

О. С. Дмитриева, Г. Р. Бадретдинова, А. В. Дмитриев

ПРОГНОЗИРОВАНИЕ ПАРАМЕТРОВ РАБОТЫ МУЛЬТИВИХРЕВОГО КЛАССИФИКАТОРА С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ В СРЕДЕ ORANGE DATA MINING

Ключевые слова: классификация частиц, эффективность классификации, машинное обучение, анализ данных, точность модели регрессии.

Классификация сухих частиц по размеру имеет множество применений во многих отраслях. В процессе приготовления порошки должны иметь узкое распределение частиц по размерам, поэтому применение классификаторов позволяет обеспечить заданные параметры и не допустить чрезмерного измельчения. Эксплуатационные характеристики при этом оцениваются в результате экспериментальных исследований и численного моделирования. В Ansys Fluent был смоделирован мультивихревой классификатор для изучения влияния различных факторов на эффективность классификации. Поскольку объем данных постоянно увеличивается, человеку становится трудно анализировать их вручную для принятия стратегических решений. Целью исследования является разработка модели для анализа данных с помощью программного обеспечения Orange Data Mining с визуальным интерфейсом. Представлен процесс оценки сравнительных результатов протестированной модели прогнозирования. В виджете «Тестирование и оценка» отображаются результаты девяти алгоритмов классификации, где результаты сравнения прогнозирования эффективности классификации частиц показаны со значением MSE, RMSE, MAE, MAPE и R2. Результаты оценки показали, что модели прогнозирования эффективности имеют разный уровень точности. Метод опорных векторов (SVM), метод на нейронных сетях, градиентный бустинг имеют более низкие коэффициенты регрессии для линейных MAE и RMSE по сравнению с kNN и другими алгоритмами классификации. Результат прогнозирования с помощью метода Neural Network соответствует прогнозу эффективности работы мультивихревого классификатора с небольшой погрешностью. Наилучший метод, использованный в этом исследовании, может быть повторно применен в будущих исследованиях, чтобы получить оптимальные конструкции мультивихревого сепаратора, обеспечивающие высокую точность классификации.

O. S. Dmitrieva, G. R. Badretdinova, A. V. Dmitriev

PREDICTING THE PARAMETERS OF THE MULTI VORTEX CLASSIFIER USING MACHINE LEARNING IN THE ORANGE DATA MINING ENVIRONMENT

Keywords: particle classification, classification efficiency, machine learning, data analysis, regression model accuracy.

The classification of dry particles by size has many applications in many industries. During the preparation process, powders must have a narrow particle size distribution, so the use of classifiers allows you to ensure the specified parameters and prevent excessive grinding. Here, the operational characteristics are evaluated because of experimental studies and numerical modeling. A multivortex classifier was modeled in Ansys Fluent to study the influence of various factors on classification efficiency. As the amount of data is constantly increasing, it becomes difficult for a person to analyze it manually to make strategic decisions. The aim of the research is to develop a model for data analysis using Orange Data Mining software with a visual interface. The process of evaluating the comparative results of the tested forecasting model is presented. The "Testing and Evaluation" widget displays the results of nine classification algorithms, where the results of comparing the prediction of the effectiveness of particle classification are shown with the values of MSE, RMSE, MAE, MAPE and R2. The evaluation results showed that performance forecasting models have different levels of accuracy. The Support Vector Machine (SVM), neural network method, and gradient boosting have lower regression coefficients for linear MAE and RMSE compared to kNN and other classification algorithms. The prediction result using the Neural Network method corresponds to the prediction of the effectiveness of the multi-vortex classifier with a small error. The best methodology used in this study can be re-applied in future studies to get optimal multivortex separator designs that ensure high classification accuracy.

Классификация частиц является одной из наиболее важных единичных операций при их обработке и широко применяется в ряде отраслей промышленности, включая химическую, перерабатывающую, фармацевтическую, пищевую и др. Сыпучие материалы, подвергаемые переработке, после измельчения обычно имеют широкое распределение по размерам, и это распределение может варьироваться в зависимости от свойств материала и преобладающих условий эксплуатации, что в свою очередь оказывает влияние на другие характеристики материала, такие как, текучесть, сегрегация, растворение и т.д. Для этих целей существуют гравитационные, каскадные, кипящего слоя, инерционные и центробежные классификаторы [1–4].

