

УДК 519.237.8; 004.855.5; 004.891; 662.61

МОНИТОРИНГ РЕЖИМОВ ГОРЕНИЯ НА ОСНОВЕ РЕГИСТРАЦИИ ИЗОБРАЖЕНИЙ ПЛАМЕНИ И МАШИННОГО ОБУЧЕНИЯ*

С. С. Абдуракипов^{1,2}, О. А. Гобызов^{1,2}, М. П. Токарев^{1,2},
В. М. Дулин^{1,2}

¹*Институт теплофизики им. С. С. Кутателадзе СО РАН,
630090, г. Новосибирск, просп. Академика Лаврентьева, 1*

²*Новосибирский государственный университет,*

630090, г. Новосибирск, Пирогова 2

E-mail: oleg.a.g.post@gmail.com

Рассматривается способ автоматического определения режима горения по изображениям пламени на основе обучаемой на маркированных данных свёрточной нейронной сети. Показано, что на изображениях пламени газового горелочного устройства точность классификации режимов достигает 98 %. Сравниваются результаты работы свёрточной нейронной сети и классификации с помощью различных линейных моделей.

Ключевые слова: классификация изображений, мониторинг, машинное обучение, свёрточная нейронная сеть, факел.

DOI: 10.15372/AUT20180514

Введение. Важную роль при поддержании или оптимизации процессов сжигания топлива играют средства мониторинга [1, 2]. Анализ изображений факельного сжигания может использоваться в качестве дополнительного источника данных, поскольку наблюдаемые характеристики пламени, такие как размер, форма, положение фронта, яркость и спектр свечения, а также характер изменения этих параметров во времени, несут в себе большой объём информации о режимах горения. Ряд работ в данном направлении посвящён попытке сформулировать метод либо алгоритм оценки параметров процесса сжигания на основе анализа отдельных характеристик изображений пламени. Например, в [3, 4] показано наличие связи соотношения топливо/воздух и температуры в закрученном пламени при сжигании каменного угля и биотоплива с распределением яркости и её пульсаций на изображениях. Примером использования информации о спектральном составе излучения (цвете пламени), непосредственно связанной с происходящими химическими реакциями, может служить метод планарной пирометрии [5].

Ещё одним подходом к мониторингу, помимо непосредственного установления зависимости отдельных характеристик изображения пламени от параметров сжигания, может быть сопоставление изображения пламени и режима горения, т. е. характерного диапазона параметров, в котором реализуется данный режим. Для осуществления такого подхода необходимо решать задачу классификации изображений пламени на основе многомерного вектора признаков. В научной литературе на сегодняшний день тема использования мето-

*Работа выполнена при финансовой поддержке Министерства образования и науки РФ (проект № 14.604.21.0162).

дов автоматического выделения признаков для классификации режимов горения практически не затрагивалась. Для классификации с применением многомерного вектора признаков в качестве входных данных существует широкий ряд методов [6]: метод опорных векторов, нейронная сеть (например, многослойный персептрон), градиентный бустинг над линейными моделями или деревьями решений и другие. Эффективность таких методов для решения задач компьютерного зрения во многом зависит от экспертных знаний исследователя по созданию признакового описания изображений. Важно отметить, что использование каждого пикселя в качестве независимого входного параметра затруднено в силу того, что количество входных переменных модели оказывается чрезвычайно велико. В связи с этим к изображениям применяются методы понижения размерности, например метод главных компонент или методы кластеризации для объединения групп похожих пикселей.

Ещё один эффективный способ решения задачи классификации изображений — использование свёрточных нейронных сетей (CNN — Convolutional Neural Network) [7]. Этот тип нейросетевых алгоритмов успешно применяется к широкому классу задач, включая распознавание рукописного ввода и лиц на изображениях. Базовыми для свёрточной нейронной сети являются две выполняющиеся в отдельных слоях операции: свёртка и субдискретизация [8]. Свёрточный слой многократно сокращает число параметров по сравнению с полносвязным слоем, однако использует больше гиперпараметров, которые должны быть определены до процедуры обучения.

Стандартным подходом к обучению CNN является обучение на маркированных данных (обучение с учителем), но для решения задачи могут применяться методы, не использующие разметку при обучении (обучение без учителя). Формирование выборки маркированных данных для обучения нейронной сети считается трудоёмким, хотя для анализа и классификации изображений пламени такой подход представляется оправданным, поскольку формирование корпуса маркированных данных возможно путём задания значений параметров функционирования горелочного устройства в заранее известном диапазоне, соответствующем определённому режиму горения.

Цель предлагаемой работы — исследование способа автоматического определения режима горения по изображениям закрученного пламени на примере лабораторного газового горелочного устройства. Для определения режимов горения используется обучаемая на маркированных данных свёрточная нейронная сеть, а результат её работы сравнивается с результатами классификации с помощью нескольких линейных моделей.

