

Особенности разработки метамоделей на основе нейронных сетей для задач индукционного нагрева

Ф. В. Чмиленко, Ю. Ю. Перевалов, В. Е. Пармёнов✉, Чжан Ци, Ю. В. Шанин

Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина), Санкт-Петербург, Россия

✉ parmenov.slava@yandex.ru

Аннотация. Рассматриваются особенности создания метамоделей для мультифизических нелинейных процессов, протекающих во время индукционного нагрева. В качестве примера приводится разработка метамоделей для индукционного нагрева под ковку цилиндрических заготовок диаметром от 80 до 200 мм из стали 45 в режиме постоянной удельной мощности. Рассматривается четыре этапа разработки метамоделей. На первом этапе с помощью численной одномерной сопряженной нелинейной электротепловой модели была создана база данных, в которой были собраны входные параметры, задающие геометрию и режим работы индукционной системы, и выходные, характеризующие ее работу. Выходные параметры были разделены на интегральные и распределенные во времени. На втором этапе к распределенным во времени параметрам был применен метод главных компонент для снижения размерности данных. Этот прием помогает увеличить скорость обучения нейронных сетей и снизить количество требуемых нейронов. На третьем этапе было проведено обучение нейронных сетей для аппроксимации каждого выходного параметра базы данных. На заключительном этапе обученные нейронные сети были собраны в одной программе для демонстрации работы созданной метамоделей в режиме реального времени. Созданная на основе нейронных сетей модель обеспечивает в реальном времени хорошую аппроксимацию параметров индукционного нагрева, поэтому внедрение метамоделей в системы управления или в пакеты для автоматического проектирования индукционных установок чрезвычайно перспективно.

Ключевые слова: индукционный нагрев, кузнечный нагрев, метамоделей, нейронные сети, искусственный интеллект, регрессия, метод главных компонент

Для цитирования: Особенности разработки метамоделей на основе нейронных сетей для задач индукционного нагрева / Ф. В. Чмиленко, Ю. Ю. Перевалов, В. Е. Пармёнов, Чжан Ци, Ю. В. Шанин // Изв. СПбГЭТУ «ЛЭТИ». 2024. Т. 17, № 7. С. 83–96. doi: 10.32603/2071-8985-2024-17-7-83-96.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Original article

Metamodels Based on Neural Networks for Induction Heating Problems Development Features

F. V. Chmilenko, Yu. Yu. Perevalov, V. E. Parmenov✉, Zhang Qi, Yu. V. Shanin

Saint Petersburg Electrotechnical University, Saint Petersburg, Russia

✉ parmenov.slava@yandex.ru

Abstract. Discusses the peculiarities of creating metamodels for multi-physics nonlinear processes occurring during induction heating. As an example, the development of a metamodel describing the process of induction heating when forging cylindrical billets made of 45 steel with diameters ranging from 80 to 200 mm under constant specific power mode is presented. Four stages of metamodel development are considered. In the first stage, using a numerical one-dimensional conjugate nonlinear electrothermal model, a database was created in which the input parameters defining the geometry and operating mode of the induction system and the output

characterizing its operation were collected. The output parameters were divided into integral and time-distributed ones. In the second stage, the principal component method was applied to the time-distributed parameters to reduce data dimensionality. This approach enables the speed of neural network training to be increased and the number of required neurons to be reduced. In the third stage, neural networks were trained to approximate each output parameter of the database. In the final stage, the trained neural networks were integrated into a single program to demonstrate the operation of the created metamodel in real-time mode. The model based on neural networks provides good approximation of induction heating parameters in real-time, thus rendering the integration of metamodels into control systems or into packages for automatic design of induction installations highly promising.

Keywords: induction heating, forging heating, metamodel, neural networks, artificial intelligence, regression, principal component analysis

For citation: Metamodels Based on Neural Networks for Induction Heating Problems Development Features / F. V. Chmilenko, Yu. Yu. Perevalov, V. E. Parmenov, Zhang Qi, Yu. V. Shanin // LETI Transactions on Electrical Engineering & Computer Science. 2024. Vol. 17, no. 7. P. 83–96. doi: 10.32603/2071-8985-2024-17-7-83-96.

Conflict of interest. The authors declare no conflicts of interest.

Введение. Устройства индукционного нагрева получили широкое распространение в технологиях термообработки металлов и проводящих материалов. Сами по себе они – сложные технические объекты, в которых протекают физические процессы различной природы, и для успешной реализации технологии необходим всеобъемлющий анализ, который возможен только с помощью численного моделирования. Поэтому с появлением доступной для научной и инженерной деятельности вычислительной техники примерно с середины 70-х гг. прошлого века численные методы расчета и моделирования электромагнитных и температурных полей при индукционном нагреве стали очень востребованы и быстро развивались. За 50 лет эволюции численное моделирование индукционного нагрева прошло путь от исследования отдельных аспектов до создания программных комплексов, моделирующих сопряженные нелинейные процессы не только для задач проектирования, но и для задач управления [1].

В настоящий момент цифровизация систем индукционного нагрева для термообработки проходит путь от численного моделирования электротепловых полей и связанных процессов до построения цифровых двойников, что отвечает требованиям стратегии «Индустрия 4.0» для прогнозирования и оптимизации производственной системы в режиме реального времени.

Однако при разработке цифровых двойников для индукционных нагревательных систем необходимо учитывать ряд особенностей. В отличие от трансформаторов, для которых цифровые двойники могут быть созданы на основе схем замещения и аналитических методов [2], цифро-

вые двойники для индукционных установок должны учитывать сильные нелинейности, вызванные неравномерным температурным полем в загрузке. В связи с этим для разработки цифровых двойников индукционных установок вместо цепей замещения представляется перспективным использовать метамодели (модели, описывающие другие модели). Возможности применения метамodelей для технологии индукционной закалки демонстрируются в работах французских исследователей [3], [4].

В данной статье авторы рассматривают особенности разработки метамodelей для кузнечных индукционных нагревателей с помощью нейронных сетей, обобщающих результаты численной модели.

Постановка задачи. В качестве объекта исследования для оценки возможности использования нейронных сетей в задачах индукционного нагрева была выбрана технология непрерывного нагрева цилиндрических заготовок перед ковкой с нагревом поверхности до 1250 °С при конечном теплоперепаде 100 °С. В этом случае система индукционного нагрева достаточно проста и протяженна в пространстве, что позволяет ограничиться одномерной нелинейной электротепловой моделью по радиусу сечения цилиндра и пренебречь краевыми эффектами, возникающими на торцах.

Для создания базы данных использовалась одномерная электротепловая модель из пакета «Ind Heat», разработанная в СПбГЭТУ «ЛЭТИ» [5]. Расчеты проводились для заготовок диаметром от 80 до 200 мм с толщиной футеровки от 5 до 30 мм и с воздушным зазором от 5 до 20 мм. Для заготовок разного диаметра были свои диапазоны частот в зависимости от показателя степени

поверхностного эффекта m_2 , который выбирался в пределах от 2.5 до 5 согласно рекомендациям, данным в [6]. Все расчеты проводились в режиме постоянной удельной мощности на поверхности, поэтому основные результаты расчетов, входящие в базу данных, представлены удельной мощностью на поверхности заготовки и временем, требуемым для достижения заданной температуры.

