

УДК 303.732.4

DOI: [10.26102/2310-6018/2026.54.3.007](https://doi.org/10.26102/2310-6018/2026.54.3.007)

Сравнительный анализ методов машинного обучения для восстановления магнитной характеристики коротких образцов в измерительной системе с параллельным магнитным шунтом

В.А. Сурняев✉, В.В. Гречихин

Южно-Российский государственный политехнический университет (НПИ) имени М.И. Платова, Новочеркасск, Российская Федерация

Резюме. В статье рассматривается задача восстановления магнитной характеристики материала коротких образцов по данным измерительной системы с параллельным магнитным шунтом. Ранее было показано, что введение шунта повышает чувствительность измерений в широком диапазоне магнитных проницаемостей исследуемого материала, что особенно важно при работе с короткими образцами и ограничениях по намагничивающему току. Однако наличие параллельной ветви приводит к перераспределению магнитного потока и усложняет интерпретацию измерительной информации, что делает применение прямых аналитических процедур восстановления характеристики затруднительным. В настоящей работе предлагается рассмотреть методы машинного обучения для решения обратной задачи восстановления магнитной характеристики по измеренным зависимостям. В отличие от ранее выполненного исследования, где анализировались только нейросетевые модели, в данной статье проведен сравнительный анализ пяти алгоритмов обучения различных классов. Обучение и тестирование выполняются в условиях, приближенных к реальным, с учетом возможных погрешностей измерительных каналов. Показано, что наилучшее качество восстановления при заданном уровне шумов обеспечивает алгоритм случайного леса, превосходящий альтернативы по критериям средней квадратичной ошибки и устойчивости к помехам.

Ключевые слова: магнитный шунт, короткие образцы, магнитная характеристика, обратная задача, машинное обучение, робастность, погрешности измерений.

Для цитирования: Сурняев В.А., Гречихин В.В. Сравнительный анализ методов машинного обучения для восстановления магнитной характеристики коротких образцов в измерительной системе с параллельным магнитным шунтом. *Моделирование, оптимизация и информационные технологии.* 2026;14(3). URL: <https://moitvivr.ru/ru/journal/article?id=2178> DOI: 10.26102/2310-6018/2026.54.3.007

Comparative analysis of machine learning methods for reconstructing the magnetic characteristic of short samples in a measurement system with a parallel magnetic shunt

V.A. Surnyaev✉, V.V. Grechikhin

Platov South-Russian State Polytechnic University (NPI), Novocherkassk, the Russian Federation

Abstract. The paper addresses the problem of reconstructing the magnetic characteristic of a short sample material from measurements obtained in a magnetic measurement system with a parallel magnetic shunt. Previous studies have shown that introducing a shunt increases measurement sensitivity over a wide range of magnetic permeabilities of the investigated material, which is especially important for short samples and under limitations on the magnetizing current. However, the presence of a parallel branch causes magnetic flux redistribution and complicates the interpretation of measurement data,

making direct analytical reconstruction procedures difficult. In this work, machine learning methods are considered for solving the inverse problem of reconstructing the magnetic characteristic from measured dependences. In contrast to earlier research where only neural-network models were analyzed, this paper provides a comparative analysis of five learning algorithms from different model classes. Training and testing are performed under conditions close to real measurements, taking into account possible errors of the measurement channels. It is shown that the best reconstruction quality at the specified noise level is achieved by the Random Forest, which outperforms the alternatives in terms of mean squared error and robustness to disturbances.

Keywords: magnetic shunt, short samples, magnetic characteristic, inverse problem, machine learning, robustness, measurement errors.

For citation: Surnyaev V.A., Grechikhin V.V. Comparative analysis of machine learning methods for reconstructing the magnetic characteristic of short samples in a measurement system with a parallel magnetic shunt. *Modeling, Optimization and Information Technology*. 2026;14(3). (In Russ.). URL: <https://moitvvt.ru/ru/journal/article?id=2178> DOI: 10.26102/2310-6018/2026.54.3.007

Введение

Измерение магнитных характеристик материалов коротких образцов представляет собой актуальную задачу для широкого круга прикладных областей, включая разработку магнитострикционных и функциональных материалов, а также контроль технологических процессов. Для коротких образцов (малое отношение длины к поперечному размеру) прямое получение характеристики затруднено вследствие выраженных размагничивающих эффектов и ограничений по уровню создаваемого магнитного поля в измерительной системе. В таких условиях возрастает роль конструктивных решений, повышающих чувствительность измерительного преобразования без существенного усложнения аппаратной части.

Одним из эффективных подходов является введение параллельного магнитного шунта, обеспечивающего перераспределение магнитного потока и рост чувствительности измерительного сигнала к изменениям магнитной проницаемости исследуемого материала. В работе [1] показано, что шунт позволяет расширить рабочий диапазон измерительной системы и повысить информативность измерений, в частности, при ограничениях на ток намагничивания и геометрические параметры образца. Вместе с тем, наличие шунта приводит к тому, что измеряемая величина определяется не только магнитным сопротивлением образца, но и параметрами параллельной ветви, что усложняет обратную интерпретацию измерительного сигнала и делает задачу восстановления магнитной характеристики существенно нелинейной.

Для решения обратных задач такого типа в последние годы широко применяются методы машинного обучения, позволяющие строить отображение «измеренные данные → искомая характеристика» без явного аналитического обращения модели при условии наличия репрезентативной обучающей выборки. Ранее в [2] рассматривался подход на основе нейросетевых моделей и показана принципиальная возможность восстановления характеристики в рамках выбранной постановки. Однако в практическом внедрении важны не только достижимая точность, но и устойчивость к помехам, интерпретируемость решения, вычислительная сложность и требования к объему данных.

В задаче восстановления магнитной характеристики по измеренной зависимости $B(I)$ в системе с параллельным шунтом присутствуют: выраженная нелинейность; ограниченное число обучающих примеров; шумы измерительного тракта, приводящие к локальным искажениям входного вектора $\{B_k\}$. Поэтому в работе целенаправленно рассмотрены модели с принципиально различными механизмами обобщения:

- линейная/полиномиальная регрессия (базовый «физически линейный» ориентир);
- kNN как метод «по библиотеке прецедентов», близкий по идеологии к классическим подходам восстановления по табличным данным/эталонам;
- одиночное дерево (CART) как интерпретируемая модель пороговых переходов между режимами намагничивания;
- случайный лес (Random Forest (bagging)) как метод подавления дисперсии и повышения устойчивости к шуму измерений;
- градиентный бустинг как метод уменьшения смещения, потенциально более точный на «чистых» данных, но чувствительный к шумовым остаткам.

Такой набор моделей позволяет не только сравнить точность, но и проанализировать связь результатов с физическими режимами и устойчивостью к измерительным погрешностям.

Целью настоящей работы является сравнительный анализ методов машинного обучения для восстановления магнитной характеристики коротких образцов в измерительной системе с параллельным магнитным шунтом.

Для достижения цели решаются следующие задачи:

1. Формализуется модель измерительной системы и вводятся соотношения, связывающие параметры магнитной цепи с измеряемыми величинами.
2. Формулируется обратная задача восстановления магнитной характеристики как задача регрессии.
3. Формируется обучающая и тестовая выборки, включая сценарии, приближенные к реальным условиям измерений.
4. Проводится сравнение пяти алгоритмов машинного обучения различных классов по критериям точности и устойчивости.
5. Определяется наиболее эффективный алгоритм и обсуждаются условия его применения в практической измерительной системе.

Научная новизна работы заключается в том, что предложено рассматривать восстановление магнитной характеристики в системе с шунтом как задачу машинного обучения с учетом перераспределения потоков в магнитной цепи; выполнено сопоставление пяти алгоритмов обучения различных классов; проведена оценка устойчивости решений к моделируемым погрешностям измерительных каналов. Практическая значимость состоит в обосновании выбора метода, обеспечивающего минимальную ошибку восстановления характеристики при наличии шумов и неопределенностей, характерных для реального измерения.