Формирование набора исходных данных на лабораторном горелочном стенде. Сбор изображений пламени проводился на лабораторном газовом горелочном стенде, представляющем собой открытый контур, подключённый к баллонам с горючим газом и магистрали со сжатым воздухом. Для подачи воздуха и топлива использовалась откалиброванная система контроля расхода газа. Смешение топлива с окислителем происходило в длинной трубе, поток на выходе формировался осесимметричным сужающимся соплом с завихрителем. Степень закрутки потока варьировалась путём использования завихрителей с различным углом наклона лопаток. Более подробное описание стенда приводится в работе [9].

Число Рейнольдса струи, построенное по среднему расходу и вязкости воздуха, составляло 5000. Наборы изображений пламени регистрировались при заданной комбинации двух параметров, определявших «режим» горения: степени закрутки потока S и отношения топливо/воздух в смеси (коэффициента избытка топлива) Φ . Всего было зарегистрировано 13 различных режимов горения пропановоздушной смеси. Съёмка производилась цветной камерой с разрешением изображения 2 Мпикс. Для каждого режима регистрировалось порядка 10^4 изображений на тёмном фоне с одного ракурса. Примеры картин визуализации и параметры режимов горения (0–12) приводятся на рис. 1.

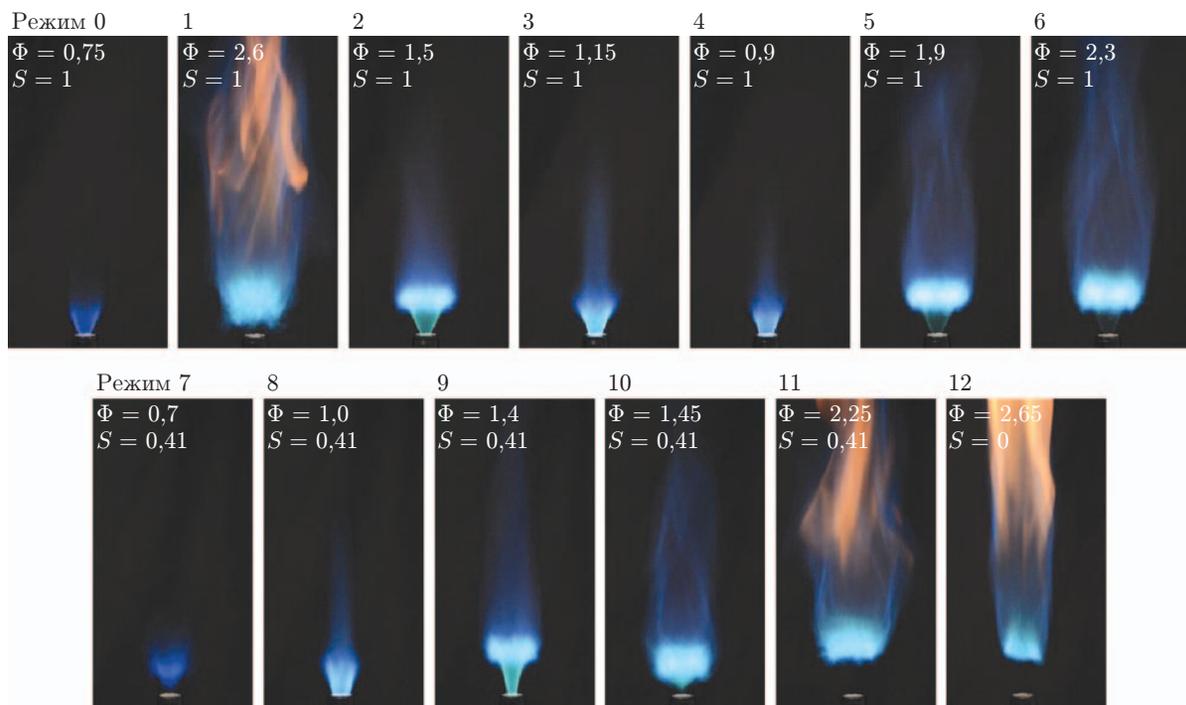


Рис. 1. Изображения пламени в различных режимах

Понижение размерности данных и линейные методы классификации. Алгоритмы предобработки данных, классификации и построения модели CNN осуществлялись на языке программирования Python с использованием библиотек NumPy, SciPy, Pandas, Scikit-Learn, OpenCV, Theano, Tensorflow и Keras. Для обработки данных применялись мультипроцессорные вычисления на одном компьютере (в составе вычислительного кластера на базе двух процессоров Intel Xeon E5 v2, 8 x DDR3 16GB).

