

УДК 621.313.8
EDN: SQUKRZ

Ф.Р. Шайдуллин, Т.И. Петров
ФГБОУ ВО «Казанский государственный энергетический университет», Казань, Россия

АНСАМБЛЬ НЕЙРОСЕТЕВЫХ СУРРОГАТОВ С ОЦЕНКОЙ НЕОПРЕДЕЛЕННОСТИ ДЛЯ ОПТИМИЗАЦИИ РОТОРА СИНХРОННОГО ДВИГАТЕЛЯ

Объект и цель научной работы. Объектом исследования является синхронный двигатель с постоянными магнитами BM1418 ZXF, имеющими V-образное расположение. Цели – разработка ансамблевой нейросетевой суррогатной модели вращающего момента двигателя с количественной оценкой неопределенности предсказания, а также апробация схемы активного обучения с верификацией перспективных вариантов геометрии ротора методом конечных элементов (МКЭ).

Материалы и методы. Использован набор данных вариантов геометрии ротора, рассчитанных МКЭ в программе FEMM 4.2. Ансамбль многослойных перцептронов обучен по схеме агрегирования случайных наборов данных; оценка неопределенности формируется как нормированное стандартное отклонение предсказаний членов ансамбля.

Основные результаты. По сравнению с одиночным суррогатом ансамблевая модель снизила долю грубых ошибок предсказания и обеспечила количественную оценку надежности каждого прогноза. В ходе апробации схемы активного обучения выявлен вариант геометрии ротора с вращающим моментом, превышающим номинальное значение двигателя.

Закключение. Работа формирует теоретическую основу ансамблевого суррогатного моделирования с оценкой неопределенности для оптимизации роторов электрических машин. Практическое значение состоит в сокращении числа расчетов МКЭ при оптимизационном поиске за счет суррогатной оценки вариантов геометрии и автоматического отбора наиболее неопределенных из них для прямой верификации.

Ключевые слова: синхронный двигатель с постоянными магнитами, нейросетевой суррогат, ансамбль моделей, оценка неопределенности, активное обучение, метод конечных элементов, оптимизация геометрии ротора.

Авторы заявляют об отсутствии возможных конфликтов интересов.

UDC 621.313.8
EDN: SQUKRZ

F.R. Shaydullin, T.I. Petrov
Kazan State Power Engineering University, Kazan, Russia

NEURAL NETWORK SURROGATE ENSEMBLE WITH UNCERTAINTY ESTIMATION FOR ROTOR OPTIMIZATION OF A SYNCHRONOUS MOTOR

Object and purpose of research. The object of the study is a permanent magnet synchronous motor BM1418 ZXF with V-shaped rotor magnets. The purpose is to develop an ensemble neural network surrogate model of the motor's electromagnetic torque with quantitative uncertainty estimation and to validate an active learning scheme with finite element method verification of promising rotor geometry variants.

Materials and methods. A dataset of rotor geometry variants computed by the finite element method in FEMM 4.2 was used. An ensemble of multilayer perceptrons was trained using the bootstrap aggregation scheme; uncertainty is estimated as the normalised standard deviation of ensemble member predictions.

Main results. Compared to a single surrogate, the ensemble model reduced the number of gross prediction errors and provided a quantitative reliability estimate for each prediction. During the active learning trial, a rotor geometry variant was identified with electromagnetic torque exceeding the motor's nominal value.

Для цитирования: Шайдуллин Ф.Р., Петров Т.И. Ансамбль нейросетевых суррогатов с оценкой неопределенности для оптимизации ротора синхронного двигателя. Труды Крыловского государственного научного центра. 2026; 3(417): 109–114.

For citations: Shaydullin F.R., Petrov T.I. Neural network surrogate ensemble with uncertainty estimation for rotor optimization of a synchronous motor. Transactions of the Krylov State Research Centre. 2026; 3(417): 109–114 (in Russian).

Conclusion. The work provides a theoretical basis for ensemble surrogate modelling with uncertainty estimation in electric machine rotor optimisation; its practical value lies in reducing finite element method calculations during optimisation through surrogate-based screening and automatic selection of the most uncertain variants for direct verification.

Keywords: permanent magnet synchronous motor, neural network surrogate, ensemble of models, uncertainty estimation, active learning, finite element method, rotor geometry optimization.

The authors declare no conflicts of interest.