Материалы и методы

Объект исследования и измерительная система. Объектом исследования является восстановление магнитной характеристики материала короткого образца по косвенным измерениям в магнитной измерительной системе. Система включает С-образный магнитопровод, намагничивающую и измерительную катушки, воздушный зазор с установленным образцом, а также параллельный магнитный шунт, образующий дополнительную ветвь магнитного потока. Конструктивное введение шунта используется для повышения чувствительности измерительного сигнала к изменению магнитных параметров образца [1, 2].

Аналитическая модель магнитной цепи. Разработка базовой аналитической модели магнитной системы необходима для понимания физики процессов перераспределения магнитного потока и обоснования сложного, нелинейного характера обратной задачи. В измерительной системе с параллельным магнитным шунтом

магнитный поток разделяется на две ветви: через исследуемый образец с нелинейным магнитным сопротивлением $R_A(\lambda)$ (где λ отражает изменение состояния материала) и через магнитный шунт с постоянным сопротивлением R_B (Рисунок 1).

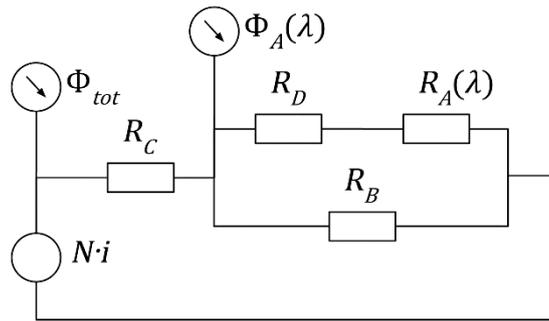


Рисунок 1 – Эквивалентная схема магнитной цепи с шунтом R_B
 Figure 1 – Equivalent circuit of the magnetic system with shunt R_B

Полный магнитный поток Φ_{tot} создаваемый намагничивающей катушкой с магнитодвижущей силой $F = NI$, определяется выражением:

$$\Phi_{tot}(\lambda) = \frac{F}{R_C + R_{||}(\lambda)}, \quad (1)$$

где R_C – магнитное сопротивление магнитопровода, а $R_{||}(\lambda)$ – эквивалентное сопротивление параллельной ветви (образец-шунт):

$$R_{||}(\lambda) = \frac{R_A(\lambda) \cdot R_B}{R_A(\lambda) + R_B}. \quad (2)$$

При этом измеряемый магнитный поток через образец $\Phi_A(\lambda)$ является лишь частью от полного потока и определяется коэффициентом деления $\alpha(\lambda)$:

$$\alpha(\lambda) \equiv \frac{R_B}{R_A(\lambda) + R_B}, \quad (3)$$

$$\Phi_A(\lambda) = \Phi_{tot}(\lambda) \cdot \alpha(\lambda). \quad (4)$$

Полученные базовые соотношения (1)–(4) математически доказывают, что при введении параллельного магнитного шунта измеряемый сигнал $\Phi_A(\lambda)$ зависит от искомого магнитного сопротивления образца $R_A(\lambda)$ сложным образом. Эта зависимость проявляется дважды: во-первых, через изменение общего эквивалентного сопротивления цепи $R_{||}(\lambda)$ (что влияет на полный поток), а во-вторых, через изменение коэффициента деления потока $\alpha(\lambda)$.

Вследствие такого перераспределения потоков на разных участках кривой намагничивания, зависимость между измеряемой магнитной индукцией и искомыми характеристиками материала становится существенно нелинейной. Прямое аналитическое обращение данной системы уравнений (особенно с учетом потоков рассеяния и зашумленности реальных измерительных сигналов) является некорректно поставленной и вычислительно неустойчивой задачей.

Именно эта сложность интерпретации измерительной информации диктует необходимость отказа от классических методов решения обратных задач в пользу методов машинного обучения, способных аппроксимировать сложные многомерные нелинейные зависимости.

Постановка обратной задачи и ее формализация для методов машинного обучения. Полученные выше соотношения показывают, что при наличии параллельного магнитного шунта измеряемый сигнал определяется как нелинейная функция

магнитного сопротивления образца $R_A(\lambda)$ (или эквивалентно $\mu_r(\lambda)$) и параметров магнитной цепи R_C и R_B . При этом поток через образец $\Phi_A(\lambda)$ зависит от $R_A(\lambda)$ одновременно через эквивалентное сопротивление параллельной ветви $R_{\parallel}(\lambda)$ и через коэффициент деления потока $\alpha(\lambda)$. Вследствие этого задача восстановления магнитной характеристики материала по косвенным измерениям является нелинейной обратной задачей, чувствительной к погрешностям измерительных каналов и неопределенности параметров цепи. В настоящей работе она рассматривается как задача построения отображения «измеренные данные \rightarrow искомая характеристика» методами машинного обучения.

Пусть $x \in R^m$ – вектор признаков, формируемый из результатов измерения в заданном режиме намагничивания. В качестве x используются значения измеряемой зависимости, например:

$$x = \{B_k\}_{k=1}^m, \quad (5)$$

где B_k – значения магнитной индукции в зоне датчика при дискретных значениях тока намагничивания I_k .

Искомым выходом модели является магнитная характеристика образца. В работе она задается в виде вектора $y \in R^m$, представляющего дискретизацию функции, индукция в образце как функция $H^{(A)}$:

$$y = \{B_j^{(A)}\}_{j=1}^n. \quad (6)$$

Таким образом, обратная задача формализуется как задача многомерной регрессии:

$$\hat{y} = f(x; \theta), \quad (7)$$

где $f(\cdot)$ – модель машинного обучения с параметрами θ , а \hat{y} – восстановленная магнитная характеристика.

Формирование обучающей выборки и протокол обучения. Обучающая выборка формируется как множество пар:

$$\mathcal{D} = \{(x^{(i)}, y^{(i)})\}_{i=1}^N, \quad (8)$$

где $x^{(i)}$ – признаки, соответствующие результатам моделирования для i -го случая, а $y^{(i)}$ – соответствующая «истинная» характеристика образца [3, 4].

Формирование данных выполнено на основе численного моделирования магнитного поля в измерительной системе. В вычислительном эксперименте фиксировалась геометрия магнитной системы (магнитопровод, воздушные зазоры, положение образца и магнитного шунта), после чего выполнялось варьирование двух факторов:

1) магнитной характеристики материала образца (то есть задавались различные зависимости, определяющие магнитное состояние материала и соответствующую ему проницаемость/кривую намагничивания), что формирует различные варианты целевого отклика $y(i)$;

2) тока в намагничивающих катушках I_k , который изменялся по заданному набору значений и тем самым создавал различные уровни намагничивания в магнитной цепи.

Для каждой пары «характеристика материала – режим намагничивания» вычислялось распределение магнитного поля и определялись значения магнитной индукции B_k в области, соответствующей расположению измерительного преобразователя. Таким образом, каждой заданной магнитной характеристике $y^{(i)}$

ставится в соответствие рассчитанная зависимость $x^{(i)} = \{Bk^{(i)}\}$, моделирующая сигнал измерительного канала при различных уровнях намагничивания. Полученная выборка D далее используется для обучения моделей машинного обучения, аппроксимирующих отображение $\hat{y} = f(x; \theta)$ [5].

Общий объем сформированной выборки составляет $N = 900$ пар $(x(i), y(i))$. Для обучения моделей машинного обучения и сопоставления алгоритмов выборка D разделялась на обучающую и контрольную части в пропорции 90%/10%, что примерно соответствует 800 примерам в обучающей выборке и 100 примерам в контрольной (тестовой) выборке. Контрольная выборка использовалась для расчета метрик качества и сравнения алгоритмов.

