

УДК 004.942, 004.67

О ПРОГНОЗИРОВАНИИ КРИЗИСА ТЕПЛОТДАЧИ ПРИ КИПЕНИИ В КАНАЛАХ С ИСПОЛЬЗОВАНИЕМ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ

© С. С. Абдуракипов¹, Н. В. Кирюхина², Е. Б. Бутаков¹¹Институт теплофизики СО РАН,

630090, г. Новосибирск, просп. Академика Лаврентьева, 1

²Калужский государственный университет им. К. Э. Циолковского,
248026, г. Калуга, ул. Ст. Разина, 26

E-mail: s.s.abdurakipov@gmail.com, natakir21@gmail.com

Представлен сравнительный анализ различных алгоритмов машинного обучения для решения задачи прогнозирования кризиса теплоотдачи при кипении в двухфазных потоках внутри каналов различной геометрии. Рассмотрены двенадцать классических моделей регрессии, реализованных в библиотеках Scikit-learn, LightGBM, XGBoost, CatBoost, а также нейросетевые методы. Дано сравнение моделей между собой, а также с традиционными методиками прогнозирования, основанными на использовании скелетных таблиц, которые приближены к полуэмпирическим соотношениям и корреляционным формулам. Обсуждаются возможности гибридных моделей, совмещающих подход, который основан на знаниях из предметной области, с алгоритмами машинного обучения. Приведены результаты экспериментов с моделью, совмещающей в гибридной схеме регрессор CatBoost с одной из традиционных методик. Выявлено преимущество моделей машинного обучения перед традиционными подходами. Показано, что среди моделей машинного обучения ансамбли алгоритмов на основе градиентного бустинга достигают наилучших показателей по всем метрикам.

Ключевые слова: машинное обучение, кризисы теплоотдачи при кипении, кризис пузырькового кипения, критическая плотность теплового потока.

DOI: 10.15372/AUT20220113

Введение. Двухфазные проточные системы охлаждения находят широкое применение в различных областях: от микропроцессорной и медицинской техники до атомной энергетики. Точное и надёжное предсказание кризиса теплоотдачи при кипении жидкости в каналах актуально для проектирования и обеспечения безопасной эксплуатации ядерных реакторов, так как его возникновение приводит к резкому ухудшению конвективного теплообмена между оболочкой тепловыделяющего элемента и теплоносителем, что может привести к разрушению оболочки.

При кипении в трубах и каналах имеют место две термогидродинамические ситуации, обозначаемые как кризисы теплоотдачи (КТО) [1]. В данной работе речь пойдёт преимущественно о кризисе первого рода или кризисе оттеснения жидкой фазы [1]. Это явление связано со скачкообразным переходом от пузырькового к плёночному режиму кипения при превышении плотностью теплового потока критического значения q_{cr} (отсюда ещё одно название — кризис пузырькового кипения). Кризис второго рода или кризис высыхания обусловлен высыханием пристеночной жидкой плёнки и характерен для потоков с большими значениями объёмного паросодержания [1], превосходящими некоторое граничное значение x_{cr} .

Несмотря на то что исследованию кризиса теплоотдачи при кипении уделялось много внимания, до сих пор нет полного понимания его внутренних механизмов, отсутствует строгая количественная теория, позволяющая определить критическое значение плотности

теплового потока (CHF, critical heat flux). Существует свыше 500 методик расчёта CHF [2], основным недостатком которых является невозможность применения за пределами тех ограниченных диапазонов параметров, для которых они получены.

Подходы, лежащие в основе этих методик, можно условно разделить на две группы: основанные на физике и основанные на данных. В методиках первой группы расчёты опираются на предположения, вытекающие из понимания физики явления, но в силу вышеупомянутых трудностей теоретического описания полученные соотношения для CHF носят приближённый и часто полуэмпирический характер. В литературе описано множество таких моделей, их называют также механистическими, например модель Liu [3], базирующаяся на теории высыхания жидкого подслоя. Опираясь на тепловой баланс, упрощённое управляющее уравнение можно получить в виде

$$q_{cr} = \frac{\rho_f \delta h_{fg}}{L_B} U_B, \quad (1)$$

где ρ_f — плотность жидкости при насыщении, δ — толщина жидкого подслоя, L_B — длина парового слоя, h_{fg} — удельная теплота испарения, U_B — скорость образования парового слоя.

Ко второй группе можно отнести корреляционные соотношения, скелетные таблицы, аппроксимирующие формулы. Примером может служить широко применяемый в инженерной практике табличный метод Groeneveld CHF LUT (look-up table) 2006 [4]. В справочных изданиях и методических рекомендациях приводятся эмпирические уравнения, удовлетворительно воспроизводящие экспериментальные данные. Так, для давлений p от 3 до 16 МПа при массовых скоростях ρw в диапазоне 750–2000 кг/(с·м²) и значений паросодержания, не превосходящих x_{cr} , в трубах диаметром $4 < d < 20$ мм [5]