Введение

Introduction

Применение нейросетевых суррогатных моделей для ускорения оптимизации геометрии ротора синхронных двигателей с постоянными магнитами (СДПМ) обусловлено высокой длительностью одного обращения к расчету на основе метода конечных элементов: от нескольких десятков секунд до нескольких минут при числе итераций эволюционного поиска порядка тысяч [1, 2]. Суррогат, обученный на ограниченной выборке МКЭ-расчетов, сокращает время оценки одного варианта геометрии до единиц миллисекунд, что принципиально меняет вычислительную сложность задачи [3, 4].

Потребность в таких моделях подчеркивается в работе [5], где оптимизация ротора СДПМ генетическим алгоритмом с прямым МКЭ-расчетом на каждой итерации потребовала нескольких тысяч вычислительно трудоемких расчетов. Среди подходов к построению суррогатов электрических машин [6] наиболее распространены многослойные перцептроны, обеспечивающие быструю оценку момента при малом числе варьируемых параметров. Обзор методов оптимизации роторов СДПМ приведен в [7].

На первом этапе настоящей работы построена одиночная нейросетевая модель вращающего момента СДПМ ВМ1418 ZXF на основе многослойного перцептрона: при обучении на 500 МКЭ-расчетах получены коэффициент детерминации $R^2 = 0,9956$ и средняя относительная погрешность 2,10 % при времени одной оценки около 5 мс.

Вместе с тем одиночный суррогат не позволяет оценить надежность конкретного предсказания: модель возвращает единственное числовое значение момента без указания на то, насколько это значение можно считать достоверным. Это имеет практические последствия при оптимизационном поиске: суррогат с высокой уверенностью может давать грубые ошибки в тех областях пространства параметров, которые недостаточно представлены в обучающей выборке, и алгоритм оптимизации не получает сигнал о необходимости перепроверки результата прямым МКЭ-расчетом.

В работе [8] показано, что замена единственного суррогата ансамблем нескольких независимых моде-

лей повышает точность предсказания и, что принципиально важно, позволяет количественно оценить неопределенность через разброс предсказаний членов ансамбля. Аналогичный подход реализован в [9] при многопараметрической оптимизации СДПМ на основе суррогатной нейросетевой модели, а в [10] ансамблевая мера неопределенности применяется как критерий отбора точек для дополнительных МКЭ-расчетов в рамках активного обучения.

Таким образом, нерешенной остается задача обеспечения предсказания суррогата сопутствующей оценкой неопределенности, достаточной для автоматизированного принятия решения о необходимости верификации варианта прямым МКЭ-расчетом.

Цели настоящей работы – разработка и экспериментальная проверка ансамблевой нейросетевой суррогатной модели вращающего момента СДПМ с оценкой неопределенности методом агрегирования случайного набора данных, а также сравнительная оценка ее точности относительно одиночной модели на независимой тестовой выборке из 100 МКЭ-расчетов.

Материалы и методы

Materials and methods

Объект исследования и базовая конечно-элементная модель. Объектом является СДПМ ВМ1418 ZXF мощностью 350 Вт, напряжением 48 В, номинальной частотой вращения 450 об/мин и номинальным вращающим моментом 7 Н·м с V-образным расположением постоянных магнитов. Конечно-элементная модель реализована в программе FEMM 4.2 с автоматизацией на языке Python; вращающий момент определялся методом интегрирования тензора Максвелла по воздушному зазору. Трехмерное параметрическое пространство задается коэффициентом масштабирования ширины магнита $k_w \in [0,70; 1,30]$, толщиной магнита $b \in [2,1; 3,9]$ мм и приращением угла V-конфигурации $\Delta\phi \in [-12,0; +12,0]^\circ$.

Основной набор данных составляют 500 вариантов топологии ротора и соответствующих значений вращающего момента, полученных МКЭ-расчетами в FEMM 4.2 по плану латинского гиперкуба (LHS). Диапазон значений вращающего момента охватывает 2,55–7,00 Н·м, где верхняя граница соответствует

номинальному моменту, достигаемому исходной конструкцией ротора. На этом наборе обучались обе сравниваемые системы. Дополнительно по тому же плану LHS рассчитаны отдельные 100 вариантов, не вошедших в обучение ни одной из моделей. Они составили фиксированную тестовую выборку. Обе сравниваемые системы (одиночный суррогат и ансамбль) верифицированы на одних и тех же 100 тестовых вариантах.