Для анализа влияния объема обучающих данных на точность восстановления дополнительно рассматривалась зависимость ошибки от размера обучающей выборки. Для этого обучающая часть объемом 800 примеров разбивалась на подвыборки размера $N_{\text{train}} \in \{100, 200, \dots, 800\}$ с шагом 100. Для каждого значения N_{train} выполнялось обучение модели на соответствующей подвыборке и последующая оценка качества на неизменной контрольной выборке. Параметры моделей (включая гиперпараметры) выбирались таким образом, чтобы минимизировать ошибку предсказания модели на контрольной выборке, то есть оптимизация проводилась по критерию минимального значения MSE на наборе из 100 контрольных примеров.

Критерий оптимизации и метрики качества. Параметры модели θ определяются минимизацией среднеквадратичной ошибки восстановления характеристики:

$$\theta^* = \arg \min_{\theta} \frac{1}{N} \sum_{i=1}^N \|y^{(i)} - f(x^{(i)}; \theta)\|_2^2. \quad (9)$$

Для итоговой оценки качества используется MSE на тестовой выборке:

$$\text{MSE} = \frac{1}{N_{\text{test}}} \sum_{i=1}^{N_{\text{test}}} \|y^{(i)} - \hat{y}^{(i)}\|_2^2. \quad (10)$$

Моделирование погрешностей измерений и оценка устойчивости. Измерительные преобразователи и вторичная измерительная аппаратура характеризуются классом точности и допускаемой погрешностью, вследствие чего результаты измерений содержат систематическую и случайную составляющие^{1,2}. В настоящей работе основное внимание уделяется оценке устойчивости (робастности) алгоритмов восстановления магнитной характеристики к случайной погрешности измерений магнитной индукции в зоне датчика. Это обусловлено тем, что входной вектор признаков $x = \{B_k\}_{k=1}^m$ формируется непосредственно по измеренной зависимости $B(I)$, и случайные искажения отдельных отсчетов B_k , связанные с шумами измерительного тракта, квантованием и флуктуациями условий регистрации, могут приводить к ухудшению качества восстановления \hat{y} и искажению формы реконструируемой магнитной характеристики.

Для приближения условий моделирования к реальным измерениям случайная составляющая погрешности учитывается путем внесения во входной вектор x искусственного аддитивного шума заданного уровня:

$$\tilde{x} = x + \varepsilon, \quad (11)$$

где x – зашумленные входные данные, ε – случайная ошибка измерения. В расчетах используется относительный уровень шума $\delta = 5\%$, при этом масштаб шума задается пропорционально амплитуде измеряемого сигнала:

¹ ГОСТ 8.401-80. Государственная система обеспечения единства измерений. Классы точности средств измерений. Общие требования. Москва: Стандартинформ; 2010. 9 с.

² РМГ 29-2013. Государственная система обеспечения единства измерений. Метрология. Основные термины и определения. Москва: Стандартинформ; 2014. 55 с.

$$\sigma = \delta \cdot \max_k |B_k|, \quad \delta = 0,05, \quad (12)$$

а компоненты ε генерируются как случайные величины с нулевым средним; при необходимости такая погрешность может быть аппроксимирована нормальным (гауссовским) распределением как распространенной моделью случайных ошибок измерения.

Оценка устойчивости выполняется сравнением метрик качества восстановления на исходных и зашумленных данных. Для тестовой выборки вычисляется MSE_0 (без добавления шума) и $MSE_{0,05}$ (при шуме 5%), после чего вводится показатель относительного ухудшения качества:

$$\Delta_{\text{noise}} = \frac{MSE_{0,05} - MSE_0}{MSE_0} \cdot 100 \%. \quad (13)$$

Дополнительно анализируется сохранение физически корректной формы восстановленной магнитной характеристики (отсутствие нефизических осцилляций/разрывов), поскольку даже при близких значениях MSE разные алгоритмы могут по-разному реагировать на шумовые искажения входной зависимости $B(I)$.

Методы машинного обучения. Для решения обратной задачи восстановления магнитной характеристики по входному вектору признаков $x = \{B_k\}_{k=1}^m$ использованы пять алгоритмов машинного обучения различных классов: дерево решений CART, ансамблевые методы Random Forest и Gradient Boosting, метрический метод k -ближайших соседей (kNN), а также линейная регрессия с оптимизацией параметров методом стохастического градиентного спуска (SGD). Выбор обусловлен стремлением охватить модели с принципиально различными механизмами обобщения (интерпретируемая нелинейная модель; ансамбли деревьев; непараметрический локальный метод; простой линейный базовый подход), что позволяет сравнить их точность и устойчивость при едином протоколе обучения и при наличии случайной погрешности измерений.

Линейная регрессия (SGD). В качестве вычислительно простого базового метода используется полиномиальная регрессия, параметры которой оцениваются методом стохастического градиентного спуска (SGD). Исходный вектор признаков $x = \{B_k\}_{k=1}^m$ отображается в расширенное пространство полиномиальных признаков $\phi(x)$, включающее мономы заданной степени p (например, квадратичные и перекрестные члены). Далее строится линейная по параметрам модель многомерной регрессии:

$$\hat{y} = W \phi(x) + b, \quad (14)$$

где W – матрица весов, b – вектор смещений. Параметры W и b выбираются минимизацией среднеквадратичной ошибки на обучающих данных, а оптимизация выполняется итеративно методом SGD, обновляющим параметры по одному объекту или по мини-пакетам:

$$W \leftarrow W - \eta \nabla_W \mathcal{L}, \quad b \leftarrow b - \eta \nabla_b \mathcal{L}, \quad (15)$$

где η – шаг обучения, \mathcal{L} – функция потерь (MSE). Такой подход позволяет получить базовую регрессионную модель, которая, с одной стороны, учитывает нелинейность связи между измеряемым сигналом $\{B_k\}$ и восстанавливаемой характеристикой, а с другой стороны, остается вычислительно эффективной и удобной для анализа чувствительности к шумовым искажениям входных данных. Общие принципы построения регрессионных моделей и оптимизации методом градиентного спуска изложены в используемых источниках по машинному обучению [6].

Дерево решений (CART). Дерево решений аппроксимирует отображение $\hat{y} = f(x)$ посредством рекурсивного разбиения пространства признаков на области R_j и построения в каждой области простой модели (для регрессии – константы, равной среднему значению целевой переменной в листе). На каждом шаге выбирается разбиение (q, s) (признак q , порог s), минимизирующее суммарную квадратичную ошибку в дочерних областях:

$$(q^*, s^*) = \arg \min_{q,s} \left(\sum_{i: x_{iq} \leq s} \hat{y}^{(i)} - \widehat{y}_L \right)_2^2 + \sum_{i: x_{iq} > s} \hat{y}^{(i)} - \overline{y}_R \right)_2^2. \quad (16)$$

Ключевые гиперпараметры метода: максимальная глубина дерева, минимальное число объектов в листе, критерии останова. Деревья решений обладают высокой интерпретируемостью, однако для одиночного дерева характерна повышенная дисперсия прогнозов, что мотивирует использование ансамблевых методов [7].

Ансамбль деревьев Random Forest. Метод Random Forest представляет собой ансамбль деревьев решений, обученных на бутстреп-выборках с дополнительной рандомизацией подмножеств признаков при построении разбиений. Для регрессии итоговый прогноз вычисляется усреднением прогнозов отдельных деревьев:

$$\hat{y}(x) = \frac{1}{T} \sum_{t=1}^T f_t(x), \quad (17)$$

где T – число деревьев, f_t – прогноз t -го дерева. Рандомизация снижает корреляцию между деревьями и уменьшает дисперсию ансамбля, что обычно повышает устойчивость к шумовым искажениям входных данных $\{B_k\}$ [8]. Ключевые гиперпараметры: T , максимальная глубина, минимальный размер листа, число случайно выбираемых признаков при разбиении.