Помимо основных результатов одномерная модель позволяет получать также интегральные и распределенные во времени параметры. В связи с этим база данных была разделена по содержанию на две части. В первой части помимо мощности и времени собирались также электрический, тепловой и полный интегральные КПД и интегральный коэффициент мощности. Во второй части собирались параметры, изменяемые во времени, – температура (на поверхности, в центре, средняя), КПД (полный, электрический, тепловой), коэффициент мощности, напряженность электромагнитного поля на поверхности цилиндра, напряжение одновиткового индуктора. Все расчетные параметры модели – это технологически важные параметры индукционного нагрева: коэффициент мощности позволяет выбрать компенсирующую емкость, напряженность электромагнитного поля по закону полного тока связана с током индуктора, а из напряжения одновиткового индуктора можно получить напряжение на витках многовиткового индуктора.

Численная модель (ЧМ). Установки индукционного нагрева – это сложные технические объекты, в которых протекают нелинейные физические процессы различной природы, и для их успешной реализации необходимо численное моделирование. Сопряженную нелинейную электротепловую модель имеет смысл реализовать с помощью метода конечных разностей или метода конечных элементов. Так как в общей постановке задачи нет привязки к форме индуктора (требуется найти удельную поверхностную мощность), то можно обойтись решением в одномерной постановке. Система нелинейных дифференциальных уравнений электромагнитного поля и теплопроводности для нагрева длинного цилиндра в продольном магнитном поле имеет вид [7], [8]

$$\frac{1}{R} \frac{\partial}{\partial R} \left(\rho(T) R \frac{\partial \dot{H}}{\partial R} \right) = j \omega \mu_0 \mu (\dot{H}, T) \dot{H}, \quad (1)$$

$$\gamma(T) C(T) \frac{\partial T}{\partial t} - \frac{1}{R} \frac{\partial}{\partial R} \left(\lambda(T) R \frac{\partial T}{\partial R} \right) = q, \quad (2)$$

где R – пространственная координата от центра к поверхности цилиндра; ρ – удельное сопротивление; T – температура; H – комплексная напряженность магнитного поля; j – мнимая единица; ω – круговая частота; μ_0 – магнитная проницаемость вакуума; μ – относительная магнитная проницаемость; γ – плотность; C – теплоемкость; λ – теплопроводность; $q = \rho(T) R \left| \frac{\partial \dot{H}}{\partial R} \right|^2$ – удельная объемная мощность внутренних источников теплоты, получаемая из решения (1).

В качестве граничных условий для электромагнитной модели выступает действующее значение напряженности магнитного поля на поверхности детали, которая через закон полного тока связана с током индуктора. Нелинейность сопряженной модели (1) и (2) обусловлена зависимостью тепловых и электрических свойств нагреваемого материала от температуры и электромагнитного поля. В связи с этим для решения данной нелинейной системы необходимы итерации. Также с помощью итераций режим постоянной удельной мощности на поверхности детали может быть сведен к граничным условиям режима тока.

Удельная мощность на поверхности заготовки, которую необходимо найти (как и время нагрева), однозначно определяется заданными параметрами: диаметром заготовки, температурой нагрева и требуемым теплоперепадом. Однако сама задача относится к классу обратных граничных задач [9]. Поэтому для нахождения удельной мощности на поверхности и времени нагрева были реализованы дополнительные итерации с помощью метода Ньютона, с учетом ошибок вычислений с числами с плавающей запятой.

Реализация итерационного решения как для нелинейной сопряженной, так и для обратной граничной задач, а также необходимость проводить расчеты для большого разнообразия входных данных накладывает дополнительные требования к реализации численной модели. Чтобы обеспечить одинаковую точность для многочисленных расчетов при минимальном участии человека, численная модель должна поддерживать адаптивное разбиение пространственной сетки и адаптивный шаг по времени.

Особенности построения обобщающей модели. На первых этапах данного исследования авторы при обучении нейронных сетей в качестве входных параметров использовали: частоту тока, диаметр детали, толщину футеровки и размер

зазора между футеровкой и деталью. Однако выяснилось, что если провести некоторые простые преобразования с входными данными, то это позволяет значительно сократить количество нейронов в скрытом слое нейронных сетей. Наибольший эффект по сокращению требуемых нейронов происходит при переходе от частоты к показателю степени поверхностного эффекта m_2 :

$$m_2 = \sqrt{2}D_2/2\Delta,$$

где $\Delta = 1/\sqrt{\pi\sigma\mu_0 f}$ – глубина проникновения тока в горячем режиме, σ – удельная проводимость стали 45, взятая при 1250 °С, f – частота тока; D_2 – диаметр детали.

В меньшей степени на сокращение количества нейронов влияет замена значения зазора между футеровкой и деталью на отношение диаметра индуктора к диаметру детали:

$$D_1/D_2 = [D_2 + 2(\text{airgap} + h_{\text{ф}})]/D_2,$$

где D_1 – диаметр индуктора; airgap – воздушный зазор; $h_{\text{ф}}$ – толщина футеровки.

В результате авторы пришли к оптимальному набору из четырех входных параметров: диаметр детали, отношение диаметра индуктора к диаметру детали, толщина футеровки, показатель степени поверхностного эффекта.

Следует отметить, что аналогичный переход от абсолютных значений к относительным также

используется в аналитической теории индукционного нагрева [10], повышая степень согласованности входных и выходных параметров.

Распределенные во времени результаты имеют пятый входной параметр – время. Использование вместо абсолютного времени (t , с) относительного (t , %) увеличивает степень подобия выходных зависимостей, что облегчает задачу обобщения для нейронных сетей. Наглядно увеличение степени подобия выходных зависимостей продемонстрировано на примере температуры поверхности цилиндрических заготовок ($\theta_{\text{п}}$, °С) в процессе нагрева при разных диаметрах детали (D_2 , мм) на рис. 1.

В связи с этим все распределенные во времени результаты в базе данных хранятся с шагом по времени 1 %. Для получения абсолютного времени необходимо воспользоваться нейронной сетью, аппроксимирующей время нагрева, и с помощью ее результатов перевести проценты в секунды.

Машинное обучение и база данных. Для формирования базы данных было проведено более 10 000 численных расчетов. Общий объем полученных данных составил около 60 Мбайт.

Для построения метамодели на основе полученных данных в качестве инструмента были выбраны нейронные сети (для каждого выходного параметра – отдельная нейронная сеть). Это объясняется тем, что обученная нейронная сеть при достаточном количестве нейронов в скрытых слоях служит идеальным аппроксиматором, который способен выявлять сложные зависимости между

