лазерной плавки. Кроме того, был проведен дополнительный эксперимент в рамках сбора данных для модели ИНС. Модель ИНС и регрессионная модель разрабатывались с использованием 108 точек данных (Приложение 1), еще 27 точек данных (Приложение 2) использовались для оценки точности модели на случайной выборке. Прогнозируемые выходные данные модели сравнивались с экспериментальными значениями, указанными в литературе.

ИНС и регрессионная модель были реализованы с использованием MATLAB R2023b. В качестве входных переменных в модели использовались мощность лазера (P), толщина слоя (T), скорость сканирования (V) и шаг штриховки (H). Диапазон входных данных для модели ИНС был установлен следующий: мощность лазера 150–1000 Вт, толщина слоя 20–80 мкм, скорость сканирования 195–2400 мм/с, расстояние между штрихами 42–240 мкм.

Эксперимент

Для изготовления образцов использовался газораспыленный порошок AlSi10Mg со средним размером частиц 20–63 мкм, содержанием кремния до 10 % и следами магния и железа. Подробный состав порошка показан в таблице 1.

Образцы были изготовлены с использованием селективной лазерной плавки в принтере RenAM 500E (Великобритания). Основные параметры процесса: мощность лазера 275 Вт, толщина слоя 30 мкм, скорость сканирования 2000 мм/с, расстояние между штрихами 80 мкм. Камера печати была заполнена 99,999 % чистым аргоном для защиты от окисления порошка. Направление печати сохранялось горизонтальным. Слои ориентировались под углом 67° к предыдущему слою. Температура рабочей поверхности поддерживалась на уровне 80 °С, чтобы избежать расслоения из-за изменения температуры между нижним слоем и рабочей поверхностью.

Плоские образцы для испытаний на растяжение длиной 25 мм были изготовлены в соответствии со стандартом ASTM E8, как показано на рис. 2. Готовые образцы выдерживались без нагрузки при 300±10 °С в течение 2 ч и охлаждались воздухом.

Испытания на растяжение проводились на универсальной испытательной машине ETM (Wance, Китай) с максимальным усилием 50 кН при скорости деформации 1 мм/мин. Осевое смещение контролировалось с помощью встроенного в компьютер видеоэкстензометра, подключенного к испытательной машине, который в реальном времени фиксировал данные о растяжении для построения диаграммы «напряжение – деформация».

Предел текучести определялся методом смещения на 0,2 % с использованием Excel-диаграммы «напряжение – деформация». Сначала была определена линейная (упругая) область для определения наклона (модуля упругости). Затем была проведена линия, параллельная этой линейной области, проходящая через точку 0,2 % деформации (ось Y). Предел текучести определялся как точка, в которой линия смещения пересекала кривую «напряжение – деформация».

Предел текучести определялся методом смещения на 0,2 % с использованием Excel-диаграммы «напряжение – деформация». Сначала была определена линейная (упругая) область для определения наклона (модуля упругости). Затем была проведена линия, параллельная этой линейной области, проходящая через точку 0,2 % деформации (ось Y). Предел текучести определялся как точка, в которой линия смещения пересекала кривую «напряжение – деформация».

Разработка ИНС

Для реализации модели ИНС использовалось программное обеспечение MATLAB R2023b, настройка нейронной сети осуществлялась с использованием стандартных инструментов глубокого обучения. Для прогнозирования прочности материала использовался подход контролируемого машинного обучения. Обучение проводилось для 1000 эпох при четырех входных переменных (мощность лазера, толщина слоя, скорость сканирования и шаг штриховки) с двумя выходными (предел текучести и предел прочности).

Стоит отметить, что в нейронной сети используются две двухслойные конструкции прямого распространения. Входной и выходной слои используют гиперболическую тангенциальную (*tansig*) и линейную (*purelin*) функции активации соответственно, как показано на рис. 3.

Структура нейронной сети состояла из 10 нейронов в скрытых слоях и 2 нейронов, соответствующих выходным переменным. Конфигурация была выбрана исходя из требований к сложности и производительности модели. Скрытый слой предназначен для эффективного извлечения признаков из входных слоев. Общий подход к определению количества нейронов в скрытом слое заключался в удвоении количества нейронов во входном слое и добавлении нейронов в выходном слое¹.

Исходные данные случайным образом разбивались по трем категориям в соотношении 80:10:10: обучение, проверка и тестирование. Для обучения ИНС использовался алгоритм Левенберга – Марквардта (*trainlm*), который считается самым быстрым алгоритмом обратного распространения. Входные и выходные данные нормализовались между -1 и +1 с использованием уравнения (1) [10] для достижения совместимости размерности и совместимости с передаточной функцией *tansig*:

$$M_{norm} = \frac{2 \times (N_i - N_{min})}{N_{max} - N_{min}} - 1, \quad (1)$$

где M_{norm} – нормализованные параметры;
 N_i – фактические данные;
 N_{min} и N_{max} – минимальные и максимальные значения фактических данных соответственно.

¹ Livshin I. Artificial Neural Networks with Java: Tools for Building Neural Network Applications. Chicago, 2019. 575 p. DOI: [10.1007/978-1-4842-4421-0](https://doi.org/10.1007/978-1-4842-4421-0).

Таблица 1. Состав порошка AlSi10Mg
Table 1. Composition of AlSi10Mg powder

Элемент	Al	Si	Mg	Fe	N	O	Ti	Zn	Mn	Ni	Cu	Pb	Sn
Мас. %	Остальное	9–11	0,25–0,45	<0,25	<0,20	<0,20	<0,15	<0,10	<0,10	<0,05	<0,05	<0,02	<0,02




Рис. 2. Параметры образца: *a* – размеры; *b* – образец
Fig. 2. Sample details: *a* – sample dimension; *b* – fabricated sample

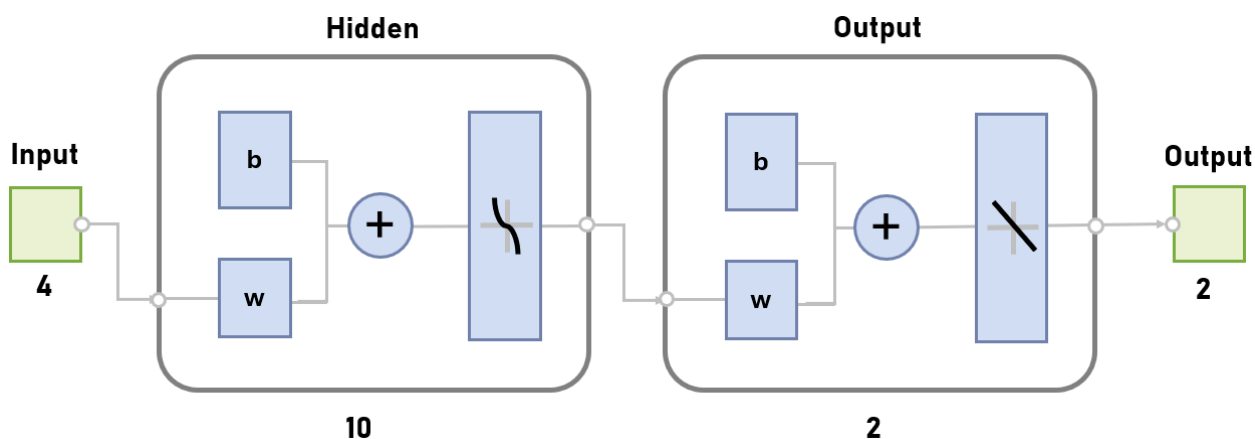


Рис. 3. Архитектура сети
Fig. 3. Network architecture

Анализ полиномиальной регрессии

С помощью MATLAB была построена модель многомерной полиномиальной регрессии для установления зависимостей между входными переменными (мощность лазера, толщина слоя, скорость сканирования и шаг штриховки) и выходной переменной (предел прочности). Для модели многомерной регрессии использовались те

же экспериментальные результаты, что и для разработки модели ИНС. Многомерная полиномиальная регрессия *fitlm* облегчает моделирование связей между несколькими входами и одним выходом. Модель вычисляет коэффициенты для каждого набора переменных и свободных членов. Она определяет влияние каждого предиктора на выходную переменную. Полином второй

степени вычислялся с использованием набора инструментов статистики и машинного обучения:

$$Y(X) = a_0 + \sum_{i=0}^N a_i X_i + \sum_{i<j}^N a_{ij} X_i X_j + \sum_{i=0}^N a_{ij} X_i^2, \quad (2)$$

где Y – ожидаемый отклик;

a_0 – свободный член;

$a_i X_i$ – линейные члены;

$a_{ij} X_i X_j$ – члены, характеризующие взаимодействие;

$a_{ij} X_i^2$ – члены второго порядка.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Результаты эксперимента

Испытания на растяжение образца, изготовленного методом селективного лазерного плавления, проводились в соответствии со стандартом ASTM E8. Результаты испытаний представлены в таблице 2. Во время испытаний на растяжение образец разрушался в направлении, перпендикулярном приложенной силе, как показано на рис. 4. Предел прочности образца составил 436,95 МПа при максимальной нагрузке 15,7 кН, наблюдалось удлинение на 9,59 %. Разрушение образца определялось как хрупкое, происходящее до того, как материал вошел в зону значимой локализации пластической деформации (рис. 5). Предел текучести $\sigma_{0,2}$ = 58 МПа.

Эффективность ИНС

Эффективность разработанной ИНС проверялась с использованием различных оценок и аналитических метрик. Полные выходные данные ИНС представлены в таблице 3.