Архитектура одиночного суррогата. В качестве базовой модели разработан многослойный перцептрон (MLP) с тремя скрытыми слоями по 64, 128 и 64 нейрона соответственно; входной слой принимает три параметра геометрии, выходной – единственное скалярное значение вращающего момента. Каждый скрытый слой включает пороговую линейную функцию активации (ReLU); обучение выполнено алгоритмом адаптивной оценки момента (Adam) с регуляризацией параметров ($\lambda = 10^{-4}$), стратегией снижения темпа обучения при остановке прогресса и сохранением лучших весов по минимуму ошибки на проверочном подмножестве (20 % обучающей выборки) за 500 эпох. При обучении на полном наборе данных из 500 вариантов и верификации на независимой тестовой выборке из 100 вариантов модель обеспечила $R^2 = 0,9956$ и среднюю относительную погрешность 2,10 %. Та же архитектура без изменений использована в качестве каждого члена ансамбля, чтобы чистый эффект агрегирования не смешивался с эффектом изменения архитектуры.

Агрегирование случайных наборов данных. Ансамбль из пяти моделей строится следующим образом: каждая модель обучается на случайной выборке с повторениями объемом N из полного обучающего набора данных размером $N = 500$ вариантов. Такая схема обеспечивает декорреляцию ошибок членов ансамбля: каждая модель обучается на уникальной совокупности вариантов и видит в среднем около 63 % уникальных точек от полного обучающего множества. Архитектура и параметры обучения каждой модели ансамбля идентичны одиночному суррогату.

Оценка неопределенности предсказания строится в два шага. Сначала вычисляется стандартное отклонение предсказаний членов ансамбля:

$$\sigma(x) = \sqrt{\frac{1}{K} \sum_{k=1}^K (f_k(x) - \hat{M}(x))^2}, \quad (1)$$

где $\hat{M}(x)$ – среднее предсказание ансамбля. Затем стандартное отклонение нормируется на величину предсказания:

$$u(x) = \frac{\sigma(x)}{|\hat{M}(x)|} \cdot 100 \%. \quad (2)$$

Если $u(x)$ превышает заданный порог, вариант считается неопределенным и направляется на верификацию прямым МКЭ-расчетом. Выбор порога влияет на баланс между числом МКЭ-расчетов и риском принять неточное предсказание: при меньшем пороге верификация выполняется чаще, но ошибочных решений меньше.

Результаты

Results

Сравнение точности одиночного суррогата и ансамбля. На тестовой выборке из 100 вариантов ансамбль достиг средней относительной погрешности (MAPE) 2,55 % и средней абсолютной погрешности (MAE) 0,119 Н·м против MAPE 2,85 % и MAE 0,120 Н·м у одиночного суррогата; число предсказаний с погрешностью свыше 5 % снижено с 16 до 10. Коэффициент детерминации R^2 у ансамбля незначительно ниже: 0,988 против 0,990. Среднеквадратическая погрешность (RMSE) составила 0,195 Н·м у ансамбля и 0,176 Н·м у одиночного суррогата, что обусловлено рядом аномальных точек в области высоких значений момента, где усредненное предсказание ансамбля систематически отклоняется от результата МКЭ-расчета.

Различие по R^2 лежит в пределах статистического разброса нейросетевого обучения и не свидетельствует о практически значимом снижении качества. Дополнительно рассчитан ранговый коэффициент корреляции Спирмена между оценкой неопределенности $u(x)$ и фактической погрешностью предсказания как мера качества калибровки суррогатной модели. На рис. 1 (см. вклейку) показаны диаграммы рассеяния «предсказание – МКЭ» для обеих моделей; штриховыми линиями обозначен коридор $\pm 5 \%$.

Оценка неопределенности ансамбля. На рис. 2 (см. вклейку) показана взаимосвязь между оценкой неопределенности ансамбля и фактической относительной погрешностью предсказания для всех 100 тестовых вариантов.

Максимальная относительная неопределенность на тестовой выборке составила 3,1 %, средняя – около 1,5 %. Корреляция между относительной оценкой и фактической погрешностью невысока: коэффициент Спирмена $\rho = 0,17$, что указывает на слабую калибровку неопределенности. При использовании порога верификации, равного 5 %, ни один из 100 вариантов не активирует МКЭ-проверку, поскольку максимальная неопределенность не достигает этого порога. Снижение порога до 2 % затронет 32 из 100 вариантов с наибольшей неопределенностью; при 3 % – семь вариантов. Это означает, что для применения схемы

активного обучения на данном наборе данных необходимо использовать порог не выше 2–3 %.