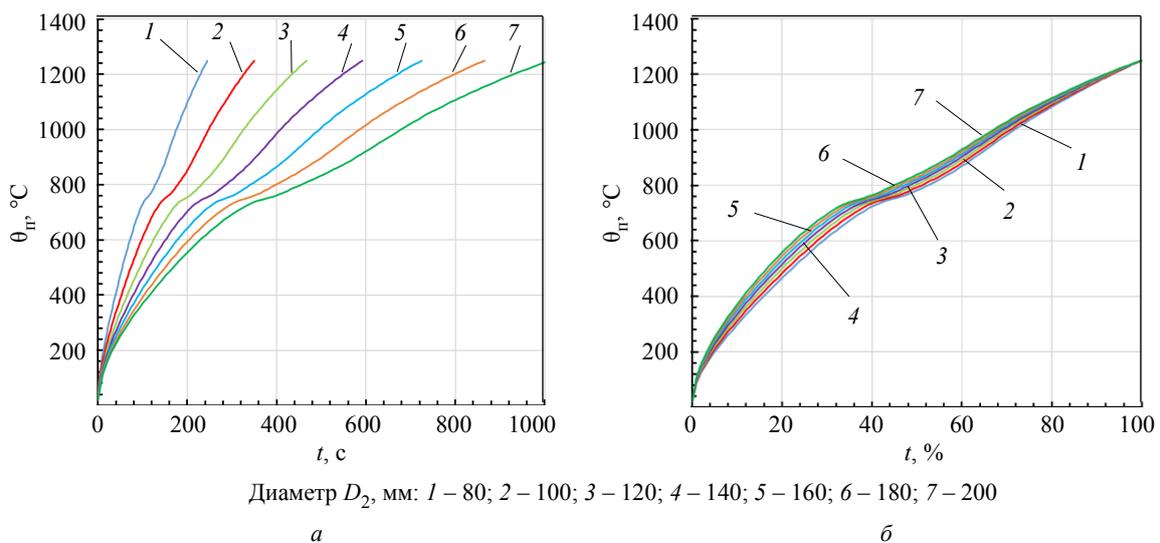


Рис. 1. Зависимости температуры поверхности цилиндрической заготовки при разных диаметрах от абсолютного (а) и относительного (б) времени нагрева

Fig. 1. Dependences of cylindrical workpiece surface temperature at different diameters on the absolute (a) and relative (b) heating time

входными и выходными параметрами, а также выполнять обобщение. Кроме того, обученную нейронную сеть легко интегрировать в программный код как для стационарных компьютеров, так и для микропроцессоров.

В данной статье исследования ограничились нейронными сетями с одним скрытым слоем, так как, согласно теореме Цыбенко [11], такие сети могут аппроксимировать любую непрерывную функцию многих переменных с любой точностью при достаточном количестве нейронов и удачном подборе коэффициентов. При обучении нейронных сетей авторы использовали байесовскую регуляризацию [12], при которой минимизируется линейная комбинация квадратов ошибок MSE и весов W :

$$\text{Error} = \text{MSE} + L_p \sum W,$$

где для байесовской регуляризации коэффициент L_p находится адаптивно, что позволяет значительно улучшить качество обобщения обученных нейронных сетей (байесовская регуляризация также реализована в пакете MatLab).

Совместно с байесовской регуляризацией, как правило, рекомендуется использовать в качестве функции активации для нейронов скрытого слоя гиперболический тангенс, поэтому для нормирования входных и выходных параметров лучше подходит диапазон $[-1; 1]$.

Поскольку процесс обучения нейронных сетей носит вероятностный характер, то для конкурентного отбора обученных нейронных сетей исходные данные были разбиты на три множества: обучающее (50%), тестовое (25%) и верификационное (25%).

Отбор топологий обученных сетей для основных и интегральных параметров происходил следующим образом. Для каждой новой топологии сети проводилось более ста итераций обучения на обучающем множестве, после чего осуществлялся конкурентный отбор обученных сетей с помощью тестового множества. Нейронная сеть, имеющая максимальный коэффициент корреляции и минимальную относительную максимальную ошибку на тестовом множестве, считалась лучшей для данной топологии. Проверка на относительную максимальную ошибку позволяет отбраковывать нейронные сети, которые имеют признаки переобучения. Верификационное множество не участвует в процессе обучения и конкурентного отбора, а используется только для конечной проверки качества отобранных нейронных сетей. Оно позволяет оценить, с какими топологиями нейронные сети обучились наиболее удачно.

Принцип обучения нейронных сетей для распределенных во времени параметров может быть аналогичен описанному с учетом добавления в качестве пятого входного параметра относительного времени. Однако при таком подходе время обучения значительно увеличивается, так как исходных данных оказывается на два порядка больше (каждая временная зависимость состоит из 101 точки). Кроме того, результирующие нейронные сети имеют большое количество нейронов и поэтому склонны к переобучению. Для понижения размерности исходного множества распределенных во времени параметров был применен метод главных компонент (метод ортогональной декомпозиции), который базируется на сингулярном разложении матриц (SVD) [13]:

$$D = U \Sigma V^T,$$

где D – матрица размером $m \times n$, U и V – квадратные матрицы размером $m \times m$ и $n \times n$ соответственно, состоящие из левых и правых сингулярных векторов соответственно; Σ – матрица размером $m \times n$, у которой на главной диагонали лежат сингулярные числа матрицы D , причем всегда строго по убыванию, а остальные элементы равны нулю.

Такое расположение сингулярных чисел на главной диагонали матрицы Σ позволяет уменьшить ранг исходной матрицы D до r с потерей части исходных данных, используя сокращенную форму сингулярного разложения

$$D \approx D_r = U_r \Sigma_r V_r^T,$$

где вычисляют только r столбцов и строк матриц U и V^T соответственно.

Схематичное представление сокращенной формы сингулярного разложения представлено на рис. 2.

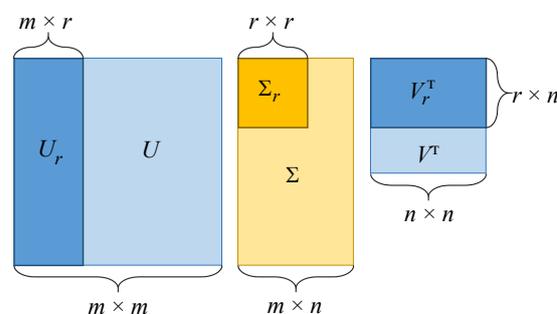


Рис. 2. Схема сокращенного сингулярного разложения матрицы $m \times n$

Fig. 2. Matrix $m \times n$ reduced singular value decomposition scheme

Относительная погрешность (в процентах) сокращенной формы сингулярного разложения σ_{SVD} определяется через норму Фробениуса, которая для сингулярного разложения принимает вид

$$\sigma_{\text{SVD}} = \frac{\|D - D_r\|_F}{\|D\|_F} \cdot 100 = \sqrt{\frac{\sum_{j=r+1}^n \delta_j^2}{\sum_{i=0}^n \delta_i^2}} \cdot 100,$$

где $\|D - D_r\|_F$ – норма Фробениуса по отброшенным сингулярным числам матрицы D ; δ_j – сингулярные числа матрицы D ; $\|D\|_F$ – норма Фробениуса матрицы D ; δ_j – отброшенные сингулярные числа матрицы D , не вошедшие в матрицу D_r .

Одним из простых методов отбора главных компонент служит правило Кайзера, согласно которому отбираются первые r столбцов матрицы Σ , которые удовлетворяют условию

$$\delta_i^2 > \frac{1}{n} \sum_{i=0}^n \delta_i^2.$$

Матрица D формировалась следующим образом: m – количество вычислительных экспериментов; $n = 101$ (количество значений распределенного во времени параметра).

Нетрудно заметить, что при таком способе формирования матрицы D матрица U после проведения сингулярного разложения – это базис вычислительных экспериментов, матрица V^T – базис значений распределенного во времени параметра, а матрица Σ – оператор перехода от эксперимента к распределенному во времени параметру.

Обобщение каждого распределенного во времени параметра проводилось следующим образом. На первом этапе формировалась исходная матрица D , состоящая из данных объединенных обучающего и тестового множеств. Затем эта матрица подвергалась сокращенному сингулярному разложению. Предварительно количество сингулярных чисел r выбиралось по правилу Кайзера.