Широкое применение центробежных классификаторов обусловлено простой конструкцией, высокой производительностью, устойчивостью и эффективностью разделения, а также небольшой занимаемой площадью. Были проведены обширные исследования по вопросам геометрического проектирования и эксплуатации центробежных классификаторов [5–7], кроме того, предпринимаются попытки решить проблемы, возникающие при физических испытаниях, использованием вычислительной гидродинамики (CFD), но все еще существуют некоторые трудности, а проблема повышения эффективности фракционирования измельченных материалов является актуальной.

В этой связи были предприняты многочисленные попытки, как экспериментально, так и вычислительно,

углубиться в вышеупомянутые трудности, связанные с классификаторами. Авторами был разработан мультивихревой классификатор с соосно расположенными трубами, конструкция защищена патентом РФ № 201604 [8]. В результате проведения промышленных испытаний конструкция показала себя только с положительной стороны, по результатам испытаний был установлен характер работы конструкции, для эквивалентного диаметра частиц 3,70, 14,75 и 53,44 мкм эффективность составила 10, 50 и 90%. Высота внутренней трубы 190 мм, внешней – 240 мм. Внутренняя труба на 30 мм расположена выше относительно внешней трубы, ширина и высота каждого прямоугольного отверстия 6 и 60 мм соответственно, диаметр и высота цилиндрического блока равен 325 мм и 200 мм соответственно. Размеры внутренней части цилиндрической трубы и выходного патрубка – 108×4 мм, внешней цилиндрической трубы – 159×5 мм, расстояние от верхнего края внешней цилиндрической трубы до начала выходного патрубка – 45 мм. Результаты серии испытаний представлены в работе [9] и были использованы для проверки прогнозов нашей модели CFD. Эти исследования принесли полезные идеи и более четкое восприятие процесса разделения в мультивихревом классификаторе, они были дополнены численным моделированием течения с помощью пакета ANSYS Fluent. В последствии при сравнении физического эксперимента с численным погрешность составляла не более 15-20%. Граничные условия – на входе в мультивихревой классификатор задавали входную скорость потока (по объемному расходу газового потока 0,03 м³/с), на выходе из аппарата задали атмосферное давление. Плотность частиц 1075 кг/м³, плотность воздуха 1,22 кг/м³. Размер частиц сыпучего материала изменялся от 5 до 100 мкм. При численном моделировании сеточная модель строилась на основе проточной области, которая разбивалась на множество контрольных объемов, представленных в виде ячеек полиэдрических элементов в количестве 219668 шт. Пристеночные зоны $y^+ \approx 1$ учитывали, для этого были построены призматические слои. Применяли итерационный подход. Вычислительный процесс сопровождается несколькими предположениями и упрощениями в управляющих механизмах – форма частиц принималась сферической, взаимодействие частиц между собой при движении газового потока не учитывалось, задавалось условие прилипания частиц на дне устройства, условие отскока частиц на стенках классификатора, фазовые переходы отсутствуют, влажность не учитывается, рассматривался идеальный газ, температура потока 20°C. Была выбрана модель турбулентности k- ω SST, которая менее затратная в вычислительном отношении. В конце каждого расчета фиксировалось значение количества частиц на дне n_{out} , что позволяло определить эффективность работы классификатора по выражению $E = n_{out}/n_{in}$, где $n_{in} = 1000$ – количество введенных частиц [10, 11].

При этом, хотя вычислительные подходы продемонстрировали надежные возможности в моделировании сложных процессов в классификаторе, они остаются трудоемкими. Учитывая вышеизложенные опасения и принимая во внимание, что анализ регулируемых

характеристик классификаторов может быть значительно обременительным, крайне важно иметь надежный инструмент для анализа, прогнозирования следующих проектов до моделирования и тестирования прототипов классификаторов удобным способом.

Другими словами, существует очевидная потребность в разработанной методике, которая может предсказать эффективность классификации в различных рабочих условиях эксплуатации мультивихревого классификатора.

С этой целью во всем мире внедряются подходы машинного обучения, которые в настоящее время широко применяются во многих областях промышленности. Идея, лежащая в основе этого интеллекта, заключается в способности запрограммированного на обучение на основе системы входных данных модуля извлекать интересную информацию с участием человека или без него. Главное преимущество этой технологии заключается в экономии затрат и времени при предоставлении тщательного обзора того, что будет храниться в базах данных. Кроме того, эти инструменты просты в реализации и позволяют избежать трудоемких экспериментальных процедур и сложных процессов интерпретации.

Следовательно, существует потребность в автоматизированных инструментах, которые могут помочь исследователям преобразовать эти огромные данные в информацию. В настоящее время доступно множество инструментов и программного обеспечения для интеллектуального анализа данных с открытым исходным кодом, например, Orange, написанный на языке Python [12].