Градиентный бустинг над деревьями (Gradient Boosting). Градиентный бустинг строит аддитивную модель как сумму базовых алгоритмов (деревьев решений), добавляя их последовательно так, чтобы уменьшать функцию потерь. Модель имеет вид:

$$\hat{y}(x) = \sum_{t=1}^T \eta f_t(x), \quad (18)$$

где $\eta \in (0, 1]$ – скорость обучения. На шаге t строится дерево f_t , приближающее отрицательный градиент функции потерь по текущему приближению (в задачах регрессии обычно используется MSE). Ключевые гиперпараметры: число деревьев T , скорость обучения η , максимальная глубина/число листьев, параметры регуляризации. При корректной настройке бустинг обеспечивает высокую точность аппроксимации, однако требует контроля сложности модели во избежание переобучения [9].

Метод k -ближайших соседей (kNN). Метод k -ближайших соседей является непараметрическим метрическим подходом: прогноз формируется по значениям целевой переменной для k ближайших объектов обучающей выборки в пространстве признаков. Для регрессии используется среднее (или взвешенное среднее) по соседям:

$$\hat{y}(x) = \frac{1}{k} \sum_{i \in \mathcal{N}_k(x)} y^{(i)}, \quad (19)$$

где $\mathcal{N}_k(x)$ – множество индексов k ближайших соседей по выбранной метрике расстояния. В большинстве практических задач применяется евклидова метрика:

$$d(x, x') = \sqrt{\sum_{j=1}^m (x_j - x'_j)^2}. \quad (20)$$

Ключевые гиперпараметры: число соседей k , метрика расстояния и схема взвешивания соседей. Метод чувствителен к масштабу признаков, поэтому важно

единообразно формировать вектор $\{B_k\}$ (единые точки дискретизации по I_k , одинаковая обработка/нормализация) [10].

Результаты

На Рисунках 2, 4, 6, 8, 10 представлены зависимости среднеквадратической ошибки (MSE) на контрольной выборке от размера обучающей подвыборки $N_{\text{train}} \in \{100, 200, \dots, 800\}$ при добавлении аддитивного шума уровня 5 % во входные данные $x = \{B_k\}_{k=1}^m$ для алгоритмов SGD, CART, Random Forest, Gradient Boosting и kNN. Эти зависимости позволяют сопоставить динамику изменения ошибки при увеличении объема обучающих данных в условиях шумовых искажений измеряемого сигнала.

На Рисунках 3, 5, 7, 9, 11 приведены примеры восстановления магнитной характеристики на контрольной выборке при шуме 5 %: для каждого из пяти алгоритмов показано сопоставление истинной характеристики и восстановленной по зашумленному входному вектору. Представленные примеры иллюстрируют типичное поведение моделей при случайной погрешности измерений и используются для визуальной проверки корректности формы восстановленной зависимости.

В Таблице 1 приведены статистики распределения ошибки восстановления магнитной характеристики на контрольной выборке: Mean MSE (средняя ошибка), Median MSE (типичный случай) и Max MSE (худший случай). Существенное различие Mean и Median указывает на наличие выбросов – отдельных характеристик, восстановленных значительно хуже большинства. Поскольку в метрологии класс точности прибора определяется по его максимальной (гарантированной) погрешности, конфигурации моделей для Таблицы 1 отбирались по критерию минимизации Max MSE на зашумленных (5 %) данных.

Таблица 1 – Сравнение устойчивости моделей при добавлении аддитивного 5 % шума

Table 1 – Comparison of model robustness with the addition of 5 % additive noise

Name	Без шума			С шумом 5 %		
	Mean MSE	Median MSE	Max MSE	Mean MSE	Median MSE	Max MSE
<i>k</i> -ближайших соседей ($k = 11, n_{\text{train}} = 100$)	0,0250	0,0160	0,0910	0,0450	0,0340	0,2810
Градиентный бустинг ($n_{\text{est}} = 400, n_{\text{train}} = 100$)	0,0018	0,0010	0,0084	0,0380	0,0150	0,2970
CART (depth = 8, $n = 500$)	0,0039	0,0014	0,0200	0,0530	0,0130	0,3780
SGD (deg = 3, $n_{\text{train}} = 300$)	0,0140	0,0078	0,2010	0,0360	0,0190	0,3900
Случайный лес ($n_{\text{tree}} = 200, n_{\text{train}} = 100$)	0,0054	0,0027	0,0390	0,0300	0,0080	0,3830

Объективный анализ метрик (Таблица 1) показывает, что на незашумленных данных наилучшие значения Mean, Median и Max демонстрирует градиентный бустинг. Однако при добавлении 5 % аддитивного шума его ошибка возрастает на порядок. Алгоритм Random Forest показывает наилучшее среднее и медианное качество на зашумленных данных (Mean MSE = 0,030, Median MSE = 0,008), тогда как метод kNN обеспечивает минимальную максимальную ошибку (Max MSE = 0,281). Одиночное дерево CART и полиномиальная регрессия (SGD) демонстрируют наибольшую склонность к формированию экстремальных выбросов (Max MSE достигает 0,378 и 0,390 соответственно).

Зависимость MSE от размера обучающей выборки для полиномов степени от 1 до 3 и при шуме 5%

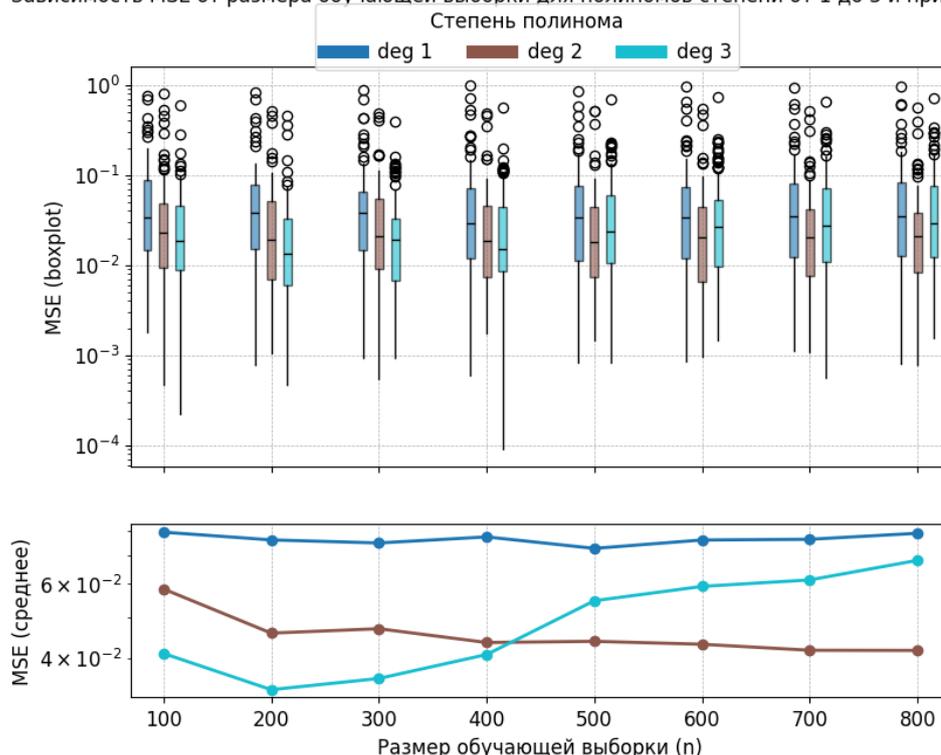


Рисунок 2 – Эволюция среднеквадратичной ошибки на тестовой выборке в зависимости от размера обучающей выборки и степени полинома при шуме 5%
Figure 2 – Evolution of the mean squared error on the test set as a function of the training set size and the polynomial degree with 5% noise