График регрессии для общих данных обучения, тестирования и испытаний на предел текучести и предел прочности показан на рис. 6. По оси X представлены целевые (экспериментальные) данные, по оси Y – выходные данные, рассчитанные с помощью модели ИНС. Пунктирная линия иллюстрирует идеальную корреляцию, где фактические и расчетные значения равны, сплошная линия показывает фактическую (истинную) корреляцию между осями X и Y .

Коэффициент корреляции R для общих выходных данных обучения, проверки и испытаний составил 0,96, 0,94 и 0,91 соответственно. Общее значение коэффициента корреляции R составило 0,96, что показывает сильную корреляцию между фактическими (целевыми) и прогнозируемыми выходными данными.

Значение, при котором сходится среднеквадратическая ошибка между фактическими и расчетными значениями, можно считать наилучшим подтверждением эффективности. Алгоритм обратного распространения калибрует значения весов и смещений с каждой итерацией и генерирует наименьшее значение среднеквадратической ошибки. Количество эпох представляет собой количество итераций, выполняемых ИНС для минимизации целевой функции [11].

Изменение ошибки обучения в зависимости от эпохи представлено на рис. 7. Наилучшую эффективность модель демонстрирует на эпохе 44 при значении 0,024. Очевидно, что переобучения не происходит.

Аналогичные тенденции наблюдались для данных обучения, тестирования и проверки.

Разработка математической формулы на основе ИНС

После обучения модели ИНС ее можно перевести в математическое уравнение или модель путем интегрирования передаточной функции с использованием весов и смещений, как показано в уравнении [10]:

Таблица 2. Результаты испытаний на растяжение
Table 2. Tensile test results

Механические свойства	Значения
Предел текучести, МПа	58
Предел прочности, МПа	436,95
Удлинение, %	9,59
Максимальное значение силы, кН	15,73



Рис. 4. Разрушенный образец
Fig. 4. Fractured sample




Рис. 5. Диаграмма «напряжение – деформация»
 Fig. 5. Stress-strain diagram

Таблица 3. Выходные данные искусственной нейронной сети
 Table 3. Artificial neural network output

Выходные данные ИНС	Значение
Количество эпох	50
R – обучение	0,96
R – проверка	0,94
R – испытание	0,91
R – общее	0,96
Среднеквадратическая ошибка	0,0155

$$Y = b_0 + \sum_{k=1}^h \left(w_k \times f_{sig} \left(b_{hk} + \sum_{i=1}^m w_{ik} X_i \right) \right), \quad (3)$$

Следовательно, уравнение (3) можно преобразовать в уравнение [12]:

$$TS_n = -0.0825 + [W] \times [q]^T, \quad (4)$$

где Y – нормализованные выходные переменные;
 b_0 – смещение на выходном слое;
 w_k – вес, который связывает k -й скрытый слой и один выходной нейрон;
 b_{hk} – смещение на k -м нейроне скрытого слоя;
 h и m – количество нейронов в скрытом слое и входных слоях соответственно;
 w_{ik} – вес связи между i -й входной переменной и скрытым слоем;
 X_i – нормализованная входная переменная;
 f_{sig} – передаточная функция, используемая для обучения ИНС.

Количество нейронов h , подключенных к входному и скрытому слоям, равно 10. Принятые передаточные функции между входным и выходным слоями – $tansig$ ($f_{sig} = tansig$) и $purelin$ соответственно.

где TS_n – нормализованный предел прочности;

$$[W] = [1.279 \ 0.6628 \ -2.9155 \ 2.6693 \ -2.8315 \ -0.3615 \ 3.2800 \ 0.7236 \ -1.8831];$$

$$[q] = [\tanh A_1 \ \tanh A_2 \ \tanh A_3 \ \tanh A_4 \ \tanh A_5 \ \tanh A_6 \ \tanh A_7 \ \tanh A_8 \ \tanh A_9 \ \tanh A_{10}];$$

$$\tanh = f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}.$$

Нормализованные переменные A_1 – A_{10} можно рассчитать с помощью матричных уравнений:

$$\begin{matrix} A_1 \\ A_2 \\ A_3 \\ A_4 \\ A_5 \\ A_6 \\ A_7 \\ A_8 \\ A_9 \\ A_{10} \end{matrix} = \begin{bmatrix} 0.4549 & -0.2335 & 1.5844 & -1.7360 \\ 0.6977 & 0.1801 & 4.0404 & 3.2143 \\ 0.5458 & 5.7727 & 4.3710 & -6.2395 \\ -1.9850 & -0.4610 & 1.2824 & -0.8306 \\ -4.5821 & 0.2266 & 1.3249 & -1.1109 \\ -2.520 & 5.4207 & 1.8587 & 0.2827 \\ -0.4423 & 0.1586 & -0.5219 & 3.0538 \\ -0.9543 & 2.7184 & 0.4837 & 0.6755 \\ 1.6739 & -2.8579 & 0.3978 & 2.3733 \\ 1.2295 & 3.2789 & -2.5835 & 1.1224 \end{bmatrix} \begin{matrix} P \\ T \\ V \\ H \end{matrix} + \begin{matrix} -2.5042 \\ 1.6432 \\ 4.3932 \\ -0.6902 \\ -1.3171 \\ -0.7925 \\ 0.3307 \\ -0.6097 \\ -0.9304 \\ -2.5837 \end{matrix}$$

Нормализованный предел прочности в уравнении (4) необходимо денормализовать, чтобы получить требуемое прогнозируемое математическое уравнение. Денормализованное уравнение для прогнозирования предела прочности:

$$TS_d = \frac{(TS_n + 1) \times 318.8}{2} + 160, \quad (5)$$

где TS_d – денормализованный предел прочности. Минимальное и максимальное значения предела прочности составляют 160 и 478,8 МПа соответственно.

Таким образом, уравнение (5) представляет собой математическую модель на основе ИНС для прогнозирования предела прочности при заданных значениях мощности лазера, толщины слоя, скорости сканирования и шага штриховки.

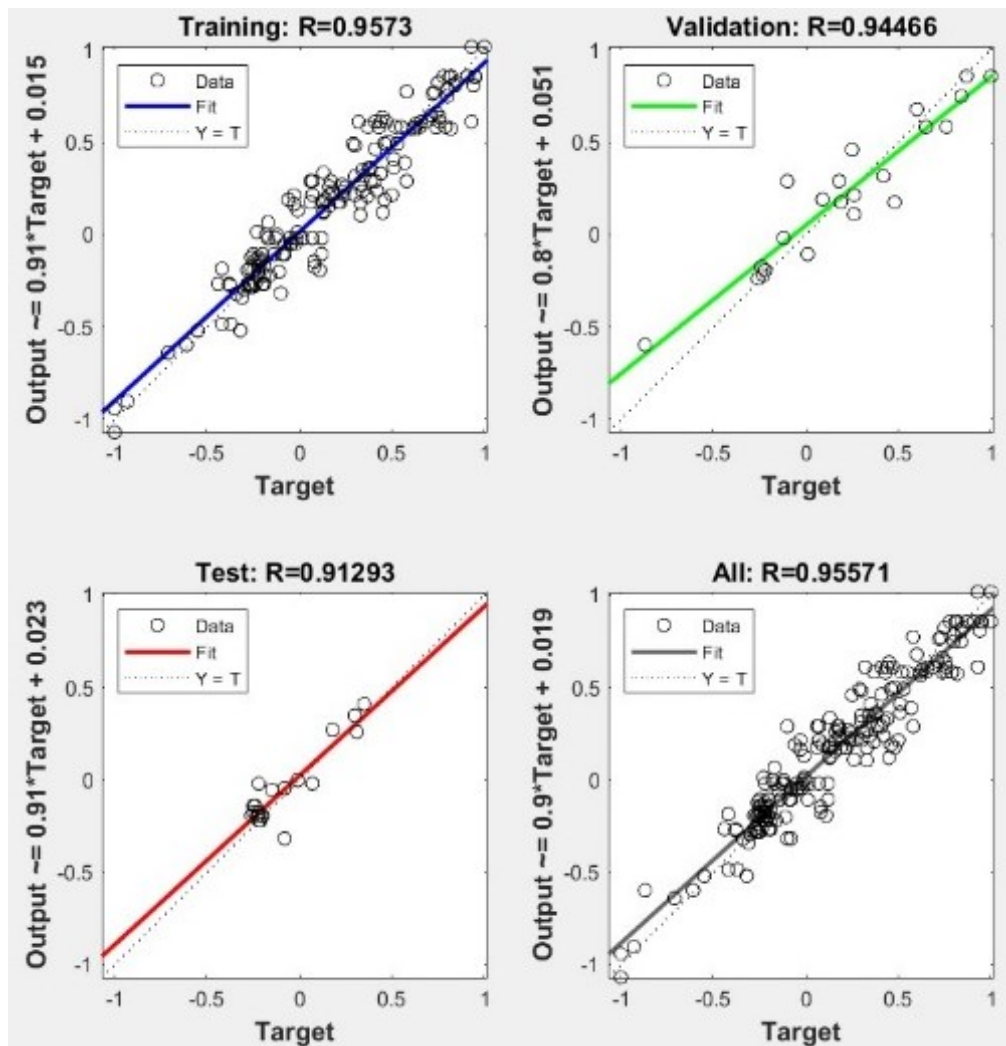


Рис. 6. График регрессии
Fig. 6. Regression plot




Рис. 7. График эффективности
Fig. 7. Performance plot

Анализ полиномиальной регрессии с использованием MATLAB

Экспериментальные результаты аппроксимировались квадратичным полиномом (2):

$$\begin{aligned}
 T.S = & -33.83 + 3.1866 \times P - 0.0435 \times T + 0.2681 \times V - \\
 & -2.9162 \times H - 0.0313 \times P \times T - 0.0004 \times P \times V - \\
 & -0.0182 \times P \times H - 0.0068 \times T \times V + \\
 & + 0.1159 \times T \times H + 0.0025 \times V \times H + 0.0005 \times P^2 + \\
 & + 0.0186 \times T^2 - 0.0001 \times V^2 + 0.0045 \times H^2
 \end{aligned} \quad (6)$$

где $T.S$ – предел прочности;
 P – мощность лазера;
 T – толщина слоя;
 V – скорость сканирования;
 H – шаг штриховки.

ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Оценка математической модели на основе ИНС

Сравнение прогнозируемых выходных данных ИНС и прогнозируемых выходных данных математической модели показано на рис. 8. Очевидно, что предлагаемая математическая модель идеально воспроизводит выходные данные ИНС с критерием соответствия $R^2=1$ и может использоваться для прогнозирования предела прочности без запуска модели ИНС. На рис. 9 показано сравнение фактических экспериментальных значений и прогнозируемых выходных данных. Среднее абсолютное процентное отклонение между экспериментальными и прогнозируемыми значениями составляет 4,74 %, что характеризует довольно хорошую точность. Критерий соответствия R^2

между прогнозируемыми ИНС данными и фактически экспериментальными значениями составляет 0,898 (рис. 10 а). Это указывает на то, что прогнозируемые значения совпали с фактическими на 89,8 %.

Оценка регрессионной модели

Рассчитанный критерий соответствия между экспериментальными и прогнозируемыми значениями с использованием полиномиальной регрессионной модели составил 0,68, что означает, что прогнозируемые значения совпадают с экспериментальными с точностью 68 %, как показано на рис. 10 б.

Рассчитанное среднее абсолютное процентное отклонение между экспериментальными и прогнозируемыми значениями составило 8,83 %, что указывает на умеренный уровень отклонения по отношению к экспериментальным значениям. На рис. 11 показано сравнение фактических и прогнозируемых значений.

F-тест и среднеквадратическая ошибка коэффициентов регрессии

F-тест регрессионной модели выполнялся для оценки прогнозирующей возможности и значимости связи между зависимыми и независимыми переменными с использованием уравнений:

$$SST = \sum (Y_i - \bar{Y})^2;$$

$$SSR = \sum (\hat{Y}_i - \bar{Y})^2;$$

$$SSE = \sum (Y_i - \hat{Y}_i^2);$$




Рис. 8. Предел прочности, рассчитанный с помощью ИНС и математической модели
Fig. 8. Tensile strength predicted using ANN vs mathematical model



Рис. 9. Экспериментальные и спрогнозированные значения предела прочности (ИНС)
Fig. 9. Experimental vs predicted values of tensile strength (ANN)

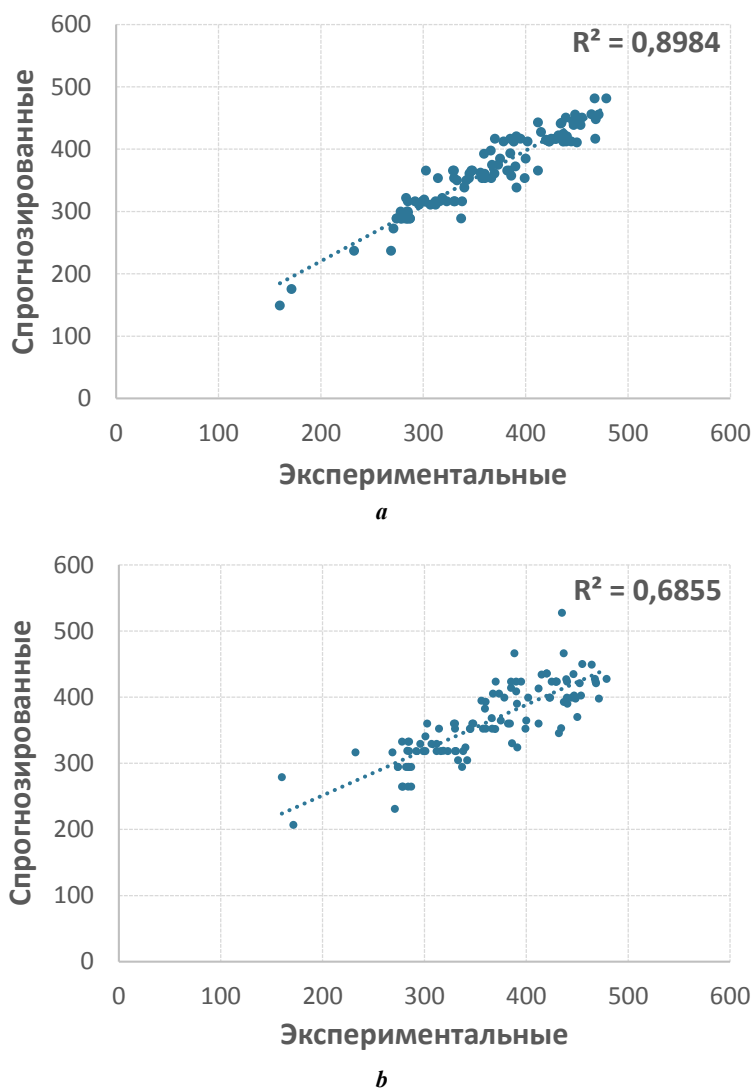


Рис. 10. Сравнение экспериментального и спрогнозированного предела прочности:
a – модель на основе ИНС; *b* – модель полиномиальной регрессии
Fig. 10. Comparison of the measured vs predicted tensile strength:
a – ANN-based model; *b* – polynomial regression model



Рис. 11. Экспериментальные и спрогнозированные значения предела прочности (полиномиальная регрессия)
Fig. 11. Experimental vs predicted values of tensile strength (polynomial regression)

$$MSR = \frac{SSR}{k};$$

$$MSE = \frac{SSE}{n-k-1};$$

$$F - statistic = \frac{MSR}{MSE},$$

где SST – общая сумма квадратов;
 SSR – сумма квадратов регрессии;
 SSE – остаточная сумма квадратов;
 MSR – среднее квадратическое для регрессии;
 MSE – среднее квадратическое для погрешности;
 Y_i – экспериментальные значения;
 \bar{Y} – среднее значение выходной переменной;
 \hat{Y}_i – прогнозируемые значения;
 k – количество независимых переменных;
 $n-k-1$ – степени свободы.

Поскольку $F=13,36$, что больше $F_{critical}$ при уровне значимости 0,05, существует статистически значимая связь между входными и выходными переменными модели.

Стандартная ошибка коэффициентов регрессии измеряет изменчивость оцененных коэффициентов, если исследование проводилось повторно. Она определяет связанную с моделью неопределенность, т. е. ее изменение при переходе к другой выборке. Анализ выполнялся с помощью MATLAB с использованием уравнений:

$$X = \begin{bmatrix} 1 & P_1 & T_1 & V_1 & H_1 & P_1T_1 & P_1V_1 \\ 1 & P_2 & T_2 & V_2 & H_2 & P_2T_2 & P_2V_2 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 1 & P_n & T_n & V_n & H_n & P_nT_n & P_nV_n \end{bmatrix};$$

$$\begin{bmatrix} P_1H_1 & T_1V_1 & T_1H_1 & V_1H_1 & P_1^2 & T_1^2 & V_1^2 & H_1^2 \\ P_1H_2 & T_2V_2 & T_2H_2 & V_2H_2 & P_2^2 & T_2^2 & V_2^2 & H_2^2 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ P_nH_n & T_nV_n & T_nH_n & V_nH_n & P_n^2 & T_n^2 & V_n^2 & H_n^2 \end{bmatrix}$$

$$\text{Residual Variance, } \sigma^2 = \frac{SSR}{n-p};$$

Variance – Covariance Matrix of Coefficients,

$$\text{Var}(\hat{\beta}) = \sigma^2 (X'X)^{-1}.$$

Стандартные ошибки представляют собой квадратные корни диагональных элементов дисперсионно-ковариационной матрицы:

Standard error of Coefficients

$$SE(\hat{\beta}) = \sqrt{\text{diag}(\text{Var}(\hat{\beta}))}.$$

Результаты исследования обобщены в таблице 4. Стандартная ошибка коэффициента определяет степень неопределенности коэффициентов. Относительно небольшая ошибка указывает на точную оценку и значимость влияния коэффициента, наблюдаемого для переменных $V, V^2, P^2, T^2, H^2, P \cdot T, P \cdot V, P \cdot H, T \cdot V$ и $V \cdot H$. Напротив, относительно большая стандартная ошибка для переменной T и свободного коэффициента показывает, что оценки не очень точны и, вероятно, будут сильнее варьироваться в зависимости от выборки.

Оценка предлагаемых моделей с новыми наборами данных

Математическая модель на основе ИНС и полиномиальная регрессионная модель проверялись на новом наборе из 27 точек данных, отличных от тех, которые использовались при разработке модели. Экспериментальные значения точек данных были взяты из литературы. Для прогнозирования предела прочности новых входных наборов данных использовались математическая модель на основе ИНС (5) и уравнение полиномиальной регрессии (6), эти же данные сравнивались с экспериментальными значениями для оценки надежности модели. Оценка проводилась с использованием статистических параметров, таких как критерий соответствия R^2 для измерения того, насколько хорошо модель соответствует данным; среднее абсолютное процентное отклонение (MAPE) для обеспечения относительной точности прогноза; абсолютное среднее отклонение (MAE) для измерения общего отклонения прогноза и среднеквадратичная ошибка (RMSE) для выяснения влияния большего отклонения, как указано в уравнениях:

$$R^2 = 1 - \frac{\text{Sum of squares of residuals}}{\text{Total sum of squares}};$$

Mean absolute percentage error (MAPE) =

$$= \frac{1}{n} \sum \frac{\text{Prediction} - \text{Actual}}{\text{Actual}} \times 100;$$

Mean absolute error (MAE) =

$$= \frac{1}{n} \sum |\text{Prediction} - \text{Actual}|;$$

Root Mean Square Error (RMSE) =

$$= \sqrt{\frac{\sum (\text{Prediction} - \text{Actual})^2}{n}}.$$

На рис. 12 показано сравнение экспериментальных значений, полученных с помощью математической модели на основе ИНС и модели полиномиальной регрессии. Средний процент ошибок составил 11,1 и 16,8 % для модели на основе ИНС и модели полиномиальной регрессии соответственно. Результаты оценки надежности двух моделей приведены в таблице 5.