Апробация схемы активного обучения. Для проверки работоспособности полной процедуры ансамблевого предсказания с оценкой неопределенности и МКЭ-верификацией проведен 10-цикловый эксперимент с реальными конечно-элементными расчетами в FEMM 4.2. Начальный набор данных составлял 500 вариантов. В каждом цикле ансамбль оценивал 1000 новых кандидатов, сгенерированных методом латинского гиперкуба по всему параметрическому пространству; в отличие от фиксированной тестовой выборки из 100 вариантов, среди 1000 случайных кандидатов встречались варианты из малоизученных областей, где неопределенность превышала 5 %. Поэтому в схеме активного обучения был выбран порог 5 %: на прямой МКЭ-расчет направлялись в пропорции 3:2 – три варианта с неопределенностью выше 5 % и два варианта с наибольшим оценочным моментом среди точек с неопределенностью ниже 5 %; число расчетов за цикл не превышало пяти. После каждого цикла ансамбль переобучался на расширенном наборе данных. Результаты представлены в табл. 1 (см. вклейку) и на рис. 3 (см. вклейку).

В ходе эксперимента MAE снижена с 92,1 мН·м до 71,6 мН·м. Коэффициент детерминации улучшился с 0,9938 до 0,9965. Среднее время одного МКЭ-расчета составило 63–67 с. Характерной особенностью эксперимента является монотонный рост доли кандидатов с высокой неопределенностью: с 24 % в первом цикле до 78 % в десятом цикле. Это явление объясняется механизмом активного обучения: при устранении неопределенности в одних областях пространства параметров ансамбль обнаруживает новые нелинейные зоны в случайно сгенерированных наборах вариантов. Большая доля кандидатов с высокой неопределенностью начиная с пятого цикла указывает на то, что пространство параметров СДПМ содержит обширные нелинейные области, предсказание в которых требует значительно большего числа итераций обучения для равномерного охвата набора данных.

Вторым важным наблюдением является рост лучшего верифицированного МКЭ-результата в ходе активного обучения: с 5,22 Н·м в первом цикле до 7,13 Н·м в девятом цикле, что превышает номинальный вращающий момент двигателя на 1,9 % и свидетельствует о способности предложенного метода обнаруживать варианты геометрии ротора с улучшенными характеристиками уже при ограниченном числе МКЭ-расчетов. При этом ансамбль систематически завышает момент: расхождение между лучшей ансамблевой оценкой и лучшим верифи-

цированным МКЭ-результатом выросло с 0,37 Н·м в первом цикле до 1,05 Н·м в десятом цикле, что объясняется экстраполяцией суррогата в области высоких значений момента, недостаточно представленных в обучающей выборке.

Обсуждение

Discussion

Полученные результаты подтверждают следующее наблюдение: ансамбль суррогатных моделей, обученных на случайных выборках, снижает число значительных ошибок по сравнению с одиночной моделью. Снижение числа вариантов с ошибкой на 37,5 % является практически значимым результатом: именно эти ошибочные предсказания наиболее критичны при оптимизационном поиске, поскольку способны направить алгоритм оптимизации к недостоверному оптимальному решению, подтвержденному лишь суррогатом. В работе [8] переход от одиночной модели к комбинированному ансамблю из четырех различных алгоритмов дал снижение среднеквадратичной ошибки на 15–20 % при многоцелевой оптимизации высокомоментного СДПМ с десятью параметрами.

В то же время слабая корреляция неопределенности с фактической погрешностью ($\rho = 0,17$) означает, что текущая схема не является полноценным индикатором сложных зон параметрического пространства. Ключевая причина состоит в однородности архитектуры: все пять суррогатов обучены на данных из одного и того же распределения и разнятся случайным выбором обучающих примеров и начальной инициализацией весов. Большинство ошибочных предсказаний сосредоточено в экстремальных зонах параметрического пространства – вблизи углов гиперкуба, где плотность обучающих точек минимальна. В таких зонах все пять моделей имеют систематическую погрешность одного знака, и их согласованное, но неверное предсказание дает малое стандартное отклонение при большой фактической ошибке.