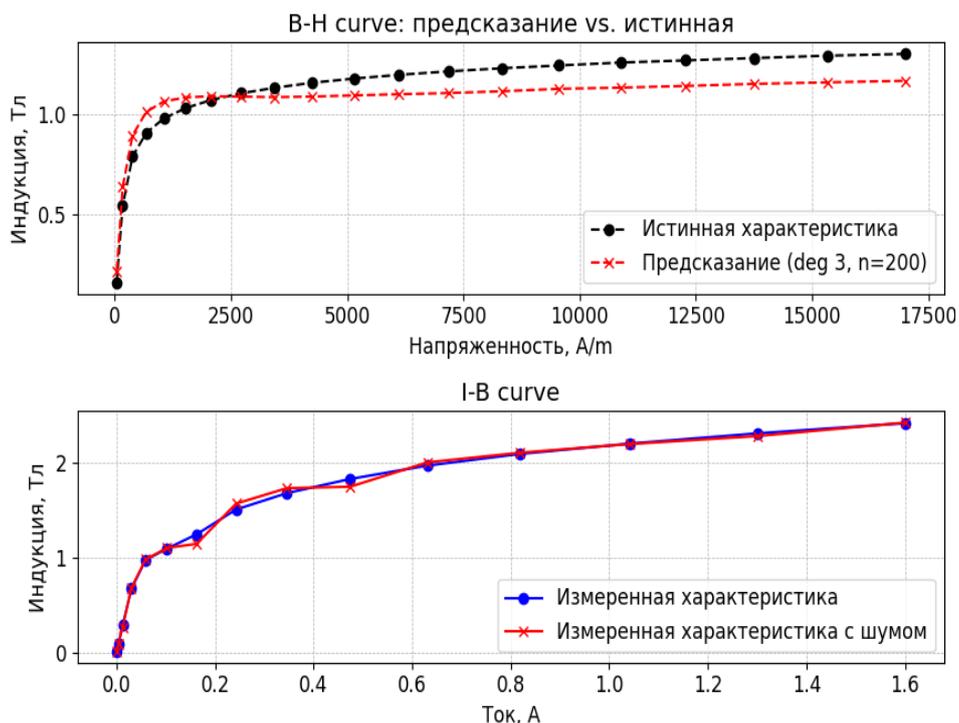


Рисунок 3 – Сравнение истинной характеристики образца и характеристики восстановленной моделью (SGD) при шуме 5 %
Figure 3 – Comparison of the true sample characteristic and the characteristic reconstructed by the model (SGD) with 5 % noise

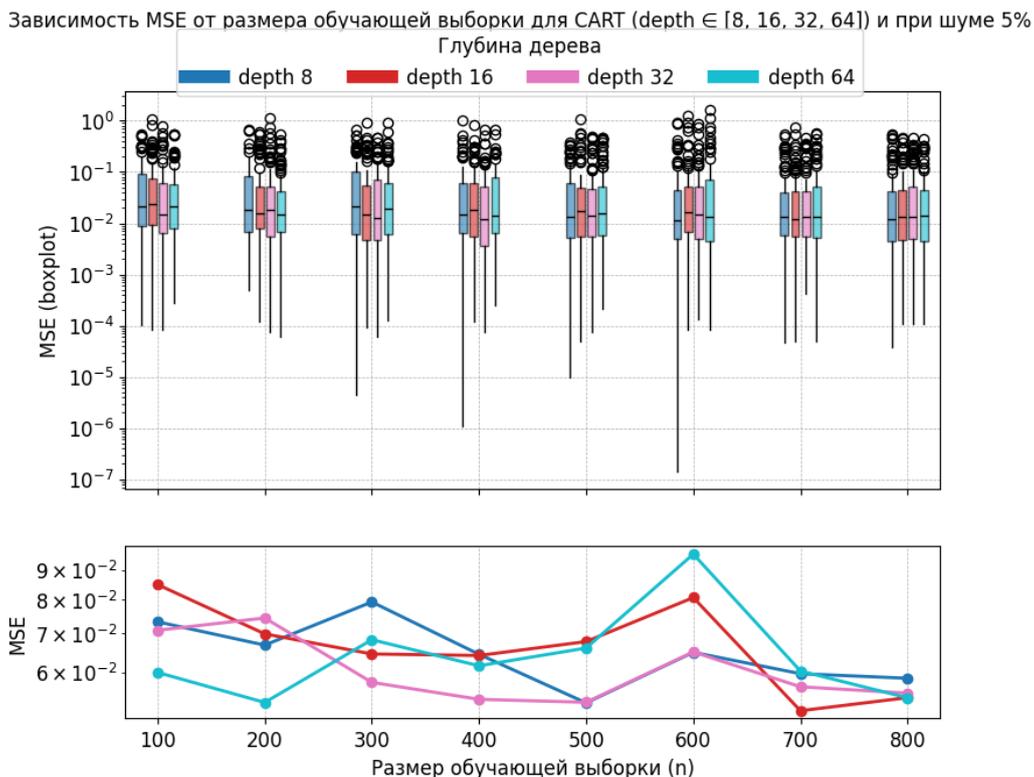


Рисунок 4 – Эволюция среднеквадратичной ошибки на тестовой выборке в зависимости от размера обучающей выборки и глубине дерева при шуме 5 %
Figure 4 – Evolution of the mean squared error on the test set as a function of the training set size and tree depth with 5 % noise

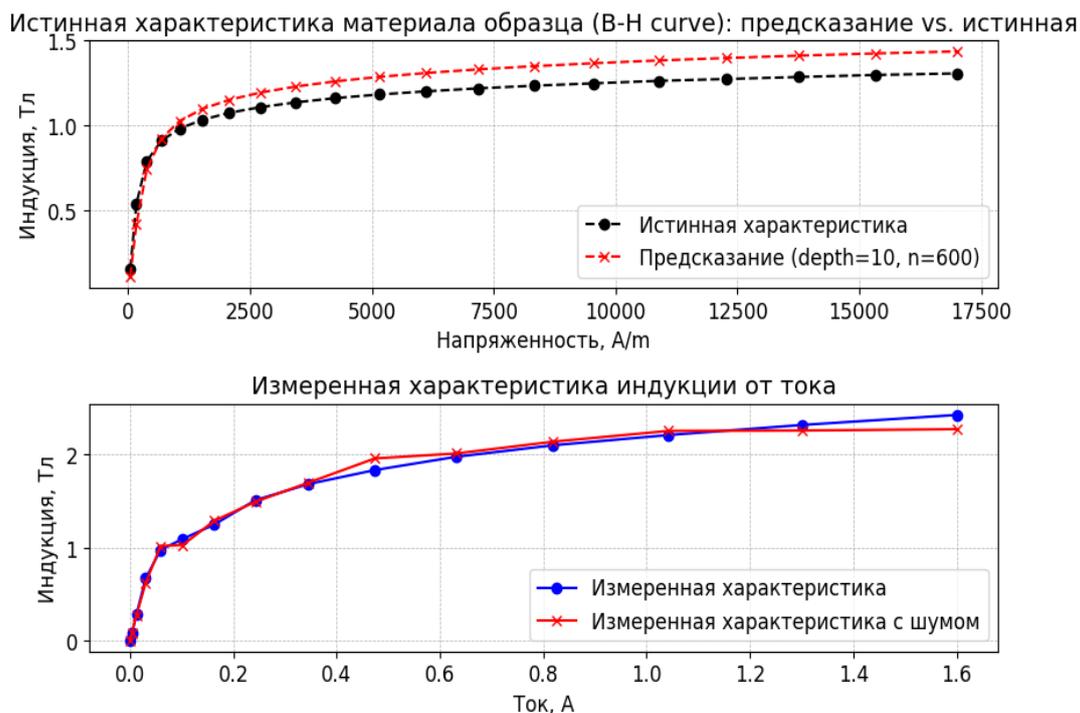


Рисунок 5 – Сравнение истинной характеристики образца и характеристики восстановленной моделью (CART) при шуме 5 %
Figure 5 – Comparison of the true sample characteristic and the characteristic reconstructed by the model (CART) with 5 % noise