$$q_{cr} = f(p)(0,001\rho w)^{m(p,x)}(8/d)^{0,5}e^{-1,5x}, \quad (2)$$

где

$$f(p) = 10,3 - 0,796p + 0,0167p^2, \quad (3)$$

$$m(p,x) = 1,2(0,25(0,1p - 1) - x). \quad (4)$$

В последние годы возможности подходов, основанных на данных [4], расширились за счёт применения алгоритмов машинного обучения (МО). Существует большое число работ, подтверждающее эффективность применения таких подходов, например, для исследования теплообмена в плёнках жидкости [6, 7]. Одним из первых методов стала искусственная нейронная сеть (ANN — artificial neural network), которая, как было показано в [8], выступает универсальным аппроксиматором для нелинейных соотношений. В [9] представлен подход с использованием ANN для прогнозирования критического теплового потока для пароводяной смеси в трубах на базе алгоритма Левенберга — Марквардта. В [10] ANN были обучены на основе трёх условий: тип I — на входе или в верхней части потока, II — местные или точечные и III — на выходе или в нижней части потока. Лучшим условием для прогнозирования является тип II, обеспечивающий точность ± 10 %. Проанализировано влияние на критический тепловой поток основных параметров, таких как давление, массовый расход, равновесное качество и переохлаждение на входе. Также предсказано CHF в условиях колебательного потока. В исследовании [11] описывается прогнозирование CHF с помощью ANN с глубокой обратной связью. Наилучшие оценки ANN-предикторов сравниваются с хорошо известным и широко применяемым в практических расчётах табличным методом LUT [4]. Полученные результаты свидетельствуют

о значительном повышении точности прогнозирования по сравнению с традиционными инструментами.

Одним из принципиальных затруднений, ограничивающих использование МО в качестве абсолютной альтернативы традиционным подходам, является отсутствие достаточного объёма размеченных данных, необходимых для обучения алгоритмов. Для его преодоления всё чаще используются различные формы интеграции анализа данных и физических моделей. В таких ситуациях говорят о машинном обучении, основанном на физике [12], когда алгоритм обучается с использованием дополнительной информации из предметной области. В исследовании [13] представлен гибридный подход, в котором базовое решение основано на предметном знании (первичная модель в виде эмпирической корреляции, таблицы или системы уравнений), а машинное обучение используется для изучения его отклонений от фактического значения. Цель обучения заключается в минимизации функции потерь, обычно представленной в виде среднеквадратичной ошибки (MSE — mean squared error) или средней абсолютной ошибки (MAE — mean absolute error). Окончательный результат выводится как сумма прогноза первичной модели и остатка, предсказанного моделью МО. В качестве первичных моделей использовались табличный метод LUT и приближённая модель Liu, выраженная соотношением (1). Для машинного обучения применялись два метода: нейронная сеть с прямой связью (ANN) и модель случайного леса. Установлено, что гибридный подход значительно превосходит в точности автономные модели.

Цель представленной работы — сравнить между собой эффективность стандартных алгоритмов предиктивного анализа данных, доступных в пакетах с открытым кодом для машинного обучения, и сопоставить их с традиционными методиками расчёта без использования МО, а также с гибридным подходом. Для сравнительной оценки результатов работы моделей использовались сопоставимые метрики качества и способы визуализации эффективности алгоритмов.

Описание данных. Для проведения исследования был использован набор данных [14], полученный на основе результатов экспериментов [15–24], сведённых в табл. 1 в [25, 26]. В общей сложности она содержит 1865 тестовых случаев.

В наборе присутствуют данные для трёх вариантов геометрии каналов, охватывающих наиболее часто встречающиеся формы: круглую трубу (1439 случаев), кольцевой канал (378 случаев), плоский канал (48 случаев). По этому признаку очевиден дисбаланс объектов наблюдения, что необходимо учесть при валидации.

Входные характеристики включают следующие величины: давление p , массовый расход $G = \rho w$, балансовое паросодержание x , эквивалентный диаметр D_e , обогреваемый диаметр D_h , обогреваемую длину канала L_h . Представлен широкий охват данными условий потока, при этом они специфичны именно для кризиса первого рода (балансовое паросодержание $x \leq 0, 2$). Целевой переменной является значение критической плотности теплового потока q_{cr} . Величины размерные, единицы измерения указаны в табл. 1. В табл. 2 представлены границы диапазонов входных характеристик и целевой переменной. Для расширения области применимости прогнозов возможно безразмерное представление данных. Однако модели МО лучше предсказывают СНФ в размерном представлении, вероятно, из-за большего числа признаков в наборе данных [25].

На рис. 1 видно, что данные неравномерно распределены по диапазонам давлений, массовых расходов и геометрических параметров. В наборе отсутствуют нулевые значения и пропуски. Все признаки, кроме геометрии, являются количественными.

Описание методов моделирования. Определение точного значения критической плотности теплового потока — это задача регрессии. Для решения задачи регрессии был применён ряд известных алгоритмов, реализованных в различных модулях библиотеки Scikit-learn, а также в библиотеках LightGBM, XGBoost, CatBoost:




Рис. 1. Визуализация охвата данными условий потока: *a* — давление, *b* — массовая скорость, *c* — эквивалентный диаметр, *d* — обогреваемая длина канала

— линейные модели: линейная регрессия LR, LASSO-регрессия, Ridge-регрессия;
 — модель на основе дерева решений DecisionTreeRegressor;
 — регрессия методом «*k* ближайших соседей» KNeighborsRegressor;
 — модель на основе нейронных сетей, многослойный перцептрон MLPRegressor;
 — ансамблевые модели: GradientBoostingRegressor, RandomForestRegressor, AdaBoostRegressor, LightGBMRegressor, XGBoostRegressor, CatBoostRegressor.