Цель настоящей статьи заключается в разработке модели для прогнозирования параметров работы мультивихревого классификатора с использованием методов машинного обучения и анализа данных в программе Orange Data Mining. Это позволит оптимизировать процесс классификации частиц и повысить точность работы устройства за счет точного предсказания ключевых характеристик его функционирования.

Основными разделами программы являются управление данными и предварительная обработка, классификация, регрессия, ассоциация, ансамбли, кластеризация, оценка и прогнозирование. Этот инструмент имеет графический интерфейс пользователя (визуальное программирование). Графический интерфейс пользователя состоит из виджетов. Эти виджеты взаимодействуют через каналы, а определенный набор связанных виджетов называется схемой (рис. 1).

Мы загрузили набор данных, полученных в результате численного моделирования, именно они формируют дальнейшие обучающие данные («data train»), далее провели сравнительное исследование между алгоритмами классификации, такими как, случайный лес Random Forest, метод k-ближайших соседей (kNN), дерево решений Decision Tree, Gradient Boosting, метод опорных векторов SVM, метод стохастического градиентного спуска SGD, Neural Network нейронная сеть, метод регрессионного анализа PLS, композиция алгоритмов обучения AdaBoost с использованием Orange, предварительно настроив их параметры. Алгоритм классификации данных – это процедура выбора гипо-

тезы из набора альтернатив, которая наилучшим образом соответствует набору данных. Процесс классификации данных состоит из двух этапов: 1) построение модели классификатора путем изучения обучающего набора и связанных с ним меток классов, 2) использование классификатора для классификации [13].

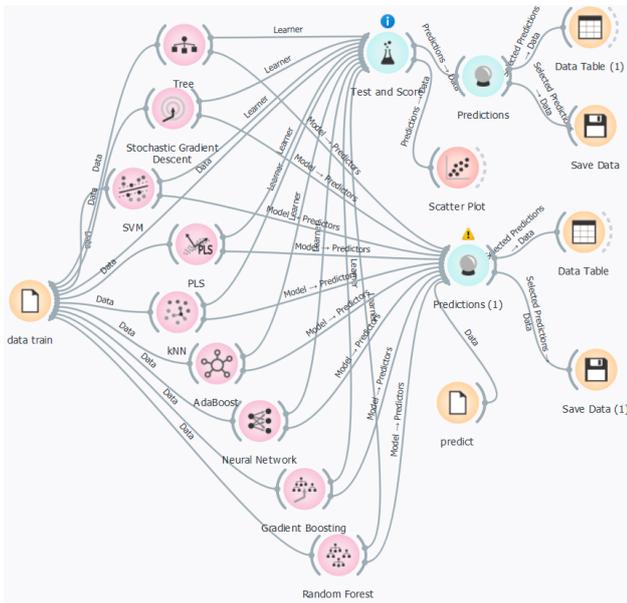


Рис. 1 – Поток обработки данных (workflow) в программе Orange Data Mining 3.37.0, созданный для предиктивного анализа мультивихревого классификатора

Fig. 1 – Data processing flow (workflow) in the Orange Data Mining 3.37.0 program, created for predictive analysis of a multi-vortex classifier

Для анализа использовались следующие модели с параметрами [14, 15]:

Random Forest – это метод ансамблевого обучения, основанный на бинарных деревьях решений. В данном случае, минимальное количество экземпляров в каждом листе дерева равно 2, а максимальная глубина дерева ограничена 5 уровнями. Обучение прекращается, когда достигается 95% большинства.

k-Nearest Neighbors (kNN) или метод k-ближайших соседей – это непараметрический метод классификации и регрессии, который использует ближайших соседей для предсказания. В данном случае, используется 3 соседа и Евклидова метрика для определения расстояния между объектами. Веса присваиваются на основе кратчайшего расстояния. kNN не делает строгих предположений о распределении базовых данных, поэтому алгоритм очень гибкий. Однако kNN имеет высокую вычислительную сложность, особенно для больших наборов данных, поскольку требует вычисления расстояния между каждой парой данных.

Дерево принятия решений Decision Tree – это метод обучения с учителем, который использует бинарные деревья для принятия решений. В данном случае, используется 25 нейронов с функцией активации выпрямленный линейный блок ReLU. Обучение осуществляется с помощью решателя L-BFGS-B с максимальным количеством итераций 200 и включенным воспроизводимым обучением.