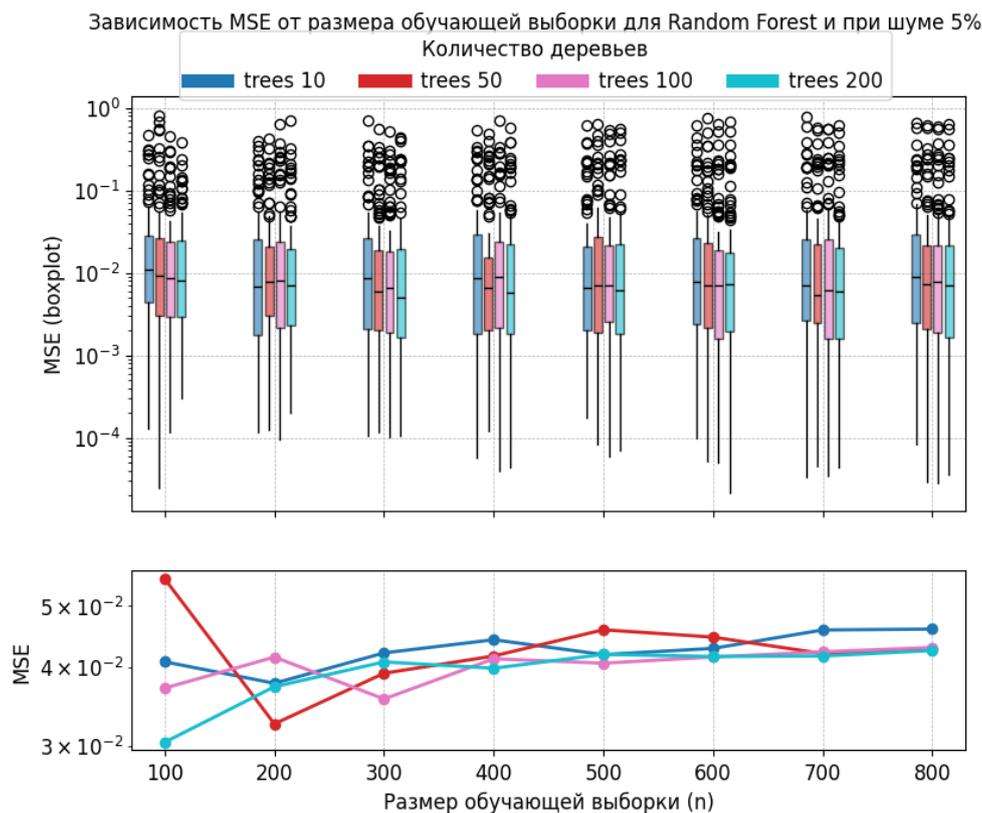


Рисунок 6 – Эволюция среднеквадратичной ошибки на тестовой выборке в зависимости от размера обучающей выборки и количества деревьев при шуме 5 %
Figure 6 – Evolution of the mean squared error on the test set as a function of the training set size and the number of trees with 5 % noise

Истинная характеристика материала образца (B-H curve): предсказание vs. истинная

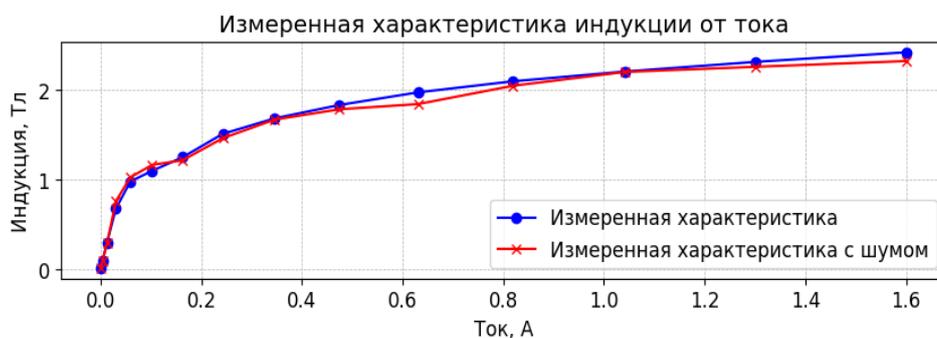
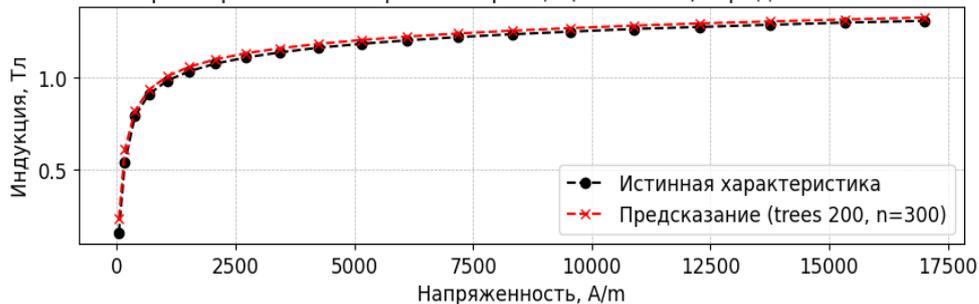


Рисунок 7 – Сравнение истинной характеристики образца и характеристики восстановленной моделью (Random Forest) при шуме 5 %
Figure 7 – Comparison of the true sample characteristic and the characteristic reconstructed by the model (Random Forest) with 5 % noise

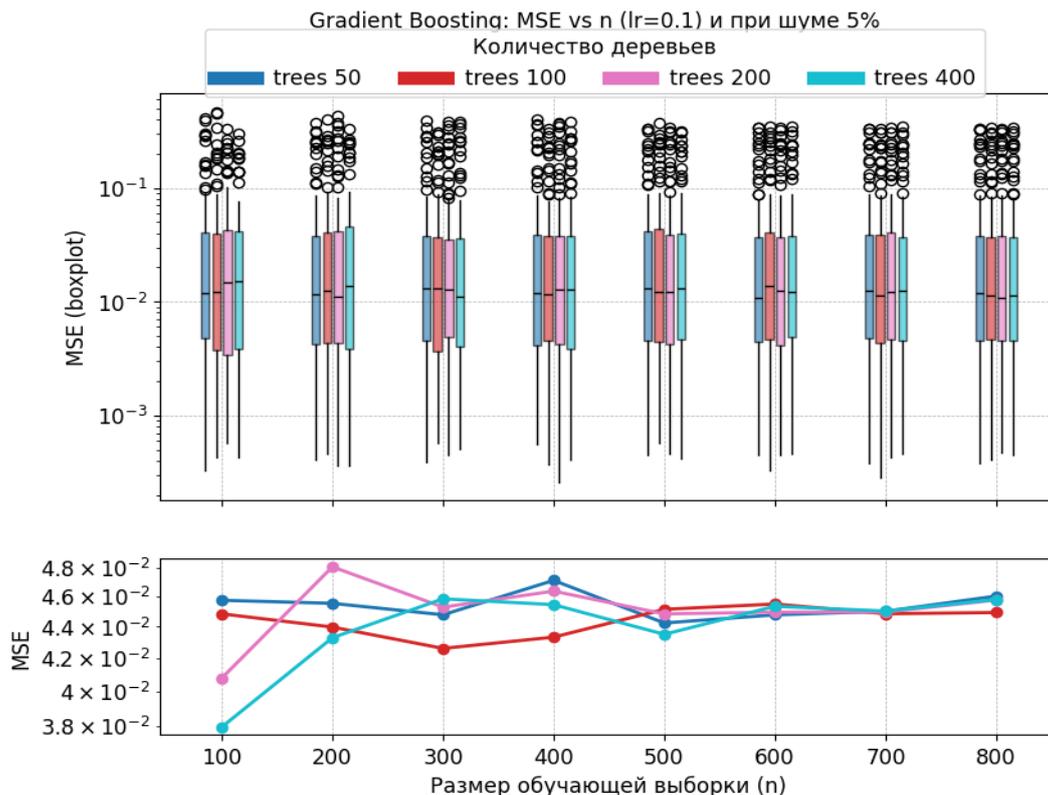
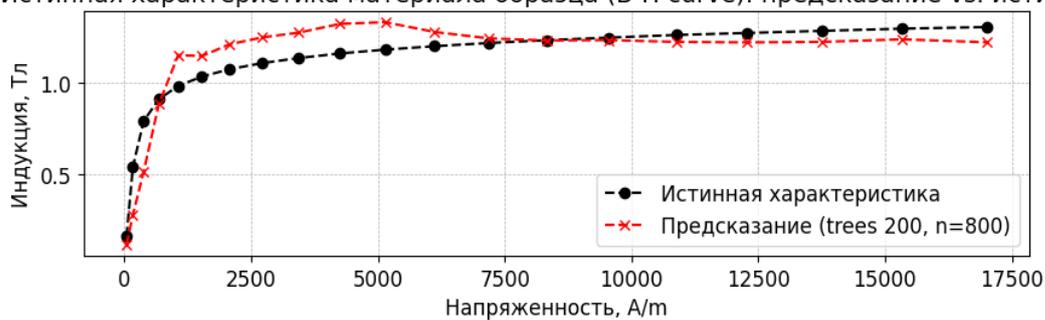