Математические основы и гиперпараметры использованных алгоритмов описаны в работах [27, 28]. Масштабирование количественных признаков предусматривало процедуру нормализации по стандартному отклонению. Для категориального признака «геометрия» использовалось унитарное кодирование One Hot Encoding во всех моделях, за исключением CatBoostRegressor, где применялся метод целевероятностного кодирования Target Encoding.

Таблица 1

Набор данных для критического значения плотности теплового потока

Автор	Геометрия	P , МПа	G , кг/(м ² ·с)	x	D_e , мм	D_h , мм	L_h , мм	Число тестов
Inasaka [17]	круглая труба	от 0,31 до 0,91	от 4300 до 6700	от -0,15 до 0,04	3,0	3,0	100	7
Peskov [18]	круглая труба	от 12 до 20	от 750 до 5361	от -0,23 до 0,13	10,0	10,0	от 400 до 1650	17
Thompson [19]	круглая труба	от 0,1 до 20,7	от 542 до 7975	от -0,45 до 0,20	от 1,0 до 37,5	от 1,0 до 37,5	от 25 до 3048	1202
Weatherhead [20]	круглая труба	13,7	от 332 до 712	от -0,49 до 0,19	от 7,7 до 11,1	от 7,7 до 11,1	457	162
Williams [21]	круглая труба	от 5,5 до 15,2	от 4300 до 6700	от -0,03 до 0,17	9,5	9,5	1836	51
Beus [22]	кольцевой канал	от 5,5 до 15,5	от 4300 до 6700	от -0,31 до 0,20	5,6	15,2	2134	77
Janssen [23]	кольцевой канал	от 4,1 до 9,7	от 4300 до 6700	от -0,13 до 0,20	от 4,6 до 22,2	от 11,3 до 96,3	от 737 до 2743	282
Mortimore [24]	кольцевой канал	от 8,3 до 13,8	от 4300 до 6700	от -0,13 до 0,20	5,0	13,3	2,134	19
Kossolapov [25]	плоский канал	0,1	от 4300 до 6700	от -0,14 до -0,02	15,0	120,0	10	12
Richenderfer [26]	плоский канал	от 0,1 до 1,0	от 4300 до 6700	от -0,04 до -0,01	15,0	120,0	10	36

Таблица 2

Границы диапазонов характеристик потоков

Характеристики	min	max
P , МПа	0,100000	20,680000
G , кг/(м ² ·с)	0,000000	7975,000000
x	-0,866700	0,232000
D_e , мм	1,000000	37,500000
D_h , мм	1,000000	120,000000
L_h , мм	10,000000	3048,000000
q_{cr} , МВт/м ²	0,800000	19,300000

С учётом вида зависимости q_{cr} от паросодержания и давления [5] целесообразным оказалось добавление полиномиальных комбинаций для этих признаков (степень $n \leq 3$ для паросодержания и $n \leq 2$ для давления).

Для оценки результатов предсказаний применялись метрики: квадратный корень из среднеквадратичной ошибки (RMSE — root-mean-square error), средняя абсолютная ошибка, доля дисперсии зависимой переменной, воспроизведённой моделью, в виде коэффициента детерминации (R^2).

Гиперпараметры моделей подбирались эмпирически с использованием поиска по сетке GridSearchCV на основе оценки R^2 . Настройка алгоритмов проводилась с помощью техники 10-кратной перекрёстной проверки. Число групп разбиения (фолдов) $k = 10$ при кроссвалидации было выбрано согласно рекомендации составителей набора данных [25]. Поскольку по форме канала данные не сбалансированы, то использовался итератор перекрёстной проверки со стратификацией на основе меток по признаку «геометрия», чтобы в каждой группе сохранялось соотношение числа наблюдений для круглых, кольцевых и плоских каналов, как и в исходном наборе.

Предварительные эксперименты показали явное преимущество ансамблевых методов, поэтому на основном этапе исследования был взят лучший по метрикам алгоритм этой группы CatBoostRegressor. Результаты моделирования сравнивались между собой, а также с эмпирической корреляционной моделью, представленной формулами (2)–(4) в адекватном ей диапазоне условий потока. Кроме того, проводилось сопоставление автономных алгоритмов МО, используемых в данном исследовании, с моделями из [13, 25, 26].

Была предпринята попытка применить гибридный подход [13]. В качестве первичной модели использовались корреляционные соотношения (2)–(4). Вычислялись отклонения значений q_{cr} , рассчитанных по формулам (2)–(4), от фактических значений в наборе данных, которые использовались как целевая переменная для машинного обучения. В качестве алгоритма МО был взят CatBoostRegressor. Результаты первичной модели суммировались с прогнозируемыми остатками.

Результаты моделирования.

Линейные модели регрессии. На начальном этапе проводилось сравнительное исследование линейных моделей: линейная регрессия LR, LASSO-регрессия ($\alpha = 0,001$), Ridge-регрессия ($\alpha = 0,01$). Из графиков на рис. 2 и табл. 3 видно, что все модели дают близкие предсказания, однако их качество сложно признать удовлетворительным. Тем не менее, как будет показано далее, даже линейные модели лучше предсказывают СНФ, чем корреляционные формулы (2)–(4), если ограничить диапазон наблюдений в наборе областью их применимости.