Gradient Boosting – это метод ансамблевого обучения, который использует градиентный спуск для последовательного добавления слабых моделей (деревьев). В данном случае, используется метод CatBoost с 100 деревьями, скоростью обучения 0.3, регуляризацией lambda 3, глубиной деревьев True и субдискретизацией 1.0.

Метод опорных векторов Support Vector Machine (SVM) – это метод машинного обучения, который используется для задач классификации и регрессии, где находится гиперплоскость, разделяющая классы с максимальным зазором. В данном случае, используется линейное ядро с параметрами: C 1, эpsilon 0.1, регрессия C 1, предел сложности ν 0,1, числовая толерантность 0,001, лимит итераций 100 и гиперпараметр ядра 0,1.

Метод стохастического градиентного спуска Stochastic Gradient Descent (SGD) – это метод оптимизации, который используется для обучения перцептронов и нейронных сетей. Параметры границы классов устанавливаются на основе градиента, определяющего направление наиболее быстрого уменьшения суммы ошибок классификации. В данном случае, используется скорость обучения 0,1, регуляризация Ridge или L2 с силой регуляризации 0,00001, 100 итераций, толерантность 0,001, перемешивание данных после каждой итерации и фиксированное значение случайного перемешивания 0.

Neural Network – это метод машинного обучения, основанный на искусственных нейронных сетях. В данном случае, используется 25 нейронов с активацией ReLU, решателем L-BFGS-B с максимальным количеством итераций 200, включенным воспроизводимым обучением.

Partial Least Squares (PLS) – это метод регрессионного анализа, который используется для уменьшения размерности данных. В данном случае, используется 2 компонента, масштабирование признаков и целей, а также лимит количества итераций 500.

AdaBoost – это метод ансамблевого обучения, который использует слабые модели для создания сильного классификатора. В данном случае, базовым оценщиком является дерево с 50 оценщиками, коэффициентом обучения 1.0 и методом бустинга SAMME.R. Алгоритм классификации – линейный, с фиксацией случайных чисел на значении 42.

Здесь тестовые данные используются для оценки точности правил классификации. В задаче классификации необходимо не только определить принадлежность объекта классу по набору атрибутов, но и оценить вероятность такой классификации. Показатель точности, который представляет собой процент правильно классифицированных экземпляров, используется для оценки эффективности алгоритма классификации.

Большое количество алгоритмов классификации позволяет сравнивать их применение и выбирать наиболее подходящий алгоритм для решения задачи по предложенному набору данных с помощью виджета «Test and Score» (таблица). Входом для него служат данные для обучения и тестирования алгоритмов и сами алгоритмы. Выходом являются оценки характеристик алгоритмов. Результаты прогнозирования

можно посмотреть с помощью виджета «Predictions» и графика «Scatter Plot», чтобы увидеть моделирование формы диаграммы разброса.

В этом же виджете «Test and Score» также отображаются результаты методов оценки, где результаты сравнения двух моделей прогнозирования эффективности классификации показаны со значением MSE, RMSE, MAE, MAPE и R2.

Таблица 1 – Параметры и результаты виджета «Test and Score»

Table 1 – Parameters and results of the «Test and Score» widget

Алгоритм классификации	MSE	RMSE	MAE	MAPE	R2
Neural Network	0,001	0,033	0,022	0,107	0,988
SVM	0,002	0,045	0,035	0,181	0,977
Gradient Boosting	0,002	0,045	0,030	0,229	0,977
kNN	0,003	0,055	0,039	0,122	0,965
AdaBoost	0,005	0,069	0,054	0,194	0,945
Random Forest	0,005	0,074	0,055	0,202	0,938
Tree	0,010	0,098	0,075	0,258	0,891
PLS	0,015	0,124	0,093	0,274	0,824
SGD	0,015	0,124	0,093	0,273	0,823

MSE (среднеквадратическая ошибка) является ключевой метрикой для оценки качества моделей машинного обучения и регрессии. Она вычисляется как среднее значение квадратов разностей между истинными и предсказанными значениями. RMSE (корень среднеквадратической ошибки) представляет собой квадратный корень из MSE и используется для сравнения точности моделей с различными масштабами и единицами измерения. MAE (средняя абсолютная ошибка) измеряет среднюю абсолютную разницу между истинными и предсказанными значениями, что позволяет сравнивать модели с разными масштабами и единицами измерения. Меньшее значение MAE указывает на то, что модель более точно предсказывает значение, которое действительно имеет место. MAPE (средняя процентная ошибка, доля MAE) оценивает среднюю процентную разницу между истинными и предсказанными значениями, также учитывая различия в масштабах и единицах измерения. R2 (коэффициент детерминации) является метрикой для оценки качества моделей в контексте линейной регрессии и принимает значения от 0 до 1, где 0 указывает на отсутствие корреляции, а 1 – на идеальную корреляцию между истинными и предсказанными значениями.