Сравнение с предыдущими исследованиями

Экспериментальные результаты оценки свойств при растяжении образца сплава AlSi10Mg, изготовленного методом селективной лазерной плавки, демонстрируют

Таблица 4. Среднее квадратическое отклонение коэффициента регрессии
 Table 4. Standard error of a regression coefficient

Переменная	Коэффициент	Стандартная ошибка регрессии
Свободный коэффициент	-33,83	156,8213
P	3,1866	0,5771
T	-0,0435	4,3601
V	0,2681	0,0783
H	-2,9162	0,741
$P \cdot T$	-0,0313	0,006
$P \cdot V$	-0,0004	0,0002
$P \cdot H$	-0,0182	0,0024
$T \cdot V$	-0,0068	0,0015
$T \cdot H$	0,1159	0,0134
$V \cdot H$	0,0025	0,0007
P^2	0,0005	0,0003
T^2	0,0186	0,0397
V^2	-0,0001	0
H^2	0,0045	0,0022

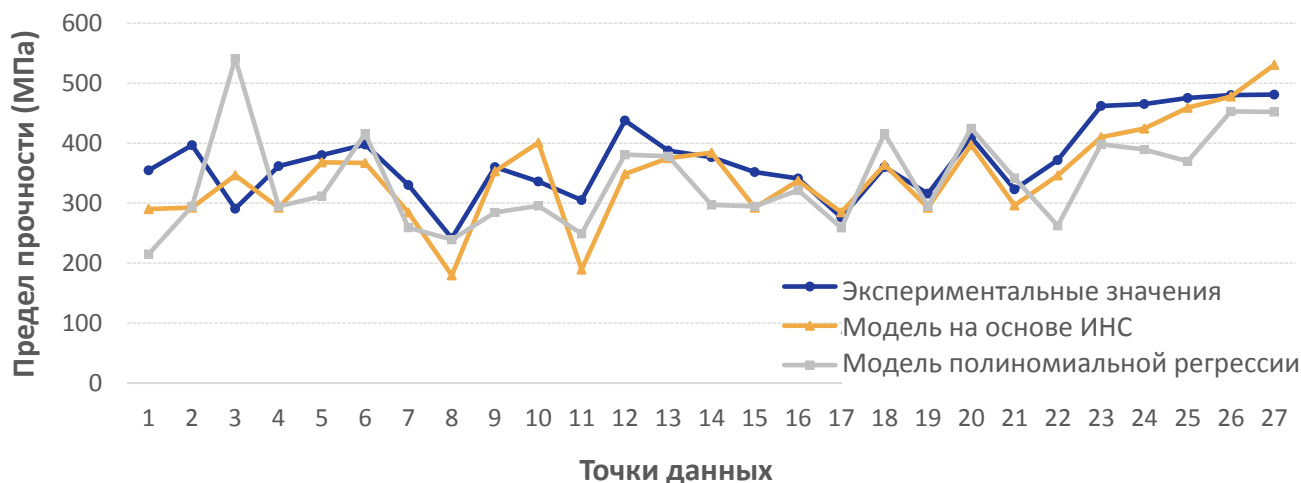


Рис. 12. Экспериментальные и спрогнозированные значения предела прочности для новых точек данных
 Fig. 12. Experimental vs predicted values of tensile strength for new data points

Таблица 5. Результат оценки модели на основе ИНС и регрессионной модели
 Table 5. Summary of the validation of ANN-based and regression models

Параметр оценки	Математическая модель на основе ИНС	Модель полиномиальной регрессии
Критерий соответствия R^2	0,68	0,25
Абсолютное среднее отклонение (MAE)	39,44	61,17
Абсолютное среднее процентное отклонение (MAPE)	11,10	16,89
Среднеквадратическая ошибка (RMSE)	50,37	79,28

высокую согласованность с предыдущими исследованиями [13–17]. Образец продемонстрировал значительно более высокий предел прочности – примерно на 25 % выше, чем у образцов, отлитых традиционным способом [18].

Разработанная модель ИНС и регрессионная модель показывают видимую зависимость выходных данных от ключевых параметров процесса – мощности лазера, толщины слоя, шага штриховки и скорости сканирования. Это наблюдение согласуется с предыдущими исследованиями, в которых мощность лазера и скорость сканирования определены как факторы, наиболее влияющие на свойства материала [6; 9].

Результаты ясно показывают, что модель ИНС превзошла регрессионную модель, показав хороший прогноз свойств материала. Это согласуется с предыдущими исследованиями, которые подчеркивают способность модели ИНС обрабатывать сложные, многофункциональные, нелинейные зависимости [6; 9; 19]. Например, в работе [8] получено значение среднеквадратической ошибки, равное 0,0335 для прогнозирования предела прочности с использованием ИНС, в то время как другие исследователи [9] сообщали о среднеквадратической ошибке, равной 0,232, 0,395, 0,122 для относительной плотности, шероховатости поверхности и твердости соответственно. Аналогичным образом в [7] получено значение среднеквадратической ошибки менее 3 % при использовании модели ИНС для прогнозирования предела прочности. В этом исследовании точность ИНС превзошла некоторые более ранние результаты, предсказывая свойства материала со значением среднеквадратической ошибки 0,0155 и суммарным значением коэффициента корреляции $R=0,96$. Это улучшение объясняется использованием более широкого набора данных для обучения модели, что повышает ее надежность и обеспечивает комплексное решение вопроса о связи параметров получения материала с его свойствами [20].

Значимость и выводы исследования

Настоящее исследование вносит вклад в область аддитивного производства, предлагая технологию прогнозирования свойств материалов на основе машинного обучения с использованием входных параметров процесса селективной лазерной плавки. Работа сосредоточена на прогнозировании предела прочности сплава AlSi10Mg, изготовленного методом селективной лазер-

ной плавки, и предлагает полезный инструмент для инженеров-конструкторов и технологов.

Практичность и эффективность предложенного решения выражается также в сокращении времени производства и используемых ресурсов. Обеспечивая оптимизацию производственных затрат в реальном времени, разработанная технология поддерживает производство высококачественных деталей.

Кроме того, поскольку модель обучается прогнозировать свойства в различных условиях, исследование предусматривает дальнейшее развитие метода с помощью оптимизации входных параметров получения материала на основе полученных нейросетевых корреляций.

Значимый результат исследования заключается в возможности внедрения технологий на основе машинного обучения в аддитивное производство. Работа предлагает использовать методы искусственного интеллекта в оптимизации свойств перспективных материалов.

Данное исследование закладывает основу для будущих исследований по внедрению машинного обучения и моделей нейронных сетей в аддитивное производство.

Ограничения предлагаемой модели ИНС

Предлагаемая модель ИНС имеет определенные ограничения, перечисленные ниже:

1. Входные переменные должны попадать в диапазон минимального и максимального значений переменных, используемых при разработке модели ИНС.
2. Входные и выходные данные должны быть нормализованы с использованием уравнения (1) перед их передачей в модель ИНС.
3. ИНС является более сложной системой по сравнению с регрессионной моделью и требует больше вычислительных ресурсов. Для эффективного обучения модели ИНС требуются большие наборы данных. Недостаточное количество экспериментальных наборов данных может ограничить возможности ИНС или привести к переобучению.

ВЫВОДЫ

В настоящем исследовании модель искусственной нейронной сети использовалась для описания экспериментальных данных. Кроме того, была разработана регрессионная модель для прогнозирования предела

прочности сплава AlSi10Mg, изготовленного методом аддитивного производства (селективной лазерной плавкой), на основе существующих экспериментальных данных. Эффективность математической модели на основе ИНС оценивалась и сравнивалась с регрессионной моделью на наборах данных, отличных от тех, которые использовались при обучении модели ИНС.

В результате были сделаны следующие выводы.

1. Предлагаемая математическая модель на основе ИНС демонстрирует превосходные показатели по сравнению с регрессионной моделью: критерий соответствия $R^2=0,898$ против $0,685$ для всех входных данных. Математическая модель на основе ИНС также показала сравнительно хорошие результаты для новых наборов данных с критерием соответствия $R^2=0,68$.

2. Математическая модель на основе ИНС демонстрирует низкое среднее абсолютное процентное отклонение: $4,74\%$ для наборов данных, используемых при разработке модели, и $11,1\%$ для новых входных наборов данных.

3. Точность математической модели на основе ИНС достаточно высока, чтобы рассматривать ее как жизнеспособный вариант для прогнозирования предела прочности. Однако эффективность модели ограничена для новых наборов входных данных из-за их ограниченной доступности. Ожидается, что включение большего количества наборов данных в разработку и проверку модели ИНС позволит добиться большей точности. Изучение различных топологий нейронных сетей и тонкая настройка гиперпараметров могут еще больше улучшить качество модели.