Модели на основе дерева решений « k ближайших соседей» и нейронной сети. В этом разделе объединены алгоритмы, основанные на различных подходах, которые потенциально могли бы улучшить результаты прогнозирования по сравнению с линейными моделями.

Параметры подбирались эмпирически, в табл. 3 вошли наилучшие достигнутые результаты:

- регрессор на основе дерева решений DecisionTreeRegressor, максимальная глубина 6;
- регрессор « k ближайших соседей» KNeighborsRegressor, $k = 3$;
- регрессор на основе нейронной сети, многослойный перцептрон MLPRegressor: число нейронов в каждом из двух скрытых слоёв 100, функция активации ReLU, оптимизатор ADAM, $\alpha = 0,0001$, постоянный шаг обучения 0,0001, максимальное число итераций 500.

Регрессия на основе дерева решений продемонстрировала превосходство по сравнению с линейными моделями методом « k ближайших соседей» и многослойным перцептроном на этом наборе данных (рис. 3, табл. 3), однако существенного улучшения качества не произошло.




Рис. 2. Результаты сравнения моделей: зависимости измеренных и предсказанных значений критической плотности теплового потока (а) и распределение остатков на тестовой выборке для линейных моделей (b)

Таблица 3

Результаты валидации алгоритмов регрессии на всех данных тестовой выборки (усреднение по фолдам кроссвалидации)

Модели	Метрики		
	RMSE	MAE	R ²
LinearRegression	0,930655	0,694691	0,726965
LASSO	0,933938	0,697900	0,725025
Ridge	0,939615	0,703290	0,721681
DecisionTreeRegressor	0,606195	0,298387	0,884158
KNeighborsRegressor	1,045679	0,617303	0,714882
MLPRegressor	1,002453	0,793492	0,710678
AdaBoostRegressor	0,953788	0,768235	0,789301
RandomForestRegressor	0,357621	0,247435	0,959666
GradientBoostingRegressor	0,351169	0,255694	0,957615
LightGBMRegressor	0,391221	0,224350	0,962544
XGBRegressor	0,362901	0,219113	0,961127
CatBoostRegressor	0,342672	0,200864	0,975981

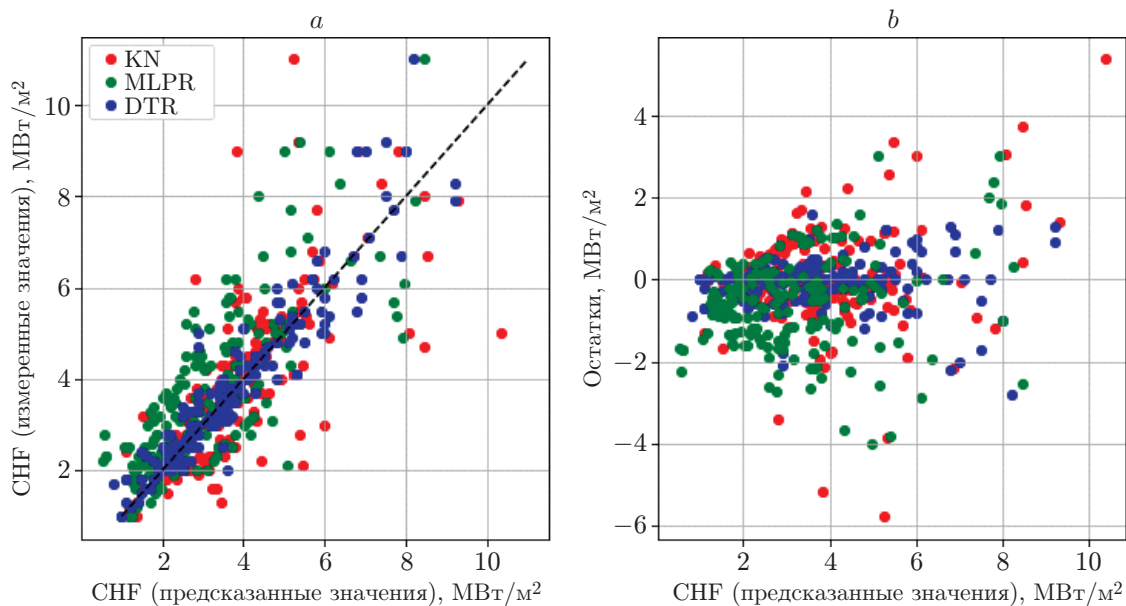


Рис. 3. Результаты сравнения моделей: зависимости измеренных и предсказанных значений критической плотности теплового потока (а) и распределение остатков на тестовой выборке для моделей на основе метода « k ближайших соседей» (KN), дерева решений (DTR) и нейронной сети (MLPR) (б)

Модели на основе ансамблей алгоритмов. В этой части исследования проводилось тестирование и сравнение моделей, объединённых в ансамбль с помощью бэггинга и бустинга:

- случайный лес деревьев регрессии RandomForestRegressor (количество деревьев 600, максимальная глубина 6);
- AdaBoostRegressor с базовым алгоритмом оценки на основе дерева решений и экспоненциальная функция потерь (количество деревьев 50, шаг обучения 0,1);
- регрессоры на основе градиентного бустинга из разных библиотек GradientBoostingRegressor (количество деревьев 500, шаг обучения 0,1, максимальная глубина 3), LightGBMRegressor (количество деревьев 500, шаг обучения 0,05, максимальная глубина 3), XGBRegressor (количество деревьев 100, шаг обучения 0,05, максимальная глубина 3), CatBoostRegressor (количество деревьев 1000, шаг обучения 0,04, глубина 8).