Точность модели прогнозирования при составлении прогнозов определяется наименьшим значением каждого метода оценки точности данных (табл. 1). В ходе исследования были получены результаты, пред-

ставленные в таблице. Анализ данных позволяет сделать вывод, что наиболее эффективными моделями машинного обучения и регрессии для прогнозирования параметров мультивихревого классификатора являются нейронные сети, метод опорных векторов (SVM) и градиентный бустинг. Модели Tree, PLS и Stochastic Gradient Descent являются менее эффективными.

На рисунках 2–5 представлен процесс оценки сравнительных результатов протестированной модели прогнозирования эффективности классификации от диаметра частиц при разных скоростях потока в мультивихревом классификаторе с помощью виджета диаграмма рассеяния «Scatter Plot», где можно выделить выбросы – точки данных, которые значительно отличаются от других наблюдений.

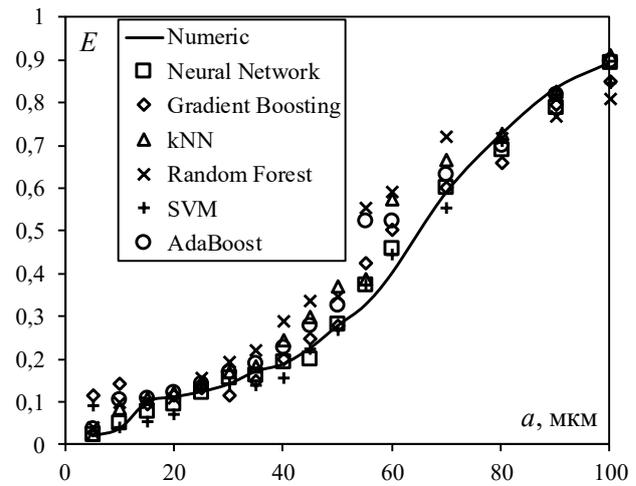


Рис. 2 – Зависимость эффективности работы мультивихревого классификатора от диаметра частиц. Скорость газа на входе в мультивихревой классификатор составляет 1,5 м/с. Результаты численного моделирования представлены линией, а результаты на основе моделей машинного обучения – точками

Fig. 2 – The dependence of the efficiency of the multi vortex classifier on the particle diameter. The gas velocity at the entrance to the multi-vortex classifier is 1.5 m/s. The results of numerical modeling are represented by a line, and dots represent the results based on machine learning models

Скорость потока может значительно влиять на эффективность классификации (рис. 2–5). При высокой скорости потока турбулентность может увеличиваться, что может затруднить точное разделение частиц по размерам. С другой стороны, оптимальная скорость потока может способствовать более четкому разделению частиц, улучшая эффективность классификации.

Нейронные сети Neural Network способны выявлять сложные зависимости в данных и могут быть более устойчивыми к изменениям в диаметре частиц. Однако, для их обучения требуется больше данных и вычислительных ресурсов. Оптимальная калибровка параметров метода может привести к значительной точности модели, поэтому необходим систематический анализ, чтобы увидеть влияние этих параметров на производительность.

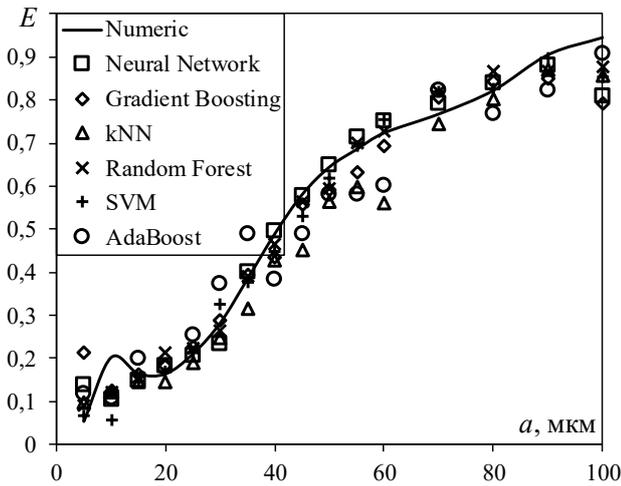


Рис. 3 – Зависимость эффективности работы мультивихревого классификатора от диаметра частиц. Скорость газа на входе в мультивихревой классификатор составляет 8 м/с. Результаты численного моделирования представлены линией, а результаты на основе моделей машинного обучения – точками