Поскольку для обобщения распределенных во времени параметров важно было сохранить точность каждой временной зависимости, количество сингулярных чисел r при необходимости увеличивалось до такого значения, при котором относительная погрешность сокращенной формы сингулярного разложения σ_{SVD} не превышала 0.5 %.

На втором этапе матрица U_r разбивалась на r столбцов, каждый из которых был выходным значением для r нейронных сетей соответственно.

Матрицы Σ_r и $V_r^T \|D\|_F$ перемножались; полученная матрица S_r в дальнейшем необходима для пересчета обобщенных элементов матрицы U_r в искомые временные зависимости, поэтому она сохраняется вместе с обученными нейронными сетями.

На третьем этапе обучалось r нейронных сетей аналогично интегральным параметрам с четырьмя основными входными параметрами. На этапе конкурентного отбора для каждой нейронной сети выбиралась лучшая топология с максимальным коэффициентом корреляции и минимальной ошибкой по метрике RMSPE. Следует отметить, что ошибка аппроксимации нейронными сетями увеличивается с ростом порядкового номера сингулярного числа, что в некоторой мере компенсируется уменьшением влияния этих сингулярных чисел.

На четвертом этапе при помощи нейронных сетей восстанавливалась матрица U_r , соответствующая входным данным обучающего и тестового множеств, затем при помощи матрицы S_r вычислялась матрица D_r , матрицы D_r и D построчно сравнивались по метрике RMSPE (ошибка менее 2 %) для определения корректности аппроксимации исходных зависимостей.

На финальном этапе при помощи нейронных сетей аппроксимировалась матрица U'_r , соответствующая входным данным верификационного множества, при помощи матрицы S_r вычислялась матрица D'_r и построчно сравнивались матрица D'_r и исходное верификационное множество для финальной оценки корректности аппроксимации временных зависимостей по тем же метрикам.

В результате для обобщения каждого распределенного во времени параметра вместо обучения одной нейронной сети для аппроксимации сложной зависимости с большим количеством исходных данных $m \times n$ необходимо обучить r нейронных сетей, чтобы аппроксимировать более простые зависимости с меньшим количеством данных m . Кроме экономии времени обучения такой подход позволяет в некоторых случаях также увеличить точность аппроксимации.

Для получения искомой временной зависимости выходного параметра необходимо при помощи r нейронных сетей получить аппроксимированную строку матрицы U_r размером $1 \times r$, после чего умножить ее на сохраненную матрицу S_r . Полученная строка размером $1 \times n$ будет искомой временной зависимостью, где n – это 101 значение распределенного во времени параметра. Промежуточные значения выходного параметра между полученными точками по времени с хорошей точностью находятся при помощи линейной аппроксимации.

Основные и интегральные параметры. Для обобщения времени нагрева t , удельной мощности на поверхности цилиндра P , электрического $\eta_{эл}$, теплового $\eta_{тепл}$, полного $\eta_{пол}$ КПД и коэффициента мощности $\cos \varphi$ было обучено шесть типов нейронных сетей. В табл. 1 приведено количество нейронов для каждого обобщаемого параметра, полученное при сравнимых максимальных относительных ошибках по обучающим σ_o , тестовым σ_T и верификационным σ_B множествам в процентах.

Табл. 1. Характеристики нейронных сетей для основных и интегральных параметров

Tab. 1. Characteristics of neural networks for main and integral parameters

Показатель	t	P	$\eta_{эл}$	$\eta_{тепл}$	$\eta_{пол}$	$\cos \varphi$
Количество нейронов, N	18	8	2	3	4	8
σ_o , %	0.37	0.37	0.31	0.41	0.37	0.32
σ_T , %	0.37	0.34	0.27	0.29	0.25	0.17
σ_B , %	0.37	0.46	0.26	0.26	0.3	0.19

По данным табл. 1 видно, что лучше всего обобщается электрический КПД, которому достаточно всего 2 нейрона в скрытом слое для достижения погрешности в 0.3 %. Такое малое количество нейронов можно объяснить тем, что когда диаметр индуктора задан относительно диаметра детали, а частота – через коэффициент $m2$, зависимость электрического КПД меняется незначительно [10]. Немного хуже обобщаются тепловой и полный КПД, им для достижения сравнимой точности требуется 3 и 4 нейрона в скрытом слое соответственно. При этом увеличение числа скрытых нейронов для каждого КПД всего до 6 снижает максимальные относительные ошибки по всем трем множествам до 0.1 %.

Коэффициент мощности и удельная мощность на поверхности цилиндра для сравнимого с КПД по точности обобщения требуют уже по

8 нейронов в скрытом слое. Для снижения максимальных ошибок ниже 0.1 % необходимо увеличить число скрытых нейронов до 14. Сложнее всего нейронные сети обобщают время нагрева, требующее 18 скрытых нейронов для обобщения с точностью, сравнимой с остальными параметрами. Относительная трудность обобщения может быть связана как со сложной нелинейной зависимостью от всех четырех входных параметров, так и с точностью итерационного метода подбора времени в исходной численной модели.

На рис. 3–5 показаны наиболее наглядные срезы зависимостей трех интегральных параметров от одного из четырех входных параметров на верификационных подмножествах численных экспериментов, не участвовавших в обучении и конкурентном отборе нейронных сетей.

На рис. 3 представлена зависимость времени нагрева (t , с) от толщины футеровки (h_{ϕ} , мм) при постоянных $D_2 = 147$ мм; $m2 = 4.55$ и воздушном зазоре 13 мм по результатам работы обученной нейронной сети с $N = 18$, где также отображены точки верификационного множества, соответствующие этим параметрам.

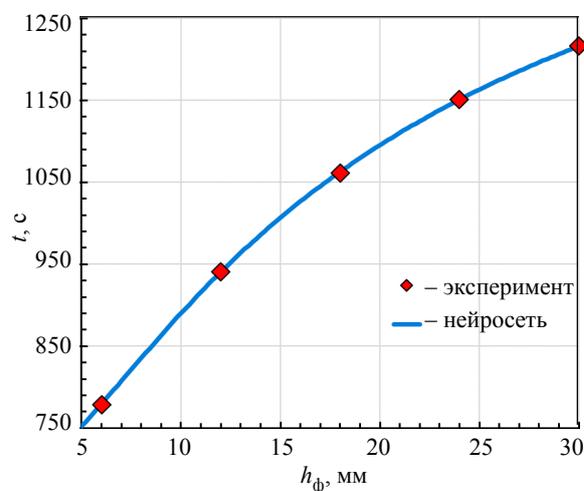


Рис. 3. Обобщенная зависимость времени нагрева от толщины футеровки на верификационном подмножестве

Fig. 3. Generalized dependence of heating time on lining thickness on verification subset

На рис. 4 представлена зависимость удельной мощности на поверхности детали (P , Вт/см²) от диаметра детали (D_2 , мм) при постоянных $h_{\phi} = 13$ мм; $m2 = 4.55$ и воздушном зазоре 13 мм по результатам работы обученной нейронной сети с $N = 8$, где также отображены точки верификационного множества, соответствующие этим параметрам.