Все рассмотренные ансамблевые модели за исключением AdaBoostRegressor на этом наборе данных работают лучше, чем автономные. Эксперименты показали явное преимущество моделей на основе градиентного бустинга (см. табл. 3). Все четыре исследованных регрессора продемонстрировали близкие показатели качества, но лучший результат по всем метрикам достигнут с использованием алгоритма CatBoostRegressor: $RMSE = 0,342672$, $MAE = 0,200864$, $R^2 = 0,975981$. Визуализация измеренных и предсказанных значений, а также распределение остатков для ансамблей алгоритмов приведены на рис. 4 и 5. На рис. 4 сравниваются модели на основе градиентного бустинга, на рис. 5 демонстрируется превосходство лучшей из них над другими ансамблевыми алгоритмами.

Машинное обучение, традиционные методики, гибридный подход. Сравним вышерассмотренные алгоритмы с тремя альтернативными подходами, традиционно используемыми для расчёта критической плотности и диагностики кризисов теплоотдачи при кипении:

- механистическая модель Lui, выраженная формулой (1);

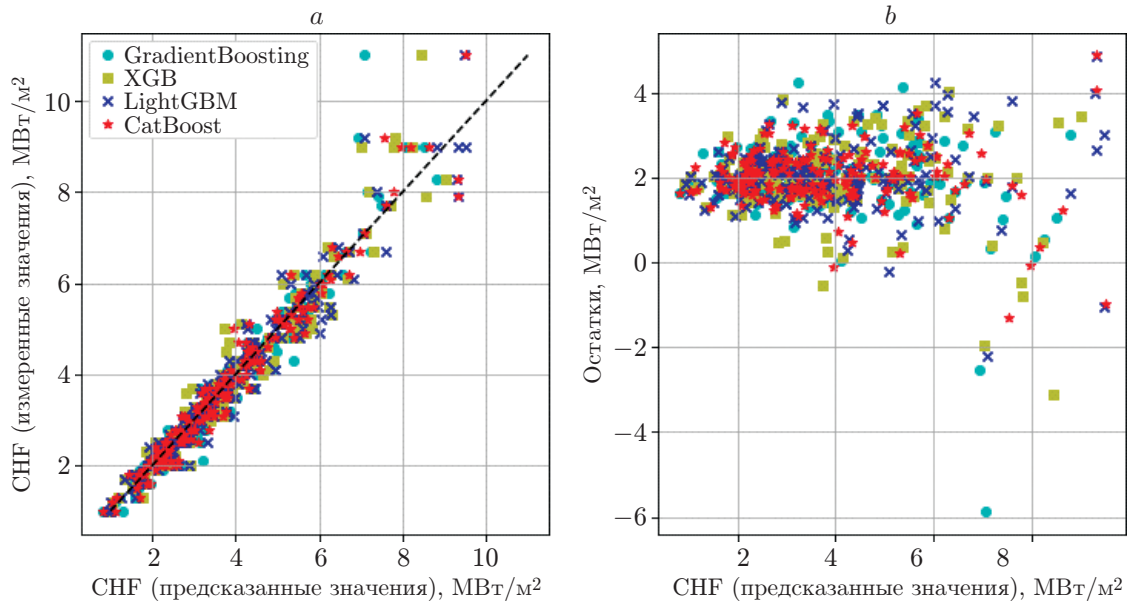


Рис. 4. Результаты сравнения моделей: зависимости измеренных и предсказанных значений критической плотности теплового потока (а) и распределение остатков на тестовой выборке моделей на основе градиентного бустинга (b)