Рисунок 8 – Эволюция среднеквадратичной ошибки на тестовой выборке в зависимости от размера обучающей выборки и количества деревьев при шуме 5 %
Figure 8 – Evolution of the mean squared error on the test set as a function of the training set size and the number of trees with 5 % noise

Истинная характеристика материала образца (B-H curve): предсказание vs. истинная



Измеренная характеристика индукции от тока

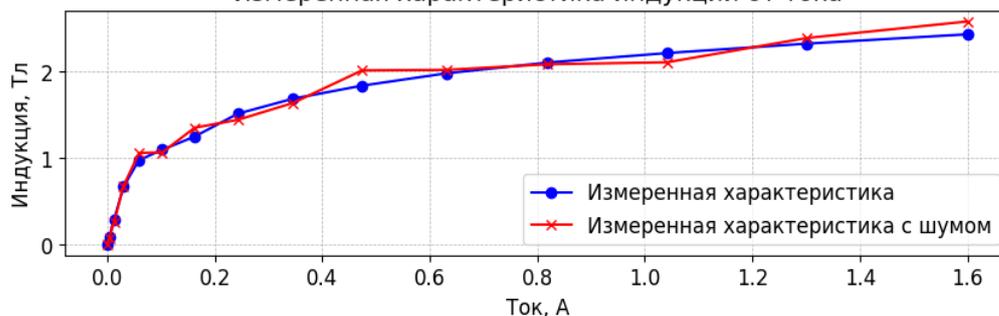


Рисунок 9 – Сравнение истинной характеристики образца и характеристики восстановленной моделью (Gradient Boosting) при шуме 5 %
Figure 9 – Comparison of the true sample characteristic and the characteristic reconstructed by the model (Gradient Boosting) with 5 % noise

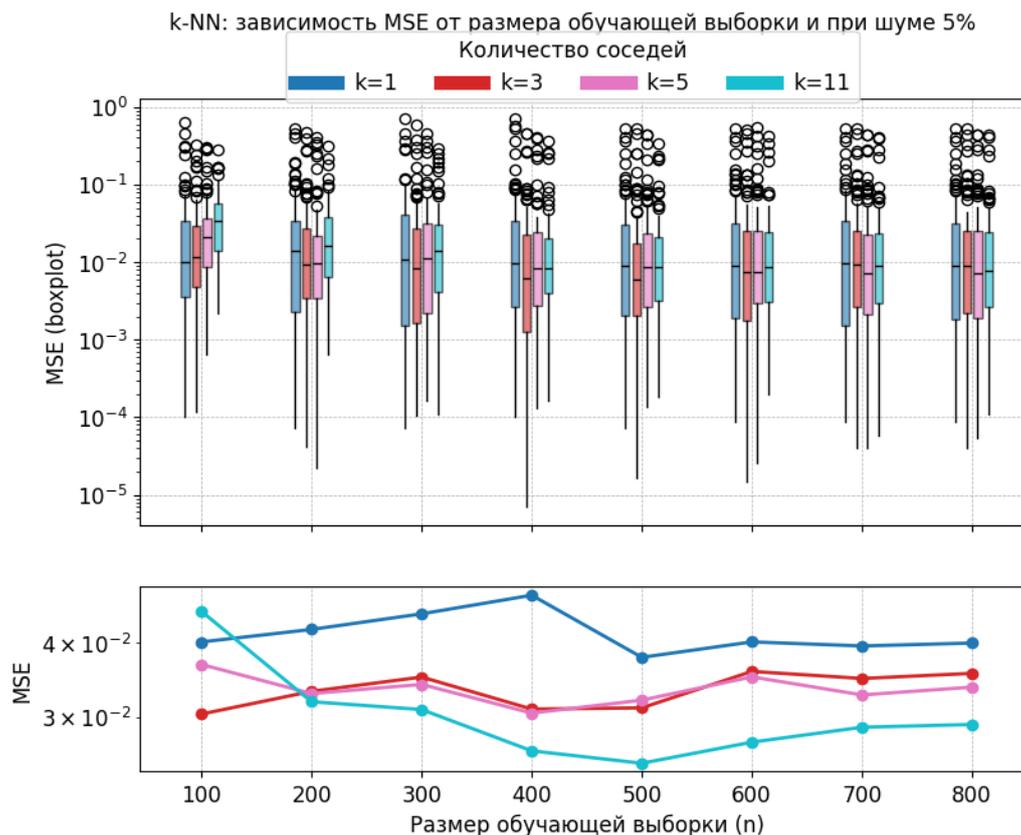


Рисунок 10 – Эволюция среднеквадратичной ошибки на тестовой выборке в зависимости от размера обучающей выборки и количества соседей при шуме 5 %
Figure 10 – Evolution of the mean squared error on the test set as a function of the training set size and the number of neighbors with 5 % noise

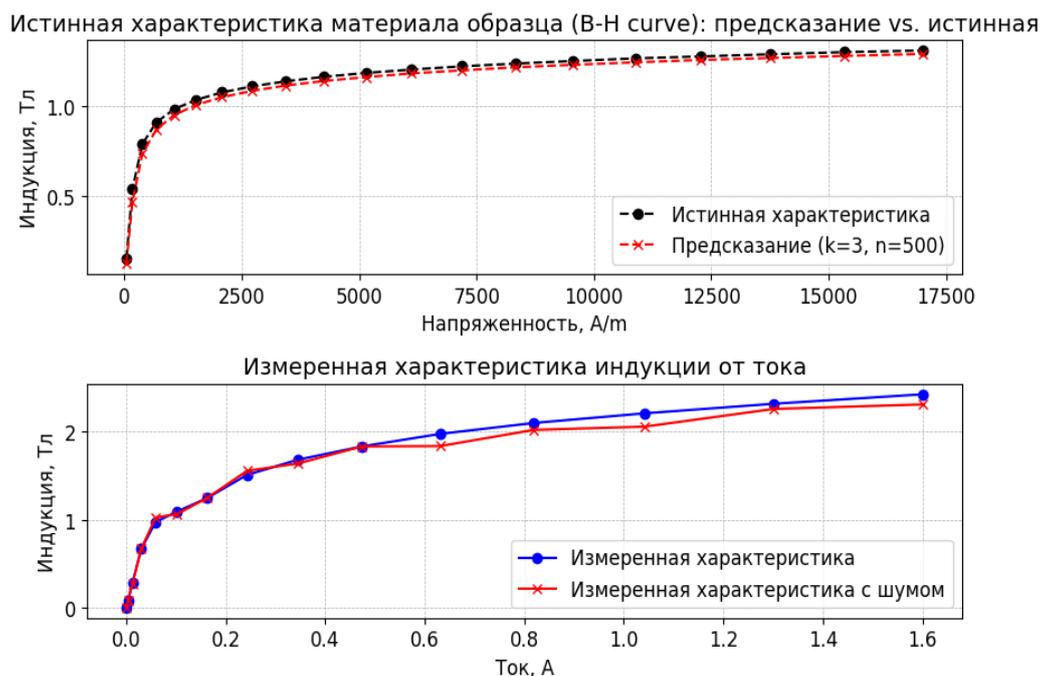


Рисунок 11 – Сравнение истинной характеристики образца и характеристики восстановленной моделью (k-ближайших соседей) при шуме 5 %
Figure 11 – Comparison of the true sample characteristic and the characteristic reconstructed by the model (k-Nearest Neighbors) with 5 % noise

Обсуждение

Полученные результаты показывают, что при добавлении аддитивного 5 % шума ко входному сигналу $x = \{B_k\}_{k=1}^m$ качество восстановления магнитной характеристики заметно ухудшается для всех рассмотренных алгоритмов, однако степень деградации различается (Таблица 1). Это подтверждает чувствительность обратной задачи к случайной погрешности измерений и необходимость учитывать робастность модели при выборе метода для практического применения.