Усиление дисперсии ансамбля за счет разнородных архитектур или алгоритмов могло бы улучшить калибровку неопределенности, однако выходит за рамки настоящей работы. В сравнении с работой [5] предложенная архитектура формирует методологическую основу для ускорения аналогичного оптимизационного поиска: ансамблевый суррогат обеспечивает быструю оценку тысяч кандидатов, а показатель неопределенности определяет допустимый порог доверия к этим оценкам.

Относительное ухудшение RMSE у ансамбля (0,195 против 0,176 Н·м у одиночного суррогата) обу-

словлено несколькими выбросами в области высоких значений момента (более 8 Н·м), где отдельные члены ансамбля имеют существенно расходящиеся предсказания, а среднее смещается от МКЭ-значения. Данные выбросы соответствуют трем-четырем вариантам; их устранение потребовало бы расширения обучающей выборки в области высоких значений коэффициента масштабирования ширины магнитов и больших площадей сечения магнита – задача, которую как раз и должна решать процедура активного обучения в последующих итерациях [10].

Результаты 10-циклового эксперимента по активному обучению подтверждают масштабируемость предложенного метода. MAE снизилась на 24 %, рост доли неопределенных кандидатов согласуется с моделью активного обучения, описанной в [10]: по мере устранения неопределенности в исследованных зонах ансамбль выявляет новые малоизученные области. Наблюдаемое увеличение количества неопределенных вариантов указывает на то, что десять циклов с числом МКЭ-расчетов не более пяти за цикл недостаточны для равномерного охвата – для достижения равномерности в аналогичных задачах оптимизации СДПМ авторы [10] рекомендуют 30–50 циклов. Тем не менее десять проведенных циклов достаточны для подтверждения работоспособности метода.

Выводы

Conclusion

Разработана и верифицирована ансамблевая нейросетевая суррогатная модель вращающего момента СДПМ BM1418 ZXF, основанная на агрегировании пяти независимо обученных многослойных перцептронов с одинаковой архитектурой. На тестовой выборке из 100 независимых МКЭ-расчетов ансамбль достиг $R^2 = 0,988$, MAPE = 2,55 %, MAE = 0,119 Н·м. По сравнению с одиночным суррогатом число предсказаний с относительной погрешностью свыше 5 % снижено с 16 до 10, что соответствует уменьшению числа грубых ошибок на 37,5 %.

Ансамбль дополнительно формирует оценку неопределенности для каждого варианта геометрии. На текущей тестовой выборке значения неопределенности не превысили 3,1 %, а корреляция неопределенности с фактической погрешностью оказалась незначительной, что обусловлено однородностью архитектуры членов ансамбля и систематическим характером ошибок в экстремальных зонах параметрического пространства. Единственный вариант с одновременно высокой неопределенностью 3,1 % и высокой факти-

ческой ошибкой 11,5 % подтвердил принципиальную работоспособность данного метода.

Проведена экспериментальная апробация схемы активного обучения в десяти последовательных циклах с реальными МКЭ-расчетами. Минимальная MAE ансамбля на контрольной выборке составила 70,1 мН·м в восьмом цикле; по завершении всех десяти циклов – 71,6 мН·м из-за добавления новых вариантов в малоизученных зонах. R^2 ко второй половине эксперимента стабилизировался на уровне 0,9965. Лучшее верифицированное МКЭ-значение вращающего момента выросло с 5,22 Н·м до 7,13 Н·м, превысив номинальный момент двигателя на 1,9 %, что демонстрирует способность предложенного подхода не только повышать точность суррогата, но и обнаруживать варианты геометрии ротора с улучшенными характеристиками. Доля кандидатов с высокой неопределенностью за десять циклов выросла с 24 % до 78 %, что подтверждает способность ансамбля выявлять нелинейные зоны пространства параметров, недостаточно охваченные начальной выборкой.

В рамках дальнейших исследований планируются: проверка зависимости точности от числа членов ансамбля; анализ влияния порога неопределенности на эффективность активного обучения; проведение полного оптимизационного поиска на окончательной версии суррогата.

Результаты исследования получены при финансовой поддержке Министерства науки и высшего образования РФ в рамках государственного задания № 075-03-2026-543 от 16.01.2026 по теме «Разработка инновационных компонентов для электромобилей различного климатического исполнения с использованием технологии цифрового двойника».