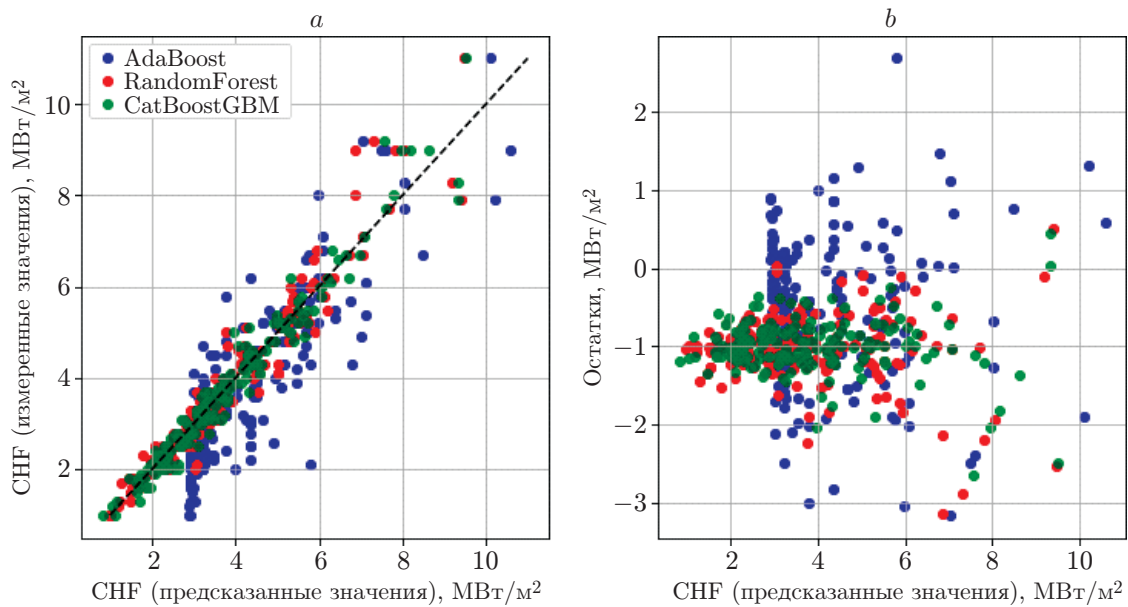


Рис. 5. Результаты сравнения моделей: зависимости измеренных и предсказанных значений критической плотности теплового потока (а) и распределение остатков для моделей на основе градиентного бустинга для моделей AdaBoost и RandomForest в сравнении с лучшей моделью на основе градиентного бустинга CatBoost на тестовой выборке (b)

Таблица 4

**Оценки качества алгоритмов МО в сравнении
с альтернативными и гибридными моделями по метрике rRMSE**

Модели	rRMSE, %
CatBoost	9,8
RF [11]	13,6
ANN [11]	13,6
ANN [23]	9,5
LUT [11]	12,0
Liu [11]	30,9
RF + LUT [11]	5,3
RF+ Liu [11]	6,5
ANN + LUT [11]	6,5
ANN+ Liu [11]	5,5

Таблица 5

**Результаты валидации альтернативной модели и алгоритмов МО
на тестовой выборке**

Модели	Метрики		
	RMSE	MAE	R ²
Формулы (2)–(4)	1,299178	0,966111	0,517038
CatBoostRegressor	0,308000	0,177750	0,916507
LinearRegression	0,390799	0,299459	0,700292
CatBoost и формулы (2)–(4)	0,373972	0,207070	0,838616

— табличный метод Groeneveld CHF LUT 2006 [4];

— эмпирическое корреляционное соотношение, определяемое формулами (2)–(4).

Сравнение первых двух алгоритмов с моделями на основе нейронной сети и регрессора RandomForest было выполнено в [13, 25]. В табл. 4 приведены оценки качества моделей для этих методик, а также гибридных моделей, взятых из [13, 25], и лучшего из вышеописанных предикторов CatBoost.

Для сравнения использовалась относительная метрика rRMSE (relative root-mean-square error), определяемая как

$$\text{rRMSE} = 100 \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{\text{CHF}_{\text{test}}^i - \text{CHF}_{\text{pred}}^i}{\text{CHF}_{\text{test}}^i} \right)^2}, \quad (5)$$

где $\text{CHF}_{\text{test}}^i$ — измеренные значения, $\text{CHF}_{\text{pred}}^i$ — предсказанные значения.

Судя по этим данным, CatBoostRegressor выигрывает в качестве у механистической и табличной моделей, даёт результаты, сравнимые с автономными моделями МО [13, 25], но уступает их гибридным моделям.

В модели, основанной на эмпирических соотношениях, в качестве $\text{CHF}_{\text{pred}}^i$ рассматривались значения критической плотности теплового потока, рассчитанные по формулам (2)–(4) с использованием признаков. Она проигрывает автономным моделям машинного обучения даже в области своей применимости, что иллюстрирует рис. 6, а. Здесь использовался не весь набор данных, а только та его часть, которая соответствует условиям формул (2)–(4): геометрия — круглая труба, эквивалентный диаметр от 4 до 20 мм, давление