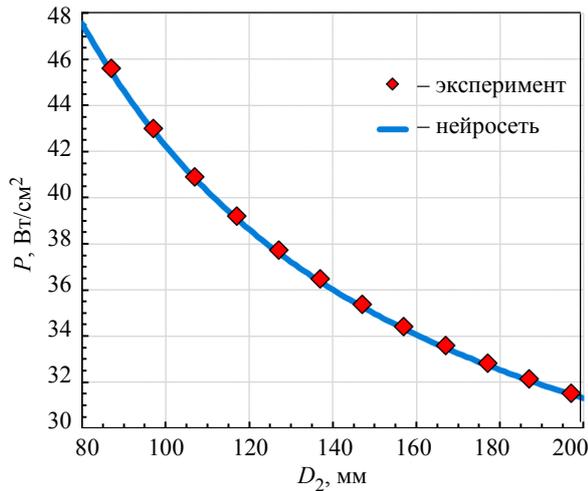


Рис. 4. Обобщенная зависимость удельной мощности на поверхности детали от диаметра детали на верификационном подмножестве
Fig. 4. Generalized dependence of cylinder surface specific power on cylinder diameter on verification subset

На рис. 5 представлена зависимость полного КПД ($\eta_{\text{полн}}$, %) от параметра $m2$ при постоянных $D_2 = 147$ мм; $h_{\text{ф}} = 6$ мм и воздушном зазоре 7 мм по результатам работы обученной нейронной сети с $N=4$, где также отображены точки верификационного множества, соответствующие этим параметрам.

На рис. 3–5 видна хорошая аппроксимация основных и интегральных параметров, пригодная для точного предсказания поведения системы индукционного нагрева.

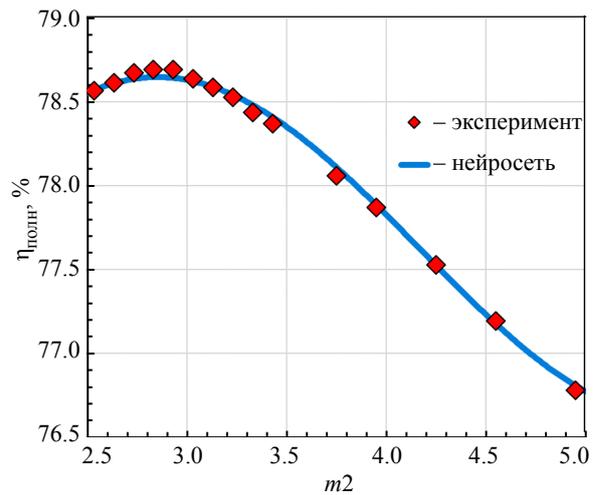


Рис. 5. Обобщенная зависимость полного КПД от параметра $m2$ на верификационном подмножестве
Fig. 5. Generalized dependence of total efficiency on $m2$ on verification subset

Распределенные во времени параметры.

Для обобщения распределенных во времени параметров: температур на поверхности, в центре цилиндра и средней ($\theta_{\text{п}}$, $\theta_{\text{ц}}$, $\theta_{\text{с}}$), электрического, теплового и полного КПД ($\eta_{\text{эл}}$, $\eta_{\text{тепл}}$, $\eta_{\text{полн}}$), напряженности магнитного поля на поверхности цилиндра H и напряжения одновиткового индуктора U_1 обучение проводилось как с помощью метода главных компонент, так и без дополнительной обработки данных.

Табл. 2. Наборы нейронных сетей обобщающих распределенные во времени параметры с помощью метода главных компонент

Tab. 2. Neural networks sets generalizing time-distributed parameters using principal components analysis

Показатель	$\theta_{\text{п}}$	$\theta_{\text{с}}$	$\theta_{\text{ц}}$	$\eta_{\text{эл}}$	$\eta_{\text{тепл}}$	$\eta_{\text{полн}}$	$\cos \varphi$	H	U_1
r	3	2	3	4	3	4	5	5	6
σ_{SVD} , %	0.19	0.23	0.19	0.17	0.17	0.33	0.45	0.31	0.32
N_1	4	5	4	3	4	4	6	6	6
N_2	3	3	4	3	4	4	6	6	6
N_3	5	–	4	3	4	5	7	4	5
N_4	–	–	–	3	–	4	5	3	5
N_5	–	–	–	–	–	–	5	4	4
N_6	–	–	–	–	–	–	–	–	4

Табл. 3. Относительные погрешности нейронных сетей обобщающих распределенные во времени параметры с помощью метода главных компонент

Tab. 3. Relative errors of neural networks generalizing time-distributed parameters using principal components analysis

Показатель	$\theta_{\text{п}}$	$\theta_{\text{с}}$	$\theta_{\text{ц}}$	$\eta_{\text{эл}}$	$\eta_{\text{тепл}}$	$\eta_{\text{полн}}$	$\cos \varphi$	H	U_1
N_{Σ}	12	8	12	12	12	17	29	23	30
max RMSPE, %	0.67	1.03	3.13	0.48	0.66	1.16	1.78	1.73	1.16
max MAPE, %	0.48	0.86	1.42	0.37	0.53	0.92	1.36	1.30	0.91
max σ , %	2.23	1.98	13.44	1.65	1.72	2.62	6.21	5.13	5.87

Каждый набор нейронных сетей, обученных с помощью метода главных компонент, включает в себя r нейронных сетей. В табл. 2 приведены относительные погрешности сокращенной формы сингулярного разложения σ_{SVD} и количества нейронов N_i для обобщения каждого из r столбцов матриц U_r каждого набора обученных нейросетей.

В табл. 3 для нейронных сетей, обученных с помощью метода главных компонент, приведены суммарные количества нейронов N_Σ , а также максимальные относительные погрешности ($\max \sigma$) и максимальные ошибки по метрикам RMSPE и MAAPE, полученные для временных зависимостей верификационного множества.

В табл. 4 для сравнения приведены характеристики нейронных сетей, обученных без дополнительной обработки данных. Так как объем исходных данных для обучения в этом случае на два порядка больше, чем для интегральных параметров, то процесс обучения занимает значительное время, возрастая нелинейно с увеличением количества скрытых нейронов. В связи с этим задача нахождения оптимального количества нейронов не ставилась, а нейронные сети обучались с 5, 10 и 15 нейронами в скрытом слое. Максимальные относительные погрешности ($\max \sigma$) и максимальные ошибки по метрикам RMSPE и MAAPE также приводятся для временных зависимостей верификационного множества.

Сравнительный анализ данных табл. 3 и 4 показывает, что применение метода главных компонент оказывает наибольший эффект на точность аппроксимации при обобщении температур. При меньшем суммарном количестве нейронов и меньшем времени, затрачиваемом на обучение, удается достичь меньшей погрешности. Тем не менее, для температуры в центре цилиндра не удалось достичь максимальной погрешности по RMSPE меньше 2 % при оптимальном количестве сингулярных чисел и оптимальном количестве нейронов в сетях. Наибольшая относительная ошибка наблюдается на начальном этапе нагрева

до 100 °С. Это объясняется тем, что при обучении нейронных сетей минимизируется абсолютная ошибка, а не относительная.

Для обобщения графиков зависимости КПД от времени оба подхода к обучению дают сопоставимый по точности результат. Это объясняется тем, что в части аналитической теории индукционного нагрева [10] электрический КПД хорошо обобщается, когда диаметр индуктора задается относительно диаметра детали и частота задается через параметр $m2$, а тепловой КПД имеет относительно простую зависимость.

Для коэффициента мощности, напряженности магнитного поля и напряжения одновиткового индуктора без применения метода главных компонент не удалось достичь ошибки по метрикам RMSPE менее 2 %. Обучение сетей с большим количеством скрытых нейронов не проводилось в виду резкого увеличения времени обучения (более нескольких дней для одной физической величины). В то же самое время применение метода главных компонент дает хорошие результаты, хоть и требует увеличения количества необходимых сингулярных чисел до 5–6.