СПИСОК ЛИТЕРАТУРЫ

- Rouf S., Malik A., Singh N., Raina A., Naveed N., Siddiqui M.I.H., Haq M.I.Ul. Additive manufacturing technologies: Industrial and medical applications // Sustainable Operations and Computers. 2022. Vol. 3. P. 258–274. DOI: [10.1016/j.susoc.2022.05.001](https://doi.org/10.1016/j.susoc.2022.05.001).
- Sercombe T.B., Li X. Selective laser melting of aluminium and aluminium metal matrix composites: review // Materials Technology. 2016. Vol. 31. № 2. P. 77–85. DOI: [10.1179/1753555715Y.0000000078](https://doi.org/10.1179/1753555715Y.0000000078).
- Chowdhury S., Yadaiah N., Prakash Ch., Ramakrishna S., Dixit S., Gulta L.R., Buddhi D. Laser Powder Bed Fusion: A State-of-the-Art Review of the Technology, Materials, Properties & Defects, and Numerical Modelling // Journal of Materials Research and Technology. 2022. Vol. 20. P. 2109–2172. DOI: [10.1016/j.jmrt.2022.07.121](https://doi.org/10.1016/j.jmrt.2022.07.121).
- Xu Yongjun, Liu Xin, Cao Xin et al. Artificial intelligence: A powerful paradigm for scientific research // The Innovation. 2021. Vol. 2. № 4. Article number 100179. DOI: [10.1016/j.xinn.2021.100179](https://doi.org/10.1016/j.xinn.2021.100179).
- Osman E.-S., Aggour M.A. Artificial neural network model for accurate prediction of pressure drop in horizontal and near-horizontal-multiphase flow // Petroleum Science and Technology. 2002. Vol. 20. № 1-2. P. 1–15. DOI: [10.1081/LFT-120002082](https://doi.org/10.1081/LFT-120002082).
- Shubham P., Sharma A., Vishwakarma P.N., Phanden R.K. Predicting Strength of Selective Laser Melting 3D Printed AlSi10Mg Alloy Parts by Machine Learning Models // 8th International Conference on Signal Processing and Integrated Networks (SPIN). India, 2021. P. 745–749. DOI: [10.1109/SPIN52536.2021.9566142](https://doi.org/10.1109/SPIN52536.2021.9566142).
- Ghetiya N.D., Patel K.M. Prediction of Tensile Strength in Friction Stir Welded Aluminium Alloy Using Artificial Neural Network // Procedia Technology. 2014. Vol. 14. P. 274–281. DOI: [10.1016/j.protcy.2014.08.036](https://doi.org/10.1016/j.protcy.2014.08.036).
- Khalefa M. Use of artificial neural network for prediction of mechanical properties of Al–Si alloys synthesized by stir casting // Journal of Petroleum and Mining Engineering. 2019. Vol. 21. P. 97–103. DOI: [10.21608/jpme.2019.13857.1004](https://doi.org/10.21608/jpme.2019.13857.1004).
- Alamri F., Maalouf M., Barsoum I. Prediction of Porosity, Hardness and Surface Roughness in Additive Manufactured AlSi10Mg Samples: preprint. 2023. DOI: [10.21203/rs.3.rs-3186551/v1](https://doi.org/10.21203/rs.3.rs-3186551/v1).
- Lawal A.I., Aladejari A.E., Onifade M., Bada S., Idris M.A. Predictions of elemental composition of coal and biomass from their proximate analyses using ANFIS, ANN and MLR // International Journal of Coal Science and Technology. 2024. Vol. 8. P. 124–140. DOI: [10.1007/s40789-020-00346-9](https://doi.org/10.1007/s40789-020-00346-9).
- Owunna I., Ikpe A.E. Modelling and prediction of the mechanical properties of TIG welded joint for AISI 4130 low carbon steel plates using artificial neural network (ANN) approach // Nigerian Journal of Technology (NIJOTECH). 2019. Vol. 38. № 1. P. 117–126. DOI: [10.4314/njt.v38i1.16](https://doi.org/10.4314/njt.v38i1.16).
- Mahmoodi-Babolan N., Heydari A., Nematollahzadeh A. Removal of methylene blue via bioinspired catecholamine/starch superadsorbent and the efficiency prediction by response surface methodology and artificial neural network-particle swarm optimization // Bioresource Technology. 2019. Vol. 294. Article number 122084. DOI: [10.1016/j.biortech.2019.122084](https://doi.org/10.1016/j.biortech.2019.122084).
- Prasad M., Kempaiah U.N., Mohan R.M., Nagaral M. Microstructure, Tensile and Compression Behavior of AlSi10Mg Alloy Developed by Direct Metal Laser Sintering // Indian Journal of Science and Technology. 2021. Vol. 14. № 45. P. 3346–3353. DOI: [10.17485/IJST/v14i45.1705](https://doi.org/10.17485/IJST/v14i45.1705).
- Zhuo Longchao, Wang Zeyu, Zhang Hongjia, Yin Enhuai, Wang Yanlin, Xu Tao, Li Chao. Effect of post-process heat treatment on microstructure and properties of selective laser melted AlSi10Mg alloy // Materials Letters. 2019. Vol. 234. P. 196–200. DOI: [10.1016/j.matlet.2018.09.109](https://doi.org/10.1016/j.matlet.2018.09.109).
- Mei Jiahe, Han Ying, Zu Guoqing, Zhu Weiwei, Zhao Yu, Chen Hua, Ran Xu. Achieving Superior Strength and Ductility of AlSi10Mg Alloy Fabricated by Selective Laser Melting with Large Laser Power and High Scanning Speed // Acta Metallurgica Sinica (English Letters). 2022. Vol. 35. P. 1665–1672. DOI: [10.1007/s40195-022-01410-w](https://doi.org/10.1007/s40195-022-01410-w).
- Zhou Suyuan, Su Yang, Gu Rui, Wang Zhenyu, Zhou Yinghao, Ma Qian, Yan Ming. Impacts of Defocusing Amount and Molten Pool Boundaries on Mechanical Properties and Microstructure of Selective Laser Melted AlSi10Mg // Materials. 2019. Vol. 12. № 1. Article number 73. DOI: [10.3390/ma12010073](https://doi.org/10.3390/ma12010073).
- Zhang Shuzhe, Wei Pei, Chen Zhen, Li Bobo, Huang Ke, Zou Yatong, Lu Bingheng. Graphene/ZrO₂/aluminum alloy composite with enhanced strength and ductility fabricated by laser powder bed fusion // Journal of Alloys and Compounds. 2022. Vol. 910. Article number 164941. DOI: [10.1016/j.jallcom.2022.164941](https://doi.org/10.1016/j.jallcom.2022.164941).
- Wei Pei, Chen Zhen, Zhang Shuzhe, Li Bobo, Han Jiang, Lu Bingheng. Microstructure and mechanical properties of