Fig. 3 – The dependence of the efficiency of the multi vortex classifier on the particle diameter. The gas velocity at the entrance to the multi-vortex classifier is 8 m/s. The results of numerical modeling are represented by a line, and dots represent the results based on machine learning models

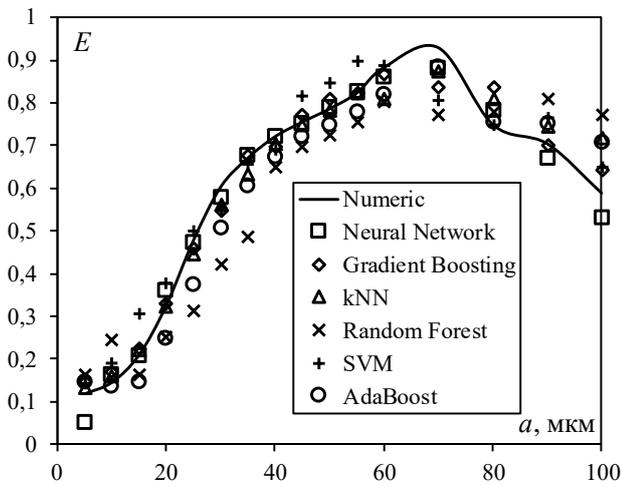


Рис. 4 – Зависимость эффективности работы мультивихревого классификатора от диаметра частиц. Скорость газа на входе в мультивихревой классификатор составляет 25 м/с. Результаты численного моделирования представлены линией, а результаты на основе моделей машинного обучения – точками

Fig. 4 – The dependence of the efficiency of the multi vortex classifier on the particle diameter. The gas velocity at the entrance to the multi-vortex classifier is 25 m/s. The results of numerical modeling are represented by a line, and dots represent the results based on machine learning models

kNN модель может быть эффективной для задач классификации, где данные имеют четкие границы между классами. Однако, с увеличением диаметра ча-

стиц, различия между классами могут становиться менее выраженными, что может снизить точность kNN. AdaBoost чувствителен к шумным данным и выбросам, что снижает его эффективность. Шум состоит из ошибок измерения, аномалий или несоответствий в собранной информации. Обработка шума важна, поскольку он может привести к ненадежным моделям и неверным прогнозам. Gradient Boosting требует тщательной настройки гиперпараметров для достижения оптимальной производительности, метод также чувствителен к шуму, хоть и менее, чем AdaBoost.

Отклонение Random Forest связано с тем, что выбор количества деревьев и глубины может повлиять на производительность, хоть он и менее чувствителен к настройке параметров.

С увеличением скорости потока до 25 м/с и диаметром частиц (от 70 мкм), различия между классами могут становиться менее выраженными, что усложняет задачу классификации. Это может быть связано с тем, что более крупные частицы могут иметь схожие аэродинамические свойства, что затрудняет их разделение из-за турбулизации потока (рис. 4).

Каждая из этих моделей имеет свои сильные и слабые стороны, и выбор подходящей модели зависит от специфики задачи, доступных данных и вычислительных ресурсов. Экспериментирование с различными моделями и их настройка может помочь найти оптимальное решение.

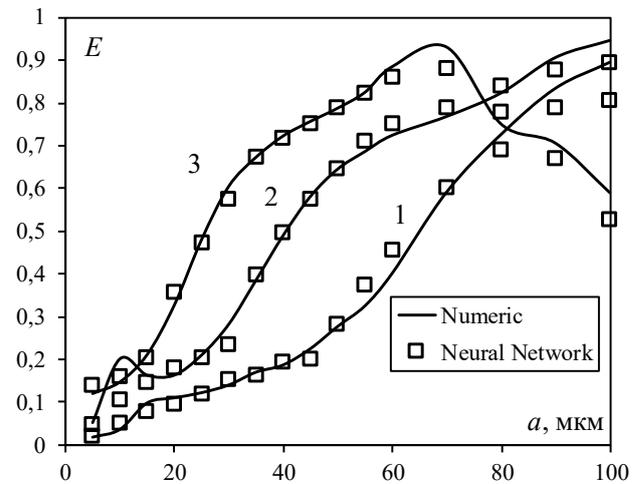


Рис. 5 – Зависимость эффективности работы мультивихревого классификатора от диаметра частиц. Скорость газа на входе в мультивихревой классификатор, м/с: 1 – 1,5; 2 – 8; 3 – 25. Результаты численного моделирования представлены в виде линии, а результаты, полученные с помощью модели машинного обучения Neural Network, показаны в виде точек