На рис. 6 и 7 представлены зависимости, обобщенные набором нейронных сетей (НС+РСА) (непрерывная линия), обученных с помощью метода главных компонент, в сравнении с результатами ЧМ (точки на графике).

На рис. 6 представлены зависимости распределенных во времени нагрева (t , с) температур, θ , °С: на поверхности (кривая 1), средней (кривая 2) и в центре (кривая 3), при $D_2 = 200$ мм, $m2 = 5$, $h_\phi = 10$ мм и воздушном зазоре 20 мм. При таком наборе параметров наблюдается максимальная ошибка обобщения температуры центра стержня по метрике RMSPE.

На рис. 7 представлены зависимости распределенных во времени нагрева (t , с) электрического (кривая 1), теплового (2) и полного (3) КПД (η , %) при $D_2 = 200$ мм, $m2 = 5$, $h_\phi = 5$ мм и воздушном зазоре 20 мм. При таком наборе парамет-

Табл. 4. Относительные погрешности нейронных сетей обобщающих распределенные во времени параметры без дополнительной обработки данных

Tab. 4. Relative errors of neural networks generalizing time-distributed parameters without additional data processing

Показатель	θ_n	θ_c	$\theta_{\text{ц}}$	$\eta_{\text{эл}}$	$\eta_{\text{тепл}}$	$\eta_{\text{полн}}$	$\cos \varphi$	H	U_1
N_Σ	15	10	15	10	10	10	15	15	15
\max RMSPE, %	2.16	1.34	4.74	0.40	0.40	0.72	5.47	2.22	2.58
\max MAAPE, %	0.42	0.40	1.53	0.28	0.31	0.61	4.09	1.88	2.22
$\max \sigma$, %	21.44	11.48	23.53	1.33	1.22	2.06	16.63	6.07	6.70

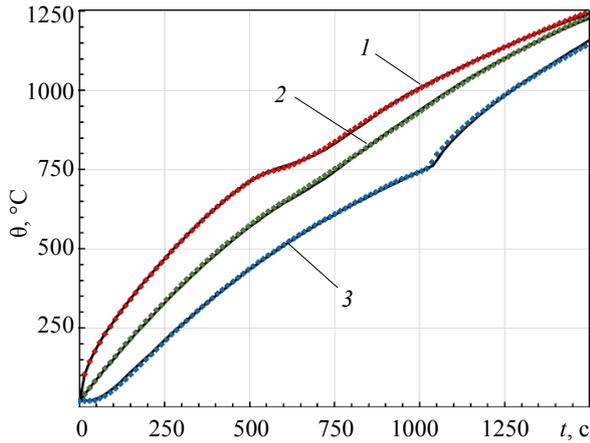


Рис. 6. Временные зависимости температур по численной модели и наборам нейронных сетей
Fig. 6. Temperature-time dependences according to the numerical model and neural networks sets

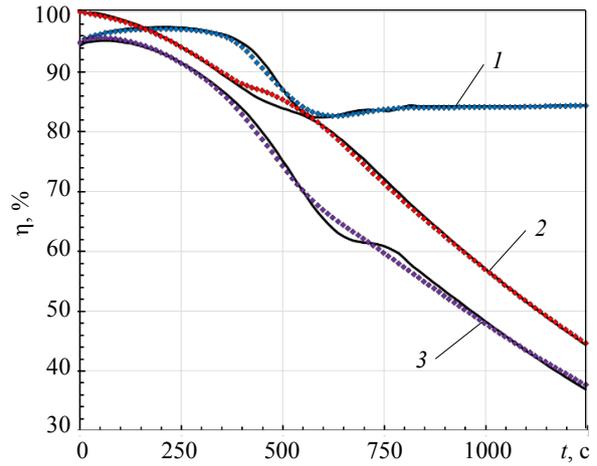


Рис. 7. Временные зависимости значений КПД по численной модели и наборам нейронных сетей
Fig. 7. Efficiency-time dependences according to the numerical model and neural networks sets

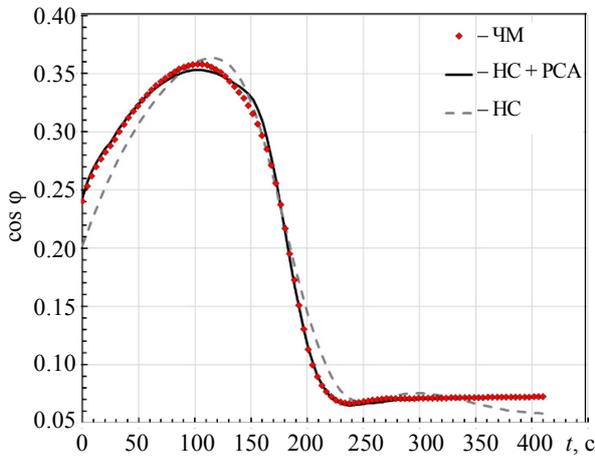


Рис. 8. Временные зависимости коэффициента мощности по численной модели и нейронным сетям с PCA и без него
Fig. 8. Power factor-time dependences according to the numerical model and neural networks with and without PCA

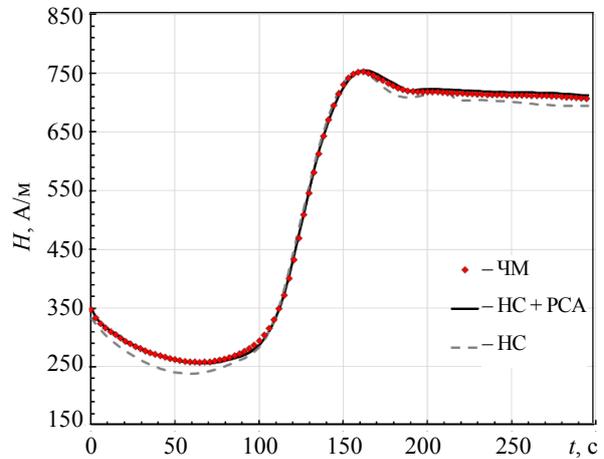


Рис. 9. Временные зависимости напряженности магнитного поля по численной модели и нейронным сетям с PCA и без него
Fig. 9. Magnetic field strength-time dependences according to the numerical model and neural networks with and without PCA

ров наблюдается максимальная ошибка обобщения полного КПД по метрике RMSPE.

На рис. 8–10 представлены зависимости, обобщенные набором нейронных сетей, обученных с помощью метода главных компонент (НС+PCA) (непрерывная линия), в сравнении с результатами ЧМ (точки на графике) и с зависимостями, обобщенными нейронными сетями, обученными без дополнительной обработки данных (НС) (штриховая линия). На приведенных зависимостях с указанными параметрами наблюдаются наибольшие максимальные ошибки обобщения по метрике RMSPE для нейронных сетей, обученных без дополнительной обработки данных.

На рис. 8 показаны зависимости распределенного во времени нагрева (t , с) коэффициента

мощности ($\cos \varphi$) при $D_2 = 80$ мм, $m_2 = 5$, $h_\phi = 30$ мм и воздушном зазоре 20 мм.

На рис. 9 представлены зависимости распределенного во времени нагрева (t , с) напряженности магнитного поля (H , А/м) при $D_2 = 80$ мм, $m_2 = 5$, $h_\phi = 5$ мм и воздушном зазоре 30 мм.