На незашумленных данных наилучшие значения Mean, Median и Max демонстрирует градиентный бустинг, что отражает его высокую аппроксимирующую способность при отсутствии помех. Однако при добавлении 5 % аддитивного шума его ошибка возрастает на порядок. Это объясняется механизмом последовательного уточнения модели по остаткам: шумовые компоненты входного сигнала частично интерпретируются бустингом как структурная закономерность, что приводит к ухудшению обобщающей способности (классическое проявление проблемы баланса смещения и дисперсии ошибки).

Алгоритм Random Forest, напротив, демонстрирует наилучшее среднее и медианное качество на зашумленных данных, что прямо обусловлено снижением дисперсии за счет механизма бэггинга и усреднения предсказаний по слабокоррелированному ансамблю деревьев. При этом наличие большого значения Max MSE указывает на существование редких примеров (выбросов), для которых качество восстановления оказывается существенно хуже типичного уровня.

Лидерство метода kNN по показателю минимальной максимальной ошибки на зашумленных данных объясняется его метрической природой. Прогноз в kNN формируется как локальное плавное усреднение характеристик для k наиболее близких обучающих примеров, что исключает неконтролируемые скачки аппроксимирующей функции. Данная особенность минимизирует риск катастрофических ошибок, однако сопровождается повышенным смещением (более высокими значениями Mean и Median), то есть худшей точностью в типичном случае по сравнению с ансамблевыми методами.

Одиночное дерево CART и полиномиальная регрессия (SGD) демонстрируют наибольшую склонность к выбросам на зашумленных данных (высокие значения Max MSE). Для деревьев решений это связано с высокой дисперсией пороговой модели (чувствительностью к малым шумовым изменениям входных сигналов B_k , приводящим к смене ветви ветвления), а для регрессии – с глобальной природой полиномиальной аппроксимации, усиливающей влияние локальных шумовых искажений на весь прогнозируемый профиль $B(H)$.

Таким образом, выбор алгоритма определяется критерием применения: при минимизации средней (типичной) ошибки в шумном измерительном тракте предпочтителен Random Forest, тогда как при жесткой ориентации на гарантированную ошибку (худший случай) более безопасным и предсказуемым оказывается метрический регрессионный метод kNN (и близкие к нему по параметру Max MSE робастные конфигурации бустинга).

Заключение

В работе рассмотрена задача восстановления магнитной характеристики коротких образцов по косвенным измерениям магнитной индукции $x = \{B_k\}_{k=1}^m$ в измерительной системе с параллельным магнитным шунтом. Сформирована обучающая выборка объемом 900 пар «вход-выход» на основе численного моделирования при варьировании магнитной характеристики образца и тока намагничивания, после чего выполнено

сравнение пяти алгоритмов машинного обучения (SGD, CART, Random Forest, Gradient Boosting, kNN).

Проведена оценка влияния случайной погрешности измерений: моделирование аддитивного шума уровня 5 % во входных данных показало различную степень деградации качества восстановления у рассматриваемых методов. Представлены зависимости MSE от размера обучающей выборки при шуме и примеры восстановления магнитной характеристики по зашумленным входным данным, а также выполнено сводное сравнение по значениям средней и медианной MSE без шума и при шуме.

Полученные результаты могут быть использованы при выборе алгоритма для практического применения в измерительной системе с магнитным шунтом, где требуется устойчивое восстановление характеристики в условиях неизбежных погрешностей измерительного тракта.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Сурняев В.А., Блажко И.О., Блажкова Е.Н. и др. Применение магнитного шунта для повышения чувствительности устройства испытания образцов магнитоэлектрических материалов. *Инженерный вестник Дона*. 2021;(9). URL: <http://ivdon.ru/ru/magazine/archive/n9y2021/7200>
Surnyaev V.A., Blazhko I.O., Blazhkova E.N., et al. Application of a magnetic shunt to increase the sensitivity of a device for testing samples of magnetostrictive materials. *Engineering Journal of Don*. 2021;(9). (In Russ.). URL: <http://ivdon.ru/en/magazine/archive/n9y2021/7200>
2. Сурняев В.А., Сурняев Д.А. Устройство измерения магнитных характеристик магнитоэлектрических материалов. *Инженерный вестник Дона*. 2016;(4). URL: <http://ivdon.ru/ru/magazine/archive/n4y2016/3956>
Surnyaev V.A., Surnyaev D.A. Measuring device of the magnetic characteristics of the magnetostrictive materials. *Engineering Journal of Don*. 2016;(4). (In Russ.). URL: <http://ivdon.ru/en/magazine/archive/n4y2016/3956>
3. Hastie T., Tibshirani R., Friedman J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. New York: Springer; 2009. 745 p. <https://doi.org/10.1007/978-0-387-84858-7>
4. Pyle D. *Data Preparation for Data Mining*. San Francisco: Morgan Kaufmann Publishers; 1999. 540 p.
5. Kuhn M., Johnson K. *Feature Engineering and Selection: A Practical Approach for Predictive Models*. Boca Raton: CRC Press; 2019. 310 p.
6. Bottou L. Large-Scale Machine Learning with Stochastic Gradient Descent. In: *Proceedings of COMPSTAT'2010: 19th International Conference on Computational Statistics, 22–27 August 2010, Paris, France*. Heidelberg: Physica; 2010. P. 177–186. https://doi.org/10.1007/978-3-7908-2604-3_16
7. Breiman L., Friedman J., Olshen R.A., Stone Ch.J. *Classification and Regression Trees*. New York: Chapman and Hall/CRC; 1984. 368 p. <https://doi.org/10.1201/9781315139470>
8. Breiman L. Random Forests. *Machine Learning*. 2001;45(1):5–32. <https://doi.org/10.1023/A:1010933404324>
9. Friedman J.H. Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*. 2001;29(5):1189–1232. <https://doi.org/10.1214/aos/1013203451>
10. Cover T., Hart P. Nearest Neighbor Pattern Classification. *IEEE Transactions on Information Theory*. 1967;13(1):21–27. <https://doi.org/10.1109/TIT.1967.1053964>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Сурняев Виталий Андреевич, аспирант, Южно-Российский государственный политехнический университет (НПИ) имени М.И. Платова, Новочеркасск, Российская Федерация.

e-mail: vitaly.surnyaev@gmail.com

Vitalii A. Surnyaev, Postgraduate, Platov South-Russian State Polytechnic University (NPI), Novocherkassk, the Russian Federation.

Гречихин Валерий Викторович, доктор технических наук, доцент, профессор кафедры «Информационные и измерительные системы и технологии» Южно-Российского государственного политехнического университета (НПИ) имени М.И. Платова, Новочеркасск, Российская Федерация.

e-mail: vgrech@mail.ru

Valerii V. Grechikhin, Doctor of Engineering Sciences, Docent, Professor at the Department of Information and Measuring Systems and Technologies, Platov South-Russian State Polytechnic University (NPI), Novocherkassk, the Russian Federation.

Статья поступила в редакцию 12.01.2026; одобрена после рецензирования 04.03.2026; принята к публикации 16.03.2026.

The article was submitted 12.01.2026; approved after reviewing 04.03.2026; accepted for publication 16.03.2026.