Fig. 5 – The dependence of the efficiency of the multi vortex classifier on the particle diameter. Gas velocity at the entrance to the multi-vortex classifier, m/s: 1 – 1,5; 2 – 8; 3 – 25. The results of numerical simulation are presented as a line, and the results got using the Neural Network machine learning model are shown as dots

Более низкие скорости потока приводят к более крупным размерам фракций, т.к. эффективная центробежная сила, действующая на частицу, снижается, что

снижает четкость классификации и является нежелательным (рис. 5). Отметим, что прогнозы практически полностью совпадают с исходными данными. Для достижения наилучших результатов важно учитывать все эти факторы и, возможно, использовать комбинацию различных методов машинного обучения для оптимизации процесса классификации.

Таким образом, предлагаемый метод, основанный на использовании программы Orange Data Mining, открывает большие возможности для поиска наиболее подходящих моделей машинного обучения и прогнозирования неизвестных параметров. Это, в свою очередь, значительно сокращает время, необходимое для численного моделирования, и позволяет быстрее получать необходимые результаты экспериментальным путем.

Кроме того, предложенный подход позволяет сократить расход материалов и энергии, необходимых для проведения экспериментальных исследований.

Разработанная модель точно отражает характеристики разделения частиц и может использоваться для изучения мультивихревого классификатора. Небольшая доработка модели позволит получить оптимальные размеры мультивихревого классификатора и технологические параметры, при которых его эксплуатация будет наиболее эффективной с высокой точностью классификации.

Исследование выполнено за счет гранта Российского научного фонда № 24-29-20061, <https://rscf.ru/project/24-29-20061/>.

The research was carried out at the expense of the grant of the Russian Science Foundation No. 24-29-20061, <https://rscf.ru/project/24-29-20061/>.

Литература

1. J. Chladek, C.K. Jayarathna, B.M.E. Moldestad, L-A Tokheim, *Chemical Engineering Science*, **177**, 151–162 (2018). DOI: 10.1016/j.ces.2017.11.042.
2. В.Б. Пономарев, В.Л. Данилов, А.В. Катаев, *Вестник Белгородского государственного технологического университета им. В.Г. Шухова*, **2**, 172–174 (2010).
3. A.K. Pukkella, J. Cilliers, K. Hadler, *Powder Technology*, **433**, 119217 (2024). DOI: 10.1016/j.powtec.2023.119217.
4. В.Я. Борщев, А.А. Кузнецова, *Вопросы современной науки и практики. Университет им. В.И. Вернадского*, **48**, 4, 147–151 (2013).
5. Q. Zhao, B. Cui, A. Ji, T. Song, Y. Shen, *Advanced Powder Technology*, **35**, 4, 104398 (2024). DOI: 10.1016/j.apt.2024.104398.
6. Р.Р. Турубаев, А.В. Шваб, *Инженерно-физический журнал*, **95**, 5, 1248–1256 (2022).
7. М.А. Юровская, Д.Е. Смирнов, А.В. Сугак, В.К. Леонтьев, *Известия высших учебных заведений. Серия Химия и химическая технология*, **57**, 10, 84–86 (2014).
8. Пат. РФ № 201604, заявл. 26.08.2023, опубл. 23.12.2023.
9. В.Э. Зинуров, А.В. Дмитриев, О.С. Дмитриева, К.С. Моисеева, *Вестник технологического университета*, **25**, 4, 58–63 (2022). DOI: 10.55421/1998-7072_2022_25_4_58.
10. V.E. Zinurov, A.V. Dmitriev, I.N. Madyshev, O.S. Dmitrieva, *Chemical and Petroleum Engineering*, **57**, 531–537 (2021). DOI: 10.1007/s10556-021-00971-4.
11. В.Э. Зинуров, А.В. Дмитриев, И.И. Насырова, О.С. Дмитриева, *Вестник технологического университета*, **25**, 4, 71–76 (2022). DOI: 10.55421/1998-7072_2022_25_4_71.
12. A. Naik, L. Samant, *Procedia Computer Science*, **85**, 662–668, (2016). DOI: 10.1016/j.procs.2016.05.251.
13. В.В. Братищенко, *Информационные технологии в бизнес-аналитике с использованием Orange3 и Python*. Изд. дом БГУ, Иркутск, 2021. 117 с.
14. M. Zandieh, A. Kazemi, M. Ahmadi, *Desalination and Water Treatment*, **236**, 123–143 (2021). DOI: 10.5004/dwt.2021.27691.
15. A. Miličević, S. Belošević, M. Žarković, I. Tomanović, N. Crnomarković, A. Stojanović, G. Stupar, L. Deng, D. Che, *Biomass and Bioenergy*, **174**, 106817 (2023). DOI: 10.1016/j.biombioe.2023.106817.