На рис. 10 показаны зависимости распределенных во времени нагрева (t , с) напряжения одновиткового индуктора (U_1 , В) при $D_2 = 200$ мм, $m_2 = 2.5$, $h_\phi = 5$ мм и воздушном зазоре 5 мм.

Результаты, представленные в табл. 3 и 4 и на рис. 6, 7, показывают очень хороший уровень обобщения исходных данных. Результаты, представленные на рис. 8–10, показывают, что более сложные зависимости требуют для аппроксима-

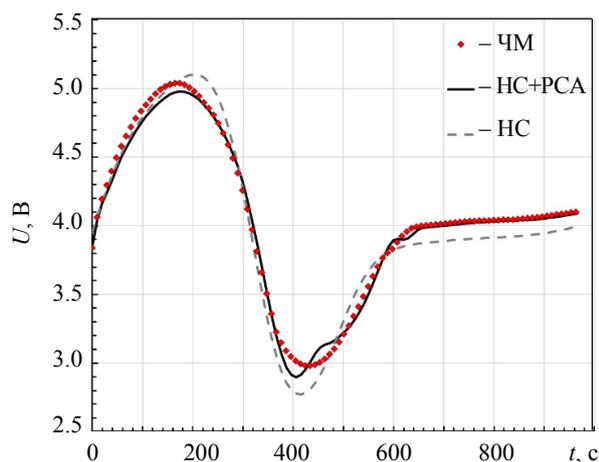


Рис. 10. Временные зависимости напряжения одновиткового индуктора по численной модели и нейронным сетям с РСА и без него

Fig. 10. Single-turn inductor voltage-time dependences according to the numerical model and neural networks with and without PCA

ции больше сингулярных чисел или нейронов в скрытом слое.

Реализация метамодели. Для того чтобы хранить обученные нейронные сети и иметь возможность переносить их с одного устройства на другое, для каждой был разработан простой текстовый формат данных. После этого обученные нейронные сети были собраны в одну метамодель, которая была реализована в отдельной программе для наглядного представления результатов предсказания параметров индукционного нагрева.

Главное преимущество созданной метамодели по сравнению с численными моделями на основе методов конечных разностей или конечных элементов заключается в том, что она позволяет быстро определять параметры индукционного нагрева в режиме реального времени. При этом, в отличие от инженерных методов расчета [6], [10], она учитывает нелинейности процесса нагрева, обусловленные изменениями свойств материала заготовки от температуры.

Стоит отметить, что нейронные сети, лежащие в основе метамодели, содержат небольшое количество нейронов в скрытом слое. Кроме того, суммарный объем данных, необходимых для аппроксимации самой сложной зависимости, составляет не более 4 Кбайт, что на четыре порядка меньше объема исходных данных. Это позволяет использовать разработанную метамодель для эффективного предсказания в реальном времени в интегрированных системах автоматического управления, построенных на базе микропроцессоров, вследствие чего созданную метамодель можно легко интегрировать в систему управления реальной индукционной установкой.

Ограничением метамодели служит то, что она работает в строго определенном диапазоне входных параметров. Это объясняется плохой экстраполяцией нейронными сетями исходных зависимостей.

Выводы и заключение. В данной статье, в отличие от [3], авторы исследовали технологию с более простой геометрией для простого режима работы (режим постоянной удельной мощности), но построили метамодель для более сложных зависимостей выходных параметров от времени. Полученные результаты обнадеживают и вселяют уверенность, что инструменты искусственного интеллекта позволят обобщить разнообразные зависимости интегральных и распределенных параметров, присущие технологиям с применением индукционного нагрева.

В связи с вышесказанным, в условиях ограниченных вычислительных ресурсов метамодели могут стать основным инструментом для построения цифровых двойников, как для индукционных установок, так и технологических линий, частью которых являются индукционные нагреватели. Подобные обобщенные модели могут также применяться в САПР для автоматизации проектирования типовых изделий или для обучения инженеров-проектировщиков и обслуживающего персонала.

Создание метамоделей только для систем управления индукционными установками намного проще, так как, в отличие от цифрового двойника, таким моделям необходимо обобщать значительно меньше данных. При этом их можно обучать не только на данных, полученных из численных моделей, но и на основе экспериментальных данных [14], [15]. В таком случае, как правило, требуются методы увеличения размерности экспериментальных данных. Возможен и гибридный подход, когда метамодель обучена на основе результатов численной модели, но ее выходные результаты корректируются на основе экспериментальных данных.

Несмотря на некоторый оптимизм в отношении будущего метамоделей, следует обратить внимание на то, что для успешного применения нейронных сетей для задач аппроксимации требуется правильный выбор входных параметров и предварительная математическая обработка исходных данных. Не исключено, что для обобщения более сложных зависимостей потребуются математические преобразования, которые не рассматривались в этой статье (различные виды нормирования, логарифмирование, нелинейные методы сокращения размерностей).

Список литературы

1. Демидович В. Б. Цифровые двойники процессов индукционного нагрева в металлургической промышленности // *Электричество*. 2023. № 4. С. 55–60.
2. Бутырин П. А., Алпатов М. Е. Цифровизация и аналитика в электротехнике. Цифровые двойники трансформаторов // *Электричество*. 2021. № 10. С. 4–10.
3. Data-driven modeling for multiphysics parametrized problems-application to induction hardening process / K. Derouiche, S. Garois, V. Champaney, M. Daoud, K. Traidi, F. Chinesta // *Metals*. 2021. Vol. 11, no. 5. P. 738–760. doi: 10.3390/met11050738.
4. Real-time prediction by data-driven models applied to induction heating process / K. Derouiche, M. Daoud, K. Traidi, F. Chinesta // *Intern. J. of Material Forming*. 2022. Vol. 15, no. 4. P. 48–66.
5. Демидович В. Б., Чмиленко Ф. В., Скворцов В. Г. Семейство программ IndHeat – среда для моделирования и разработки индукционных нагревательных устройств // *Индукционный нагрев*. 2010. № 2. С. 15–19.
6. Шамов А. Н., Бодажков В. А. Проектирование и эксплуатация высокочастотных установок. Л.: Машиностроение, 1974. 279 с.
7. Демидович В. Б., Чмиленко Ф. В. Численные методы в теории индукционного нагрева. СПб.: ООО «Технолит», 2008. 220 с.
8. Немков В. С., Демидович В. Б. Теория и расчет установок индукционного нагрева. Л.: Энергоатомиздат, 1988. 280 с.
9. Самарский А. А., Вабищев П. Н. Численные методы решения обратных задач математической физики. М.: Едиториал УРСС, 2004. 480 с.
10. Слухоцкий А. Е., Рыскин С. Е. Индукторы для индукционного нагрева. Л.: Энергия, 1974. 264 с.
11. Cybenko G. V. Approximation by Superpositions of a Sigmoidal function // *Mathematics of Control Signals and Systems*. 1989. Vol. 2, no. 4. P. 303–314.
12. MacKay D. J. C. Bayesian interpolation // *Neural computation*. 1992. Vol. 4, no. 3. P. 415–447.
13. Голуб Дж., Ван Лоан Ч. Матричные вычисления, М.: Мир, 1993. 548 с.
14. Garois S., Daoud M., Chinesta F. Data-driven inverse problem for optimizing the induction hardening process of c45 spur-gear // *Metals*. 2023. Vol. 13, no. 5. P. 997. doi: 10.3390/met13050997.
15. Artificial intelligence modeling of induction contour hardening of 300M steel bar and C45 steel spur-gear / S. Garois, M. Daoud, K. Traidi, F. Chinesta // *Intern. J. of Material Forming*. 2023. Vol. 16, no. 3. Article: 26. doi: 10.1007/s12289-023-01748-1.