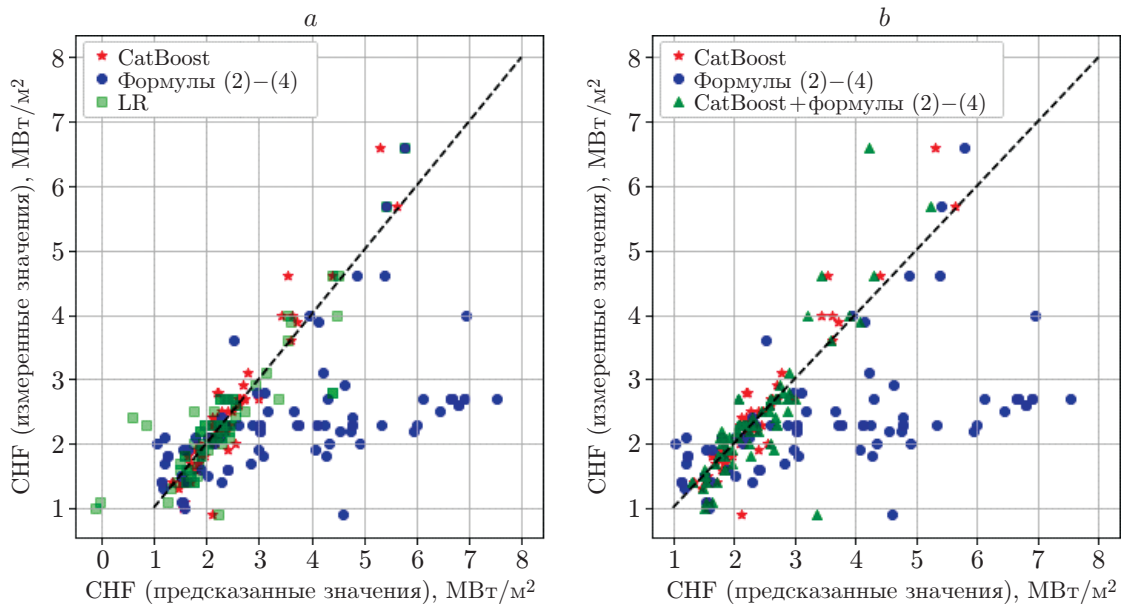


Рис. 6. Результаты сравнения моделей: зависимости измеренных и предсказанных значений критической плотности теплового потока для формул (2)–(4), алгоритмов МО (а) и для гибридной модели по сравнению с автономными на тестовой выборке в части данных, соответствующих области применимости формул (2)–(4) (b)

от 3 до 16 МПа, массовый расход от 750 до 2000 кг/(с·м²). Этим условиям удовлетворяет только 288 наблюдений из исходного набора. Метрики качества для трёх моделей, представленных на рис. 6, приведены в табл. 5.

Результаты совмещения эмпирических соотношений (2)–(4) с регрессором МО в гибридной схеме показаны на рис. 6, b. В качестве алгоритма, использованного для обучения остатков, лучшим из рассмотренных оказался CatBoostRegressor. Гибридный подход позволил существенно улучшить качество первичной модели (2)–(4), но итоговый результат оказался хуже показателей автономных моделей машинного обучения (табл. 5).

Заключение. Проведён сравнительный анализ алгоритмов машинного обучения, доступных в библиотеках с открытым кодом, для набора данных полученного на основе опубликованных экспериментальных результатов исследования кризиса оттеснения жидкой фазы (кризиса первого рода) при кипении в каналах различной геометрии. На этих данных были протестированы 12 алгоритмов машинного обучения, включающие линейные модели, ансамбли деревьев и нейросетевые модели. Была реализована эмпирическая корреляционная модель, допустимая для ограниченного диапазона входных характеристик, и применён гибридный подход, совместивший эту модель с лучшим из рассмотренных предикторов. По итогам исследования можно сделать следующие выводы.

1. Лучшие показатели по всем метрикам качества продемонстрировали ансамблевые модели на основе градиентного бустинга. Лучшим регрессором по результатам исследования оказался алгоритм CatBoostRegressor с показателями $RMSE = 0,342672$, $MAE = 0,200864$, $R^2 = 0,975981$.

2. Из традиционных методик расчёта CHF по данным, приводимым в литературе, лучшим является табличный метод Groeneveld CHF LUT 2006. Он превосходит механистические и корреляционные расчётные соотношения и многие из автономных моделей МО, особенно по возможностям экстраполяции. Однако использование таблиц для ком-

пьютерных расчётов неудобно, так как требует дополнительных процедур для значений входных параметров, не приведённых в таблицах. Таким образом, алгоритмы МО обладают преимуществом по сравнению с альтернативными методами расчёта CHF.

3. Корреляционные формулы просты и удобны в применении, но выполняются только в ограниченной области условий потока. Но даже в адекватном им диапазоне параметров точность предсказаний CHF по формулам (2)–(4) значительно уступает автономным моделям МО.

4. Гибридные подходы, совмещающие модели, которые основаны на знаниях предметной области, с машинным обучением, обладают очевидным преимуществом перед автономными моделями. Особенно эффективным по данным, приводимым в литературе, является использование в качестве базовой модели табличного метода Groeneveld CHF LUT 2006.

5. Гибридный подход, при котором в качестве базовой модели использовались формулы (2)–(4), а модель MO CatBoostRegressor применялась для аппроксимации остатков целевой переменной, дал результат значительно лучший, чем базовая модель только на формулах. Однако, как показали эксперименты, автономные модели МО на этих данных работают эффективнее.

Результаты исследования могут быть использованы для прогнозирования ситуаций, вызванных нежелательным ухудшением теплоотдачи в трубах и каналах, которые обусловлены кризисом кипения.