- graphene and nano-zirconia reinforced AlSi10Mg composite fabricated by laser powder bed fusion // *Materials Science and Engineering: A*. 2023. Vol. 864. Article number 144574. DOI: [10.1016/j.msea.2022.144574](https://doi.org/10.1016/j.msea.2022.144574).
19. Amor N., Noman M.T., Ismail A., Petru M., Sebastian N. Use of an Artificial Neural Network for Tensile Strength Prediction of Nano Titanium Dioxide Coated Cotton // *Polymers*. 2022. Vol. 14. № 5. Article number 937. DOI: [10.3390/polym14050937](https://doi.org/10.3390/polym14050937).
 20. Khan A.Q., Awan H.A., Rasul M., Siddiqi Z.A., Pimanmas A. Optimized artificial neural network model for accurate prediction of compressive strength of normal and high strength concrete // *Cleaner Materials*. 2023. Vol. 10. Article number 100211. DOI: [10.1016/j.clema.2023.100211](https://doi.org/10.1016/j.clema.2023.100211).
- ## REFERENCES
1. Rouf S., Malik A., Singh N., Raina A., Naveed N., Siddiqui M.I.H., Haq M.I.U.I. Additive manufacturing technologies: Industrial and medical applications. *Sustainable Operations and Computers*, 2022, vol. 3, pp. 258–274. DOI: [10.1016/j.susoc.2022.05.001](https://doi.org/10.1016/j.susoc.2022.05.001).
 2. Sercombe T.B., Li X. Selective laser melting of aluminium and aluminium metal matrix composites: review. *Materials Technology*, 2016, vol. 31, no. 2, pp. 77–85. DOI: [10.1179/1753555715Y.0000000078](https://doi.org/10.1179/1753555715Y.0000000078).
 3. Chowdhury S., Yadaiah N., Prakash Ch., Ramakrishna S., Dixit S., Gulta L.R., Buddhi D. Laser Powder Bed Fusion: A State-of-the-Art Review of the Technology, Materials, Properties & Defects, and Numerical Modelling. *Journal of Materials Research and Technology*, 2022, vol. 20, pp. 2109–2172. DOI: [10.1016/j.jmrt.2022.07.121](https://doi.org/10.1016/j.jmrt.2022.07.121).
 4. Xu Yongjun, Liu Xin, Cao Xin et al. Artificial intelligence: A powerful paradigm for scientific research. *The Innovation*, 2021, vol. 2, no. 4, article number 100179. DOI: [10.1016/j.xinn.2021.100179](https://doi.org/10.1016/j.xinn.2021.100179).
 5. Osman E.-S., Aggour M.A. Artificial neural network model for accurate prediction of pressure drop in horizontal and near-horizontal-multiphase flow. *Petroleum Science and Technology*, 2002, vol. 20, no. 1-2, pp. 1–15. DOI: [10.1081/LFT-120002082](https://doi.org/10.1081/LFT-120002082).
 6. Shubham P., Sharma A., Vishwakarma P.N., Phanden R.K. Predicting Strength of Selective Laser Melting 3D Printed AlSi10Mg Alloy Parts by Machine Learning Models. *8th International Conference on Signal Processing and Integrated Networks (SPIN)*. India, 2021, pp. 745–749. DOI: [10.1109/SPIN52536.2021.9566142](https://doi.org/10.1109/SPIN52536.2021.9566142).
 7. Ghetiya N.D., Patel K.M. Prediction of Tensile Strength in Friction Stir Welded Aluminium Alloy Using Artificial Neural Network. *Procedia Technology*, 2014, vol. 14, pp. 274–281. DOI: [10.1016/j.protcy.2014.08.036](https://doi.org/10.1016/j.protcy.2014.08.036).
 8. Khalefa M. Use of artificial neural network for prediction of mechanical properties of Al–Si alloys synthesized by stir casting. *Journal of Petroleum and Mining Engineering*, 2019, vol. 21, pp. 97–103. DOI: [10.21608/jpme.2019.13857.1004](https://doi.org/10.21608/jpme.2019.13857.1004).
 9. Alamri F., Maalouf M., Barsoum I. *Prediction of Porosity, Hardness and Surface Roughness in Additive Manufactured AlSi10Mg Samples: preprint*. 2023. DOI: [10.21203/rs.3.rs-3186551/v1](https://doi.org/10.21203/rs.3.rs-3186551/v1).
 10. Lawal A.I., Aladejari A.E., Onifade M., Bada S., Idris M.A. Predictions of elemental composition of coal and biomass from their proximate analyses using ANFIS, ANN and MLR. *International Journal of Coal Science and Technology*, 2024, vol. 8, pp. 124–140. DOI: [10.1007/s40789-020-00346-9](https://doi.org/10.1007/s40789-020-00346-9).
 11. Owunna I., Ikpe A.E. Modelling and prediction of the mechanical properties of TIG welded joint for AISI 4130 low carbon steel plates using artificial neural network (ANN) approach. *Nigerian Journal of Technology (NIJOTECH)*, 2019, vol. 38, no. 1, pp. 117–126. DOI: [10.4314/njt.v38i1.16](https://doi.org/10.4314/njt.v38i1.16).
 12. Mahmoodi-Babolan N., Heydari A., Nematollahzadeh A. Removal of methylene blue via bioinspired catecholamine/starch superadsorbent and the efficiency prediction by response surface methodology and artificial neural network-particle swarm optimization. *Bioresource Technology*, 2019, vol. 294, article number 122084. DOI: [10.1016/j.biortech.2019.122084](https://doi.org/10.1016/j.biortech.2019.122084).
 13. Prasad M., Kempaiah U.N., Mohan R.M., Nagara M. Microstructure, Tensile and Compression Behavior of AlSi10Mg Alloy Developed by Direct Metal Laser Sintering. *Indian Journal of Science and Technology*, 2021, vol. 14, no. 45, pp. 3346–3353. DOI: [10.17485/IJST/v14i45.1705](https://doi.org/10.17485/IJST/v14i45.1705).
 14. Zhuo Longchao, Wang Zeyu, Zhang Hongjia, Yin Enhuai, Wang Yanlin, Xu Tao, Li Chao. Effect of post-process heat treatment on microstructure and properties of selective laser melted AlSi10Mg alloy. *Materials Letters*, 2019, vol. 234, pp. 196–200. DOI: [10.1016/j.matlet.2018.09.109](https://doi.org/10.1016/j.matlet.2018.09.109).
 15. Mei Jiahe, Han Ying, Zu Guoqing, Zhu Weiwei, Zhao Yu, Chen Hua, Ran Xu. Achieving Superior Strength and Ductility of AlSi10Mg Alloy Fabricated by Selective Laser Melting with Large Laser Power and High Scanning Speed. *Acta Metallurgica Sinica (English Letters)*, 2022, vol. 35, pp. 1665–1672. DOI: [10.1007/s40195-022-01410-w](https://doi.org/10.1007/s40195-022-01410-w).
 16. Zhou Suyuan, Su Yang, Gu Rui, Wang Zhenyu, Zhou Yinghao, Ma Qian, Yan Ming. Impacts of Defocusing Amount and Molten Pool Boundaries on Mechanical Properties and Microstructure of Selective Laser Melted AlSi10Mg. *Materials*, 2019, vol. 12, no. 1, article number 73. DOI: [10.3390/ma12010073](https://doi.org/10.3390/ma12010073).
 17. Zhang Shuzhe, Wei Pei, Chen Zhen, Li Bobo, Huang Ke, Zou Yatong, Lu Bingheng. Graphene/ZrO₂/aluminum alloy composite with enhanced strength and ductility fabricated by laser powder bed fusion. *Journal of Alloys and Compounds*, 2022, vol. 910, article number 164941. DOI: [10.1016/j.jallcom.2022.164941](https://doi.org/10.1016/j.jallcom.2022.164941).
 18. Wei Pei, Chen Zhen, Zhang Shuzhe, Li Bobo, Han Jiang, Lu Bingheng. Microstructure and mechanical properties of graphene and nano-zirconia reinforced AlSi10Mg composite fabricated by laser powder bed fusion. *Materials Science and Engineering: A*, 2023, vol. 864, article number 144574. DOI: [10.1016/j.msea.2022.144574](https://doi.org/10.1016/j.msea.2022.144574).
 19. Amor N., Noman M.T., Ismail A., Petru M., Sebastian N. Use of an Artificial Neural Network for Tensile Strength Prediction of Nano Titanium Dioxide Coated Cotton. *Polymers*, 2022, vol. 14, no. 5, article number 937. DOI: [10.3390/polym14050937](https://doi.org/10.3390/polym14050937).
 20. Khan A.Q., Awan H.A., Rasul M., Siddiqi Z.A., Pimanmas A. Optimized artificial neural network model for accurate prediction of compressive strength of normal and high strength concrete. *Cleaner Materials*, 2023, vol. 10, article number 100211. DOI: [10.1016/j.clema.2023.100211](https://doi.org/10.1016/j.clema.2023.100211).

Mathematical modelling to predict the tensile strength of additively manufactured AlSi10Mg alloy using artificial neural networks

Sunita K. Srivastava*¹, researcher of Department of Mechanical Engineering

N. Rajesh Mathivanan², PhD, professor of Department of Mechanical Engineering

PES University, Bangalore (India)

*E-mail: sunita.shri45@gmail.com

¹ORCID: <https://orcid.org/0009-0005-2174-2067>

²ORCID: <https://orcid.org/0000-0003-1903-2005>

Received 10.09.2024

Revised 29.10.2024

Accepted 25.11.2024

Abstract: Integrating machine learning in additive manufacturing to simulate real manufacturing outcomes can significantly reduce the cost of manufacturing through selective manufacturing. However, limited research exists on developing a prediction model for the mechanical properties of the material. The input variables include key selective laser melting process parameters such as laser power, layer thickness, scan speed, and hatch spacing, with tensile strength as the output. The artificial neural network (ANN) based mathematical model is compared with a second-degree polynomial regression model. The robustness of both models was further assessed with the new data points beyond those used in the development of ANN-based mathematical model and regression model. The results demonstrate that the proposed ANN-based mathematical model offers superior accuracy, with a mean absolute percentage error (MAPE) value of 4.74 % and the R^2 (goodness of fit) value of 0.898 in predicting the strength of AlSi10Mg. The ANN-based mathematical method also demonstrates the strong performance on the new data, achieving a regression value of 0.68. This concludes that the model shows sufficient proof to consider a viable option for predicting the tensile strength.

Keywords: AlSi10Mg alloy; additive manufacturing; artificial neural network (ANN); machine learning; selective laser melting; mathematical model.

For citation: Srivastava S.K., Mathivanan N.R. Mathematical modelling to predict the tensile strength of additively manufactured AlSi10Mg alloy using artificial neural networks. *Frontier Materials & Technologies*, 2025, no. 1, pp. 93–110. DOI: 10.18323/2782-4039-2025-1-71-8.