Информация об авторах

Чмиленко Фёдор Викторович – д-р техн. наук, профессор кафедры электротехнологической и преобразовательной техники СПбГЭТУ «ЛЭТИ».

E-mail: tchfv@mail.ru

<https://orcid.org/0000-0001-6223-9250>

Перевалов Юрий Юрьевич – канд. техн. наук, доцент кафедры электротехнологической и преобразовательной техники СПбГЭТУ «ЛЭТИ».

E-mail: yurperevalov@yandex.ru

<https://orcid.org/0000-0001-8703-7815>

Парменов Вячеслав Евгеньевич – аспирант, ассистент кафедры электротехнологической и преобразовательной техники СПбГЭТУ «ЛЭТИ».

E-mail: parmenov.slava@yandex.ru

<https://orcid.org/0009-0004-3149-4418>

Чжан Ци – аспирант кафедры электротехнологической и преобразовательной техники СПбГЭТУ «ЛЭТИ».

E-mail: 690366324@qq.com

Шанин Юрий Вячеславович – аспирант кафедры электротехнологической и преобразовательной техники СПбГЭТУ «ЛЭТИ».

E-mail: yurashanin@yandex.ru

<https://orcid.org/0000-0002-0641-0989>

Вклад авторов:

Чмиленко Ф. В. – научное руководство; концепция исследования; развитие методологии; проведение вычислительных экспериментов; написание исходного текста; итоговые выводы.

Первалов Ю. Ю. – идея научного исследования; постановка задачи; предложение области практического применения; итоговые выводы.

Парменов В. Е. – анализ результатов; иллюстрирование и инфографика; доработка исходного текста.

Чжан Ци – обучение нейронных сетей; преобразование входных и выходных параметров; доработка исходного текста.

Шанин Ю. В. – подбор метода понижения размерности множества распределенных параметров; адаптация метода сокращенного сингулярного разложения; перевод.

References

1. Demidovich V. B. Cifrovye dvojniki processov indukcionnogo nagreva v metallurgicheskoy promyshlennosti // *Jelektrichestvo*. 2023. № 4. S. 55–60. (In Russ.).
2. Butyrin P. A., Alpatov M. E. Cifrovizacija i analitika v jelektrrotehnike. Cifrovye dvojniki transformatorov // *Jelektrichestvo*. 2021. № 10. S. 4–10. (In Russ.).
3. Data-driven modeling for multiphysics parametrized problems-application to induction hardening process / K. Derouiche, S. Garois, V. Champaney M. Daoud, K. Traidi, F. Chinesta // *Metals*. 2021. Vol. 11, no. 5. P. 738–760. doi: 10.3390/met11050738.
4. Real-time prediction by data-driven models applied to induction heating process / K. Derouiche, M. Daoud, K. Traidi, F. Chinesta // *Intern. J. of Material Forming*. 2022. Vol. 15, no. 4. P. 48–66.
5. Demidovich V. B., Chmilenko F. V., Skvorcov V. G. Semejstvo programm IndHeat – sreda dlja modelirovanija i razrabotki indukcionnyh nagrevatel'nyh ustrojstv // *Indukcionnyj nagrev*. 2010. no. 2. S. 15–19. (In Russ.).
6. Shamov A. N., Bodazhkov V. A. Proektirovanie i jekspluatacija vysokochastotnyh ustanovok. L.: Mashinstroenie, 1974. 279 s. (In Russ.).
7. Demidovich V. B., Chmilenko F. V. Chislennye metody v teorii indukcionnogo nagreva. SPb.: OOO «TehnoLit», 2008. 220 s. (In Russ.).
8. Nemkov V. S., Demidovich V. B. Teorija i raschet ustanovok indukcionnogo nagreva. L.: Jenergoatomizdat, 1988. 280 s. (In Russ.).
9. Samarskij A. A., Vabishhev P. N. Chislennye metody reshenija obratnyh zadach matematicheskoy fiziki. M.: Editorial URSS, 2004. 480 s. (In Russ.).
10. Sluhockij A. E., Ryskin S. E. Induktory dlja indukcionnogo nagreva. L.: Jenergija, 1974. 264 s. (In Russ.).
11. Cybenko G. V. Approximation by Superpositions of a Sigmoidal function // *Mathematics of Control Signals and Systems*. 1989. Vol. 2, no. 4. P. 303–314.
12. MacKay D. J. C. Bayesian interpolation // *Neural computation*. 1992. Vol. 4, no. 3. P. 415–447.
13. Golub Dzh., Van Loan Ch. *Matrichnye vychislenija*, M.: Mir, 1993. 548 s. (In Russ.).
14. Garois S., Daoud M., Chinesta F. Data-driven inverse problem for optimizing the induction hardening process of c45 spur-gear // *Metals*. 2023. Vol. 13, no. 5. P. 997. doi: 10.3390/met13050997.
15. Artificial intelligence modeling of induction contour hardening of 300M steel bar and C45 steel spur-gear / S. Garois, M. Daoud, K. Traidi, F. Chinesta // *Intern. J. of Material Forming*. 2023. Vol. 16, no. 3. Article: 26. doi: 10.1007/s12289-023-01748-1.

Information about the authors

Fedor V. Chmilenko – Dr Sci. (Eng.), Professor of the Department of Electrical Technology and Converter Engineering, Saint Petersburg Electrotechnical University.

E-mail: tchfv@mail.ru

<https://orcid.org/0000-0001-6223-9250>

Yuriy Yu. Perevalov – Cand. Sci. (Eng.), Associate Professor of the Department of Electrical Technology and Converter Engineering, Saint Petersburg Electrotechnical University.

E-mail: yyperevalov@yandex.ru

<https://orcid.org/0000-0001-8703-7815>

Vyacheslav E. Parmenov – postgraduate student, Assistant of the Department of Electrical Technology and Converter Engineering, Saint Petersburg Electrotechnical University.

E-mail: parmenov.slava@yandex.ru

<https://orcid.org/0009-0004-3149-4418>

Zhang Qi – postgraduate student of the Department of Electrical Technology and Converter Engineering, Saint Petersburg Electrotechnical University.

E-mail: 690366324@qq.com

Yuriy V. Shanin – postgraduate student of the Department of Electrical Technology and Converter Engineering, Saint Petersburg Electrotechnical University.

E-mail: yurashanin@yandex.ru

<https://orcid.org/0000-0002-0641-0989>

Author contribution statement:

Chmilenko F. V. – scientific guidance; research concept; development of methodology; conducting computational experiments; writing the source text; final conclusions.

Perevalov Yu. Yu. – scientific research idea; problem statement; practical application field proposal; final conclusions.

Parmenov V. E. – results analysis; illustration and infographics; source text revision.

Zhang Qi – neural networks training; input and output parameters conversion; source text revision.

Shanin Yu. V. – selection of method for reducing dimension of distributed parameters set; reduced singular value decomposition method adaptation; translation.

Статья поступила в редакцию 26.03.2024; принята к публикации после рецензирования 04.06.2024; опубликована онлайн 30.09.2024.

Submitted 26.03.2024; accepted 04.06.2024; published online 30.09.2024.