References

1. J. Chladek, C.K. Jayarathna, B.M.E. Moldestad, L-A Tokheim, *Chemical Engineering Science*, **177**, 151–162 (2018). DOI: 10.1016/j.ces.2017.11.042.
2. V.B. Ponomarev, V.L. Danilov, A.V. Kataev, *Vestnik Belgorodskogo gosudarstvennogo tekhnologicheskogo universiteta im. V.G. Shukhova*, **2**, 172–174 (2010).
3. A.K. Pukkella, J. Cilliers, K. Hadler, *Powder Technology*, **433**, 119217 (2024). DOI: 10.1016/j.powtec.2023.119217.
4. V.Ya. Borshchev, A.A. Kuznetsova, *Voprosy sovremennoy nauki i praktiki. Universitet im. V.I. Vernadskogo*, **48**, 4, 147–151 (2013).
5. Q. Zhao, B. Cui, A. Ji, T. Song, Y. Shen, *Advanced Powder Technology*, **35**, 4, 104398 (2024). DOI: 10.1016/j.apt.2024.104398.
6. R.R. Turubaev, A.V. Shvab, *Inzhenerno-fizicheskiy zhurnal*, **95**, 5, 1248–1256 (2022).
7. M.A. Yurovskaya, D.E. Smirnov, A.V. Sugak, V.K. Leont'ev, *Izvestiya vysshikh uchebnykh zavedeniy. Seriya Khimiya i khimicheskaya tekhnologiya*, **57**, 10, 84–86 (2014).
8. Pat. RF № 201604, zayavl. 26.08.2023, opubl. 23.12.2023.
9. V.E. Zinurov, A.V. Dmitriev, O.S. Dmitrieva, K.S. Moiseeva, *Herald of Technological University*, **25**, 4, 58–63 (2022). DOI: 10.55421/1998-7072_2022_25_4_58.
10. V.E. Zinurov, A.V. Dmitriev, I.N. Madyshev, O.S. Dmitrieva, *Chemical and Petroleum Engineering*, **57**, 531–537 (2021). DOI: 10.1007/s10556-021-00971-4.
11. V.E. Zinurov, A.V. Dmitriev, I.I. Nasyrova, O.S. Dmitrieva, *Herald of Technological University*, **25**, 4, 71–76 (2022). DOI: 10.55421/1998-7072_2022_25_4_71.
12. A. Naik, L. Samant, *Procedia Computer Science*, **85**, 662–668, (2016). DOI: 10.1016/j.procs.2016.05.251.
13. V.V. Bratishchenko, *Informatsionnye tekhnologii v biznes-analitike s ispol'zovaniem Orange3 i Python*. Izd. dom BGU, Irkutsk, 2021. 117 p.
14. M. Zandieh, A. Kazemi, M. Ahmadi, *Desalination and Water Treatment*, **236**, 123–143 (2021). DOI: 10.5004/dwt.2021.27691.
15. A. Miličević, S. Belošević, M. Žarković, I. Tomanović, N. Crnomarković, A. Stojanović, G. Stupar, L. Deng, D. Che, *Biomass and Bioenergy*, **174**, 106817 (2023). DOI: 10.1016/j.biombioe.2023.106817.

© **О. С. Дмитриева** – к.т.н., доцент кафедры оборудования пищевых производств, Казанский национальный исследовательский технологический университет, Казань, Россия, ja_deva@mail.ru; **Г. Р. Бадретдинова** – ассистент кафедры автоматизации технологических процессов и производств (АТПП), Казанский государственный энергетический университет (КГЭУ), nice.badretdinova@mail.ru; **А. В. Дмитриев** – д.т.н., зав. кафедрой АТПП, КГЭУ, ieremiada@gmail.com.

© **O. S. Dmitrieva** – PhD (Technical Sci.), Associate Professor, Department of Food Production Equipment, Kazan National Research Technological University, Kazan, Russia, ja_deva@mail.ru; **G. R. Badretdinova** – Assistant of the Department of Automation of Technological Processes and Production (ATPP), Kazan State Energy University (KSEU), nice.badretdinova@mail.ru; **A. V. Dmitriev** – Doctor of Sciences (Technical Sci.), Head of the ATPP department, KSEU, ieremiada@gmail.com.