Приложение 1

- Raus A.A., Wahab M.S., Shayfull Z., Kamarudin K., Ibrahim M. The Influence of Selective Laser Melting Parameters on Density and Mechanical Properties of AlSi10Mg. *MATEC Web of Conferences*, 2016, vol. 78, article number 01078. DOI: [10.1051/mateconf/20167801078](https://doi.org/10.1051/mateconf/20167801078).
- Prasad M., Kempaiah U.N., Mohan R.M., Nagaral M. Microstructure, Tensile and Compression Behaviour of AlSi10Mg Alloy Developed by Direct Metal Laser Sintering. *Indian Journal of Science and Technology*, 2021, vol. 14, no. 45, pp. 3346–3353. DOI: [10.17485/IJST/v14i45.1705](https://doi.org/10.17485/IJST/v14i45.1705).
- Nirish M., Rajendra R. Heat Treatment Effect on the Mechanical Properties of AlSi10Mg Produced by Selective Laser Melting. *Journal of Mechanical Engineering Research and Developments*, 2022, vol. 45, no. 2, pp. 19–28. URL: https://www.researchgate.net/publication/360783808_Heat_Treatment_Effect_on_the_Mechanical_Properties_of_AlSi10Mg_Produced_by_Selective_Laser_Melting.
- Ashwath P., Xavier M.A., Batako A., Jeyapandiarajan P., Joel J. Selective laser melting of Al–Si–10Mg alloy: microstructural studies and mechanical properties assessment. *Journal of Materials Research and Technology*, 2022, vol. 17, pp. 2249–2258. DOI: [10.1016/j.jmrt.2022.01.135](https://doi.org/10.1016/j.jmrt.2022.01.135).
- Casati R., Hamidi Nasab M., Coduri M., Tirelli V., Vedani M. Effects of Platform Pre-Heating and Thermal-Treatment Strategies on Properties of AlSi10Mg Alloy Processed by Selective Laser Melting. *Metals*, 2018, vol. 8, no. 11, article number 954. DOI: [10.3390/met8110954](https://doi.org/10.3390/met8110954).
- Chen B., Moon S.K., Yao X., Bi G., Shen J., Umeda J., Kondoh K. Strength and strain hardening of a selective laser melted AlSi10Mg alloy. *Scripta Materialia*, 2017, vol. 141, pp. 45–49. DOI: [10.1016/j.scriptamat.2017.07.025](https://doi.org/10.1016/j.scriptamat.2017.07.025).
- Delahaye J., Tchoufang Tchouindjang J., Lecomte-Beckers J., Rigo O., Habraken A.M., Mertens A. Influence of Si precipitates on fracture mechanisms of AlSi10Mg parts processed by Selective Laser Melting. *Acta Materialia*, 2019, vol. 175, pp. 160–170. DOI: [10.1016/j.actamat.2019.06.013](https://doi.org/10.1016/j.actamat.2019.06.013).
- Hitzler L., Janousch C., Schanz J., Merkel M., Heine B., Mack F., Hall W., Öchsner A. Direction and location dependency of selective laser melted AlSi10Mg specimens. *Journal of Materials Processing Technology*, 2017, vol. 243, pp. 48–61. DOI: [10.1016/j.jmatprotec.2016.11.029](https://doi.org/10.1016/j.jmatprotec.2016.11.029).
- John M.D., Flaviana C., Paolo A.E. et al. Direct Metal Laser Sintering: an additive manufacturing technology ready to produce lightweight structural parts for robotic applications. *Politecnico di Torino*. URL: <https://iris.polito.it/handle/11583/2518303>.
- Li Wei, Li Shuai, Liu Jie, Zhang Ang, Zhou Yan, Wei Qingsong, Yan Chunze, Shi Yusheng. Effect of heat treatment on AlSi10Mg alloy fabricated by selective laser melting: Microstructure evolution, mechanical properties and fracture mechanism. *Materials Science and Engineering: A*, 2016, vol. 663, pp. 116–125. DOI: [10.1016/j.msea.2016.03.088](https://doi.org/10.1016/j.msea.2016.03.088).

11. Rosenthal I., Stern A., Frage N. Strain rate sensitivity and fracture mechanism of AlSi10Mg parts produced by Selective Laser Melting. *Materials Science and Engineering: A*, 2017, vol. 682, pp. 509–517. DOI: [10.1016/j.msea.2016.11.070](https://doi.org/10.1016/j.msea.2016.11.070).
12. Tang M., Pistorius P.C. Anisotropic Mechanical Behavior of AlSi10Mg Parts Produced by Selective Laser Melting. *JOM*, 2017, vol. 69, pp. 516–522. DOI: [10.1007/s11837-016-2230-5](https://doi.org/10.1007/s11837-016-2230-5).
13. Wang Lianfeng, Sun Jing, Zhu Xiaogang, Cheng Lingyu, Shi Yun, Guo Lijie, Yan Biao. Effects of T2 Heat Treatment on Microstructure and Properties of the Selective Laser Melted Aluminum Alloy Samples. *Materials*, 2018, vol. 11, no. 1, article number 66. DOI: [10.3390/ma11010066](https://doi.org/10.3390/ma11010066).
14. Zhuo Longchao, Wang Zeyu, Zhang Hongjia, Yin Enhuai, Wang Yanlin, Xu Tao, Li Chao. Effect of post-process heat treatment on microstructure and properties of selective laser melted AlSi10Mg alloy. *Materials Letters*, 2019, vol. 234, pp. 196–200. DOI: [10.1016/j.matlet.2018.09.109](https://doi.org/10.1016/j.matlet.2018.09.109).
15. Larrosa N.O., Wang W., Read N., Loretto M.H., Evans C., Carr J., Tradowsky U., Attallah M.M., Withers P.J. Linking microstructure and processing defects to mechanical properties of selectively laser melted AlSi10Mg alloy. *Theoretical and Applied Fracture Mechanics*, 2018, vol. 98, pp. 123–133. DOI: [10.1016/j.tafmec.2018.09.011](https://doi.org/10.1016/j.tafmec.2018.09.011).
16. Manfredi D., Calignano F., Krishnan M., Canali R., Ambrosio E.P., Atzeni E. From Powders to Dense Metal Parts: Characterization of a Commercial AlSiMg Alloy Processed through Direct Metal Laser Sintering. *Materials*, 2013, vol. 6, no. 3, pp. 856–869. DOI: [10.3390/ma6030856](https://doi.org/10.3390/ma6030856).
17. Ming Tang, Pistorius P.C. Oxides, porosity and fatigue performance of AlSi10Mg parts produced by selective laser melting. *International Journal of Fatigue*, 2017, vol. 94, part 2, pp. 192–201. DOI: [10.1016/j.ijfatigue.2016.06.002](https://doi.org/10.1016/j.ijfatigue.2016.06.002).
18. Mei Jiahe, Han Ying, Zu Guoqing, Zhu Weiwei, Zhao Yu, Chen Hua, Ran Xu. Achieving Superior Strength and Ductility of AlSi10Mg Alloy Fabricated by Selective Laser Melting with Large Laser Power and High Scanning Speed. *Acta Metallurgica Sinica*, 2022, vol. 35, pp. 1665–1672. DOI: [10.1007/s40195-022-01410-w](https://doi.org/10.1007/s40195-022-01410-w).
19. Zygula K., Nosek B., Pasiowicz H., Szyslak N. Mechanical properties and microstructure of AlSi10Mg alloy obtained by casting and SLM technique. *World Scientific News*, 2018, vol. 104, pp. 462–472. URL: https://www.researchgate.net/publication/330215508_Mechanical_properties_and_microstructure_of_AlSi10Mg_alloy_obtained_by_casting_and_SLM_technique.
20. Hovig E.W., Azar A.S., Mhamdi M., Sørby K. Mechanical Properties of AlSi10Mg Processed by Laser Powder Bed Fusion at Elevated Temperature. *TMS 2020 149th Annual Meeting & Exhibition Supplemental Proceedings*. London, Springer Cham Publ., 2020, pp. 395–404. DOI: [10.1007/978-3-030-36296-6_37](https://doi.org/10.1007/978-3-030-36296-6_37).
21. Zhou Suyuan, Su Yang, Gu Rui, Wang Zhenyu, Zhou Yinghao, Ma Qian, Yan Ming. Impacts of Defocusing Amount and Molten Pool Boundaries on Mechanical Properties and Microstructure of Selective Laser Melted AlSi10Mg. *Materials*, 2019, vol. 12, no. 1, article number 73. DOI: [10.3390/ma12010073](https://doi.org/10.3390/ma12010073).
22. Tan Qiyang, Yin Yu, Fan Zhiqi, Zhang Jingqi, Liu Yingang, Zhang Ming-Xing. Uncovering the roles of LaB6-nanoparticle inoculant in the AlSi10Mg alloy fabricated via selective laser melting. *Materials Science and Engineering: A*, 2021, vol. 800, article number 140365. DOI: [10.1016/j.msea.2020.140365](https://doi.org/10.1016/j.msea.2020.140365).
23. Famodimu O.H., Stanford M., Oduzoa C.F., Lijuan Zhang. Effect of process parameters on the density and porosity of laser melted AlSi10Mg/SiC metal matrix composite. *Frontiers of Mechanical Engineering*, 2018, vol. 13, pp. 520–527. DOI: [10.1007/s11465-018-0521-y](https://doi.org/10.1007/s11465-018-0521-y).
24. Marchese G., Aversa A., Lorusso M., Manfredi D., Calignano F., Lombardi M., Biamino S., Pavese M. Development and Characterisation of Aluminium Matrix Nanocomposites AlSi10Mg/MgAl₂O₄ by Laser Powder Bed Fusion. *Metals*, 2018, vol. 8, no. 3, article number 175. DOI: [10.3390/met8030175](https://doi.org/10.3390/met8030175).
25. Gao C., Wu W., Shi J., Xiao Z., Akbarzadeh A.H. Simultaneous enhancement of strength, ductility, and hardness of TiN/AlSi10Mg nanocomposites via selective laser melting. *Additive Manufacturing*, 2020, vol. 34, article number 101378. DOI: [10.1016/j.addma.2020.101378](https://doi.org/10.1016/j.addma.2020.101378).
26. He Peidong, Kong Hui, Liu Qian, Ferry M., Kruzic J.J., Li Xiaopeng. Elevated temperature mechanical properties of TiCN reinforced AlSi10Mg fabricated by laser powder bed fusion additive manufacturing. *Materials Science and Engineering: A*, 2021, vol. 811, article number 141025. DOI: [10.1016/j.msea.2021.141025](https://doi.org/10.1016/j.msea.2021.141025).
27. Wang Yachao, Shi Jing, Lu Shiqiang, Xiao Weihuan. Investigation of Porosity and Mechanical Properties of Graphene Nanoplatelets-Reinforced AlSi10Mg by Selective Laser Melting. *Journal of Micro and Nano Science and Engineering*, 2018, vol. 6, no. 1, article number 010902. DOI: [10.1115/1.4038454](https://doi.org/10.1115/1.4038454).
28. Wang Yachao, Shi Jing. Effect of hot isostatic pressing on nanoparticles reinforced AlSi10Mg produced by selective laser melting. *Materials Science and Engineering: A*, 2020, vol. 788, article number 139570. DOI: [10.1016/j.msea.2020.139570](https://doi.org/10.1016/j.msea.2020.139570).
29. Wei Pei, Chen Zhen, Zhang Shuzhe, Li Bobo, Han Jiang, Lu Bingheng. Microstructure and mechanical properties of graphene and nano-zirconia reinforced AlSi10Mg composite fabricated by laser powder bed fusion. *Materials Science and Engineering: A*, 2023, vol. 864, article number 144574. DOI: [10.1016/j.msea.2022.144574](https://doi.org/10.1016/j.msea.2022.144574).
30. Zhang Shuzhe, Chen Zhen, Wei Pei et al. Wear properties of graphene/zirconia biphasic nano-reinforced aluminium matrix composites prepared by SLM. *Materials Today Communications*, 2022, vol. 30, article number 103009. DOI: [10.1016/j.mtcomm.2021.103009](https://doi.org/10.1016/j.mtcomm.2021.103009).
31. Zhang Shuzhe, Wei Pei, Chen Zhen, Li Bobo, Huang Ke, Zou Yatong, Lu Bingheng. Graphene/ZrO₂/aluminum alloy composite with enhanced strength and ductility fabricated by laser powder bed fusion. *Journal of Alloys and Compounds*, 2022, vol. 910, article number 164941. DOI: [10.1016/j.jallcom.2022.164941](https://doi.org/10.1016/j.jallcom.2022.164941).
32. Yi Junchao, Zhang Xiaowei, Rao Jeremy Heng, Xiao Jingyu, Jiang Yehua. In-situ chemical reaction mechanism and non-equilibrium microstructural evolution of (TiB₂ + TiC)/AlSi10Mg composites prepared by SLM-CS processing. *Journal of Alloys and Compounds*, 2021, vol. 857, article number 157553. DOI: [10.1016/j.jallcom.2020.157553](https://doi.org/10.1016/j.jallcom.2020.157553).
33. Miao Kai, Zhou Hang, Gao Yumpeng, Deng Xin, Lu Zhongliang, Li Dichen. Laser powder-bed-fusion of Si₃N₄ reinforced AlSi10Mg composites: Processing, mechanical properties and strengthening mechanisms. *Materials Science and Engineering: A*, 2021, vol. 825, article number 141874. DOI: [10.1016/j.msea.2021.141874](https://doi.org/10.1016/j.msea.2021.141874).
34. Limbasiya N., Jain A., Soni H., Wankhede V., Krolczyk G., Sahlot R. A comprehensive review on the effect of process parameters and post-process treatments on microstructure and mechanical properties of selective laser melting of AlSi10Mg. *Journal of Materials Research and Technology*, 2022, vol. 21, pp. 1141–1176. DOI: [10.1016/j.jmrt.2022.09.092](https://doi.org/10.1016/j.jmrt.2022.09.092).