Список использованной литературы

1. Multi-objective optimization of PMSM servo system control performance based on artificial neural network and genetic algorithm / F. Li, X. Li, H. Hou, X. Xie // Applied Sciences. 2025. Vol. 15, № 18. P. 10280. DOI: 10.3390/app151810280.
2. Разработка метода топологической оптимизации электрических машин на основе генетического алгоритма / А.Р. Сафин, Р.Р. Хуснутдинов, А.М. Копылов [и др.] // Вестник Казанского государственного энергетического университета. 2018. № 4(40). С. 77–85.
3. Мартынов В.А., Голубев А.Н. Моделирование электромагнитных процессов в многофазных синхронных двигателях с постоянными магнитами // Электричество. 2013. № 9. С. 37–41.
4. Голубев А.Н., Мартынов В.А., Алейников А.В. Разработка уточненной математической модели синхронного

- двигателя с постоянными магнитами для расчетов в реальном времени // Вестник Ивановского государственного энергетического университета. 2017. № 5. С. 37–43. DOI: 10.17588/2072-2672.2017.5.037-043.
5. *Петров Т.И.* Модификация генетического алгоритма для комплексной топологической оптимизации ротора синхронных двигателей // Известия высших учебных заведений. Проблемы энергетики. 2021. Т. 23, № 3. С. 70–79. DOI: 10.30724/1998-9903-2021-23-3-70-79.
6. Surrogate Modeling of Electrical Machine Torque Using Artificial Neural Networks / *M. Tahkola, J. Keränen, D. Sedov* [et al.] // IEEE Access. 2020. Vol. 8. P. 220027–220045. DOI: 10.1109/ACCESS.2020.3042834.
7. *Майоров А.А., Сафин А.Р.* Методы оптимизации роторов синхронных электродвигателей с постоянными магнитами // Известия высших учебных заведений. Проблемы энергетики. 2024. Т. 26, № 3. С. 50–65. DOI: 10.30724/1998-9903-2024-26-3-50-65.
8. Multi-Objective Optimization Strategy for Permanent Magnet Synchronous Motor Based on Combined Surrogate Model and Optimization Algorithm / *Y. Yu, Y. Pan, Q. Chen* [et al.] // Energies. 2023. Vol. 16, No. 4. 1630. DOI: 10.3390/en16041630.
9. *Li Z., Huang M., Wang Z.* Surrogate-Assisted Multi-Objective Optimization of Interior Permanent Magnet Synchronous Motors with a Limited Sample Size // Applied Sciences. 2025. Vol. 15, No. 8. 4259. DOI: 10.3390/app15084259.
10. Ensemble Surrogates and NSGA-II with Active Learning for Multi-Objective Optimization of WAG Injection in CO₂-EOR / *Y. Zhu, H. Li, Y. Zheng* [et al.] // Energies. 2025. Vol. 18, No. 24. 6575. DOI: 10.3390/en18246575.
5. *Petrov T.I.* Modification of genetic algorithm for integrated topological optimization of synchronous motor rotor // Power Engineering: Research, Equipment, Technology. 2021. Vol. 23, No. 3. P. 70–79. DOI: 10.30724/1998-9903-2021-23-3-70-79 (in Russian).
6. Surrogate Modeling of Electrical Machine Torque Using Artificial Neural Networks / *M. Tahkola, J. Keränen, D. Sedov* [et al.] // IEEE Access. 2020. Vol. 8. P. 220027–220045. DOI: 10.1109/ACCESS.2020.3042834.
7. *Maierov A.A., Safin A.R.* Optimization methods for of permanent-magnet synchronous motor rotors // Power Engineering: Research, Equipment, Technology. 2024. Vol. 26, No. 3. P. 50–65. DOI: 10.30724/1998-9903-2024-26-3-50-65 (in Russian).
8. Multi-Objective Optimization Strategy for Permanent Magnet Synchronous Motor Based on Combined Surrogate Model and Optimization Algorithm / *Y. Yu, Y. Pan, Q. Chen* [et al.] // Energies. 2023. Vol. 16, No. 4. 1630. DOI: 10.3390/en16041630.
9. *Li Z., Huang M., Wang Z.* Surrogate-Assisted Multi-Objective Optimization of Interior Permanent Magnet Synchronous Motors with a Limited Sample Size // Applied Sciences. 2025. Vol. 15, No. 8. 4259. DOI: 10.3390/app15084259.
10. Ensemble Surrogates and NSGA-II with Active Learning for Multi-Objective Optimization of WAG Injection in CO₂-EOR / *Y. Zhu, H. Li, Y. Zheng* [et al.] // Energies. 2025. Vol. 18, No. 24. 6575. DOI: 10.3390/en18246575.