СПИСОК ЛИТЕРАТУРЫ

1. **Чень Л.** Критический тепловой поток в микроканалах и в замкнутом пространстве. Обзор экспериментальных исследований и методов прогнозирования // Российский химический журнал. 2011. **55**, № 2. С. 85–98.
2. **Кириллов П. Л.** Кризис теплообмена в каналах // Атомная энергия. 1996. **80**, № 5. С. 370–380.
3. **Liu W., Nariai H., Inasaka F.** Prediction of critical heat flux for subcooled flow boiling // Int. Journ. Heat Mass Transf. 2000. **43**. P. 3371–3390.
4. **Groeneveld D. C., Shan J. Q., Vasic A. Z. et al.** The 2006 CHF look-up table // Nucl. Eng. Des. 2007. **237**. P. 1909–1922.
5. **Кириллов П. Л., Юрьев Ю. С., Бобков В. Н.** Справочник по теплогидравлическим расчётам (ядерные реакторы, теплообменники, парогенераторы). М.: Энергоиздат, 1990. 360 с.
6. **Hornik K., Stinchcombe M., White H.** Multilayer feedforward networks are universal approximators // Neural Networks. 1989. **2**, Iss. 5. P. 359–366.
7. **Chinnov E. A., Abdurakipov S. S.** Interaction of 3D waves with thermocapillary structures in a heated liquid film // Int. Journ. Heat and Mass Transfer. 2020. **156**, N 1. P. 119822.
8. **Chinnov E. A., Abdurakipov S. S.** The effect of external disturbances on thermal entry length // High Temperature. 2014. **52**, N 2. P. 235–240.
9. **Nafey A. S.** Neural network based correlation for critical heat flux in steam-water flows in pipes // Int. Journ. Thermal Sci. 2009. **48**, N 12. P. 2264–2270.
10. **Su G., Fukuda K., Jia D., Morita K.** Application of an artificial neural network in reactor thermohydraulic problem: Prediction of critical heat flux // Journ. Nuclear Sci. and Technol. 2002. **39**, N 5. P. 564–571.
11. **Cong T., Su G., Qiu S., Tian W.** Applications of ANNs in flow and heat transfer problems in nuclear engineering: A review work // Progress in Nuclear Energy. 2013. **62**. P. 54–71.

12. **Karniadakis G. E., Kevrekidis I. G., Lu L. et al.** Physics-informed machine learning // Nature Rev. Phys. 2021. **3**, N 6. P. 422–440.
13. **Zhao X., Shirvan K., Salko R. K., Guo F.** On the prediction of critical heat flux using a physics-informed machine learning-aided framework // Appl. Thermal Eng. 2020. **164**. P. 114540.
14. **Shahane S.** Predicting Critical Heat Flux: Prediction of critical heat flux using Machine Learning. URL: <https://www.kaggle.com/saurabhshahane/predicting-heat-flux> (дата обращения: 08.12.2021).
15. **Inasaka F., Nariai H.** Critical heat flux of subcooled flow boiling for water in uniformly heated straight tubes // Fus. Eng. Des. 1992. **19**. P. 329–337.
16. **Peskov O. L., Subbotin V. I., Zenkevich B. A., Sergeyev N. D.** The critical heat flux for the flow of steam-water mixtures through pipes // Probl. Heat Transf. Hydraul. Two Phase Media. 1969. **1**. P. 48–62.
17. **Thompson B., Macbeth R. V.** Boiling water heat transfer burnout in uniformly heated round 29 tubes: A compilation of world data with accurate correlations // United Kingdom Atomic Energy Authority Report AEEW-R356. 1964.
18. **Weatherhead R. J.** Nucleate boiling characteristics and the critical heat flux occurrence in subcooled axial-flow water systems. Argonne National Laboratory Report ANL-6675, 1963.
19. **Williams C. L., Beus S. G.** Critical heat flux experiments in a circular tube with heavy water and light water. AWBA Development Program. WAPD-TM-1462. 1980.
20. **Beus S. G., Seebold O. P.** Critical heat flux experiments in an internally heated annulus with a non-uniform, alternate high and low axial heat flux distribution. AWBA Development Program, WAPD-TM-1475, 1981.
21. **Janssen E., Kervinen J. A.** Burnout conditions for single rod in annular geometry, Water at 600 to 1400 psia. GEAP-3899, 1963.
22. **Mortimore E. P., Beus S. G.** Critical heat flux experiments with a local hot patch in an internally heated annulus. LWBR development program, WAPD-TM-1419, 1979.
23. **Kossolapov A., Su G., McKrell T. et al.** Transient flow boiling and CHF under exponentially escalating heat inputs // Proc. of the 17th Int. Top. Meet. Nucl. React. Therm. Hydraul. Xi'an, Shaanxi, China, 3–8 Sept., 2017.
24. **Richenderfer A. J.** Experimental Study of Heat Flux Partitioning in Pressurized Subcooled Flow Boiling. Ph. D. thesis. Massachusetts Institute of Technology, 2018.
25. **Zhao X.** Prediction of steam-water flow boiling critical heat flux in tubes and annuli using physics-informed deep feed-forward neural networks. Project report. 2018.
26. **Zhao X., Salko R. K., Shirvan K.** Machine learning-based critical heat flux predictors in subcooled and low-quality flow boiling // Proc. of the Int. Top. Meet. Adv. Therm. Hydraul. (ATH 2018). Orlando, USA, Nov. 11–15, 2018. P. 945–948.
27. **Абдуракипов С. С., Токарев М. П., Первунин К. С., Дулин В. М.** Моделирование характеристик тонального шума методами машинного обучения при обтекании гидропрофиля // Автометрия. 2019. **55**, № 2. С. 123–131. DOI: 10.15372/AUT20190213.
28. **Абдуракипов С. С., Бутаков Е. Б.** Сравнительный анализ алгоритмов машинного обучения для определения предотказных и аварийных состояний авиадвигателей // Автометрия. 2020. **56**, № 6. С. 34–48. DOI: 10.15372/AUT20200605.

Поступила в редакцию 08.12.2021

После доработки 20.01.2022

Принята к публикации 20.01.2022