1. Maamoun A.H., Xue Y.F., Elbestawi M.A., Veldhuis S.C. The Effect of Selective Laser Melting Process Parameters on the Microstructure and Mechanical Properties of Al6061 and AlSi10Mg Alloys. *Materials*, 2019, vol. 12, no. 1, article number 12. DOI: [10.3390/ma12010012](https://doi.org/10.3390/ma12010012).
2. Srinivasa Rakesh Ch., Raja A., Nadig P., Jayaganthan R., Vasa N.J. Influence of working environment and built orientation on the tensile properties of selective laser melted AlSi10Mg alloy. *Materials Science and Engineering: A*, 2019, vol. 750, pp. 141–151. DOI: [10.1016/j.msea.2019.01.103](https://doi.org/10.1016/j.msea.2019.01.103).
3. Dong Zhichao, Zhang Xiaoyu, Shi Wenhua, Zhou Hao, Lei Hongshuai, Liang Jun. Study of Size Effect on Microstructure and Mechanical Properties of AlSi10Mg Samples Made by Selective Laser Melting. *Materials*, 2018, vol. 11, no. 12, article number 2463. DOI: [10.3390/ma11122463](https://doi.org/10.3390/ma11122463).
4. Li Xinwei, Shi Shi, Han Shuang, Hu Xiaogang, Zhu Qiang, Lu Hongxing, Li Wenwu, Shi Yusheng, Ding Hui. Microstructure, solidification behavior and mechanical properties of Al-Si-Mg-Ti/TiC fabricated by selective laser melting. *Additive Manufacturing*, 2020, vol. 34, article number 10132. DOI: [10.1016/j.addma.2020.101326](https://doi.org/10.1016/j.addma.2020.101326).
5. Kempen K., Thijs L., Van Humbeeck J., Kruth J.-P. Processing AlSi10Mg by selective laser melting: parameter optimisation and material characterisation. *Materials Science and Technology*, 2014, vol. 31, no. 8, pp. 917–923. DOI: [10.1179/1743284714Y.0000000702](https://doi.org/10.1179/1743284714Y.0000000702).
6. Kim Dong-Kyu, Woo Wanchuck, Hwang Ji-Hyun, An Ke, Choi Shi-Hoon. Stress partitioning behavior of an AlSi10Mg alloy produced by selective laser melting during tensile deformation using in situ neutron diffraction. *Journal of Alloys and Compounds*, 2016, vol. 686, pp. 281–286. DOI: [10.1016/j.jallcom.2016.06.011](https://doi.org/10.1016/j.jallcom.2016.06.011).
7. Maskery I., Aboulkhair N.T., Tuck C.J., Wildman R., Ashcroft I., Everitt N.M., Hague R.J.M.. Fatigue Performance Enhancement of Selectively Laser Melted Aluminium Alloy by Heat Treatment. 26th Annual International Solid Freeform Fabrication Symposium. Texas, 2015, pp. 1–10. URL: https://www.researchgate.net/publication/282816647_Fatigue_Performance_Enhancement_of_Selectively_Laser_Melted_Aluminium_Alloy_by_Heat_Treatment.
8. Sun Jing, Qiu Lianfang, Wang Fei, Yang Yang, Guo Lijie. A new modification effect of eutectic Si in selective laser melted AlSi10Mg. *Materials Science and Technology*, 2019, vol. 35, no. 6, pp. 1–7. DOI: [10.1080/02670836.2019.1589740](https://doi.org/10.1080/02670836.2019.1589740).
9. Wei Pei, Wei Zhengying, Chen Zhen, Du Jun, He Yuyang, Li Junfeng, Zhou Yatong. The AlSi10Mg samples produced by selective laser melting: single track, densification, microstructure and mechanical behaviour. *Applied Surface*, 2017, vol. 408, pp. 38–50. DOI: [10.1016/j.apsusc.2017.02.215](https://doi.org/10.1016/j.apsusc.2017.02.215).
10. Zhang Changchun, Zhu Haihong, Liao Hailong, Cheng Yong, Hu Zhiheng, Zeng Xiaoyan. Effect of heat treatments on fatigue property of selective laser melting AlSi10Mg. *International Journal of Fatigue*, 2018, vol. 116, pp. 513–522. DOI: [10.1016/j.ijfatigue.2018.07.016](https://doi.org/10.1016/j.ijfatigue.2018.07.016).
11. Yang Tao, Liu Tingting, Liao Wenhe, MacDonald E., Wei Huijiang, Zhang Changdong, Chen Xiangyuan, Zhang Kai. Laser powder bed fusion of AlSi10Mg: Influence of energy intensities on spatter and porosity evolution, microstructure and mechanical properties. *Journal of Alloys and Compounds*, 2020, vol. 849, article number 156300. DOI: [10.1016/j.jallcom.2020.156300](https://doi.org/10.1016/j.jallcom.2020.156300).
12. Yan Qian, Song Bo, Shi Yusheng. Comparative study of performance comparison of AlSi10Mg alloy prepared by selective laser melting and casting. *Journal of Materials Science & Technology*, 2020, vol. 41, pp. 199–208. DOI: [10.1016/j.jmst.2019.08.049](https://doi.org/10.1016/j.jmst.2019.08.049).
13. Suttley L.J. Evaluation of metallurgical and mechanical properties of AlSi10Mg produced by selective laser melting: Graduate Theses & Non-Theses. 2018. 174. Digital Commons and Montana Tech. URL: https://digitalcommons.mtech.edu/grad_rschr/174.
14. Liu Bin, Kuai Zezhou, Li Zhonghua, Tong Jianbin, Bai Peikang, Li Baoqiang, Nie Yunfei. Performance Consistency of AlSi10Mg Alloy Manufactured by Simulating Multi Laser Beam Selective Laser Melting (SLM): Microstructures and Mechanical Properties. *Materials*, 2018, vol. 11, no. 12, article number 2354. DOI: [10.3390/ma11122354](https://doi.org/10.3390/ma11122354).
15. Murphy D.M. Performance evaluation of AlSi10Mg fabricated by a selective laser melting process. Missouri University of Science and Technology. URL: https://scholarsmine.mst.edu/masters_theses/8006.
16. Kumar M.S., Mohan E., Robinson S., Prasad T.D. Comparative Study on Morphological, Physical and Mechanical Characteristics of L-PBF Based AlSi10Mg Parts with Conventional Stir Casted Al-10%SiC Composites. *Silicon*, 2022, vol. 14, pp. 2695–2706. DOI: [10.1007/s12633-021-01065-9](https://doi.org/10.1007/s12633-021-01065-9).
17. Zhou S.Y., Wang Z.Y., Su Y., Wang H., Liu G., Song T.T., Yan M. Effects of Micron/Submicron TiC on Additively Manufactured AlSi10Mg: A Comprehensive Study from Computer Simulation to Mechanical and Microstructural Analysis. *JOM*, 2020, vol. 72, pp. 3693–3704. DOI: [10.1007/s11837-019-03984-w](https://doi.org/10.1007/s11837-019-03984-w).