References

1. Multi-objective optimization of PMSM servo system control performance based on artificial neural network and genetic algorithm / *F. Li, X. Li, H. Hou, X. Xie* // Applied Sciences. 2025. Vol. 15, № 18. P. 10280. DOI: 10.3390/app151810280.
2. Development of topological optimization method for electric machines based on genetic algorithms / *A.R. Saifin, R.R. Khusnutdinov, A.M. Kopylov* [et al.] // Transactions of Kazan State Power Engineering University. 2018. No. 4(40). P. 77–85 (in Russian).
3. *Martynov V.A., Golubev A.N.* Simulation of electromagnetic processes in multi-phase synchronous motors with permanent magnets // Elektrichestvo (Electricity). 2013. No. 9. P. 37–41 (in Russian).
4. *Golubev A.N., Martynov V.A., Aleynikov A.V.* Development of refined mathematical model of permanent-magnet synchronous motor for real-time calculations // Vestnik (Transactions) of Ivanovo State Power Engineering University. 2017. No. 5. P. 37–43. DOI: 10.17588/2072-2672.2017.5.037-043 (in Russian).

Сведения об авторах

Шайдуллин Фаиль Рамисович, аспирант кафедры «Электроснабжение промышленных предприятий» ФГБОУ ВО «Казанский государственный энергетический университет». Адрес: 420066, Россия, Казань, Красносельская ул., д. 51. E-mail: fail1999@yandex.ru.

Петров Тимур Игоревич, к.т.н., заведующий кафедрой «Электроснабжение промышленных предприятий» ФГБОУ ВО «Казанский государственный энергетический университет». Адрес: 420066, Россия, Казань, Красносельская ул., д. 51. E-mail: tobac15@mail.ru.

About the authors

Fail R. Shaidullin, Post-Graduate, Electric Power Supply of Industrial Facilities Department, Kazan State Power Engineering University. Address: 51, Krasnoselskaya st., Kazan, Russia, post code 420066. E-mail: fail1999@yandex.ru.

Timur I. Petrov, Cand. Sci. (Eng.), Head of Electric Power Supply of Industrial Facilities Department, Kazan State Power Engineering University. Address: 51, Krasnoselskaya st., Kazan, Russia, post code 420066. E-mail: tobac15@mail.ru.

Поступила / Received: 30.04.26
Принята в печать / Accepted: 27.07.26
© Шайдуллин Ф.Р., Петров Т.И., 2026




Рис. 1. Диаграммы рассеяния предсказаний суррогата и результатов МКЭ-расчета на тестовой выборке:
а) одиночный суррогат; б) ансамбль из пяти моделей

Fig. 1. Scatter plots of surrogate predictions against finite element method calculation results on the test set:
а) single surrogate; б) ensemble of five models




Рис. 2. Связь неопределенности ансамбля с фактической погрешностью предсказания момента.
Красные точки – варианты с ошибкой свыше 5 %; пунктир – линия тренда

Fig. 2. Relation between ensemble uncertainty and actual torque prediction error; red points – variants with error above 5 %; dashed line – trend line

Таблица 1. Результаты десяти циклов активного обучения

Table 1. Result of ten active learning cycles

Цикл	Неопределенность, %	Лучший момент по оценке ансамбля, Н·м	Реальное значение, Н·м	MAE, мН·м	R^2
1	24	5,59	5,22	92,1	0,9938
2	30	6,30	5,37	92,4	0,9923
3	39	6,72	6,61	83,5	0,9955
4	40	7,09	6,35	83,1	0,9954
5	61	7,42	6,59	78,1	0,9962
6	60	7,33	6,96	75,2	0,9961
7	66	8,12	7,02	81,8	0,9933
8	75	7,60	6,97	70,1	0,9962
9	69	8,21	7,13	71,9	0,9965
10	78	8,11	7,06	71,6	0,9965




Рис. 3. Динамика MAE ансамбля и коэффициента детерминации по результатам активного обучения

Fig. 3. Dynamics of ensemble MAE and coefficient of determination following active learning