Для получения базовой оценки качества решения задачи была реализована и протестирована группа линейных методов машинного обучения с разметкой и без неё. Использовались несколько линейных методов классификации: метод ближайших соседей (kNN — k -Nearest Neighbors), метод опорных векторов (SVM — Support Vector Machine) с линейной функцией ядра, метод логистической регрессии, а также основанные на кластеризации объектов методы обучения без разметки (метод k -средних (k -means) и агломеративная иерархическая кластеризация [6]). Многоклассовая классификация реализована методами SVM и логистической регрессии с применением стратегии "one-vs-all", которая заключается в обучении отдельного бинарного классификатора для каждого класса. Для указанных алгоритмов размерность данных предварительно понижалась путём разложения ансамбля векторных представлений изображений по методу главных компонент (PCA — Principal Component Analysis): первые 100 компонент разложения использовались в качестве входного вектора признаков для тестируемых алгоритмов и содержали более 95 % дисперсии входных данных. Количество компонент выбиралось эмпирическим путём, чтобы дальнейшее увеличение их числа не приводило к существенному изменению результатов кластеризации. Гиперпараметры линейных моделей классификации подбирались с применением процедуры стратифицированной кросс-валидации [6] по трём подвыборкам. Подбор гиперпараметров алгоритмов позволил повысить точность классификации на 1–3 %.

Полученные результаты продемонстрировали ряд выраженных проблем, присущих методам машинного обучения без разметки при решении задачи классификации. В качестве примера на рис. 2 показаны результаты классификации по 100 главным компонентам режимов методом k -средних. Представленная визуализация была выполнена с помощью ме-

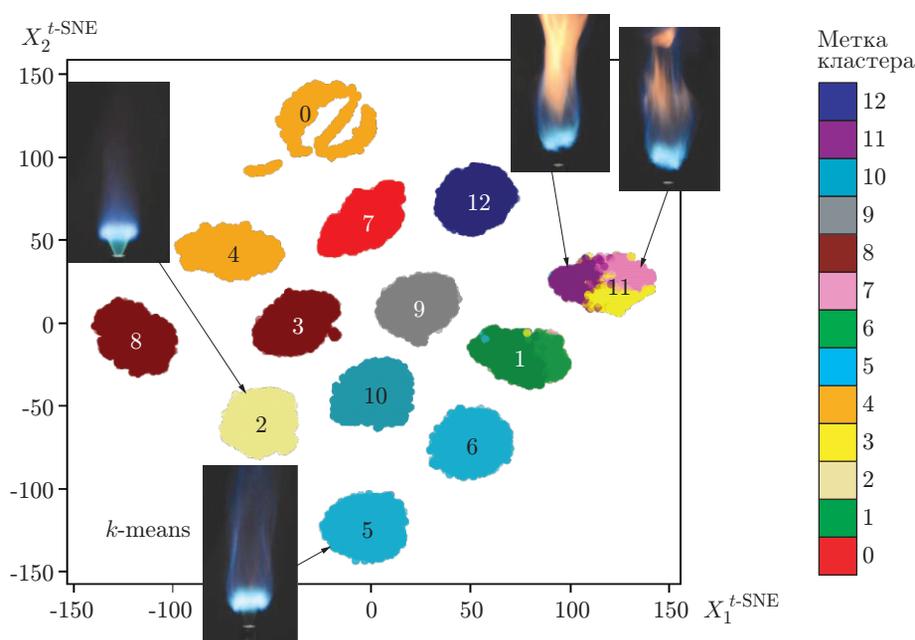


Рис. 2. Классификация изображений с помощью метода k -средних; визуализация методом t -SNE в пространстве пониженной размерности на 100 компонентах PCA

тогда визуализации многомерных переменных (t -SNE — t -Distributed Stochastic Neighbor Embedding) [10]. Метод t -SNE использовался для свёртки пространства 100 главных компонент до двухмерного пространства компонент t -SNE с максимальным сохранением исходной структуры данных. На рисунке номером облака точек обозначен соответствующий номер режима, а цветом точек — класс, присвоенный им алгоритмом. Видно, что алгоритм объединяет несколько разных, но визуально схожих режимов в один кластер, вместе с тем разбивая другие, более вариативные, режимы на несколько кластеров, что приводит к низкой точности классификации. Алгоритмы машинного обучения на размеченных данных показали более высокую точность классификации (на уровне 88–89 %) с небольшим (менее 1 %) стандартным отклонением при кросс-валидации на различных подвыборках (табл. 1). Малое стандартное отклонение свидетельствует об устойчивости алгоритма при классификации новых наборов данных. Отметим, что подбор иного, более релевантного, способа формирования вектора признаков может значительно улучшить результат. К примеру, для генерации вектора признаков из изображений возможно использование предобученной свёрточной нейронной сети (Inception, ResNet и др.).

Структура свёрточной нейронной сети. Нейронная сеть предназначена для решения задачи классификации изображений пламени, получаемых с видеопотока цифровой

Таблица 1

Точность линейных моделей

Модель классификации	Точность при кросс-валидации, %	Стандартное отклонение при кросс-валидации, %
Агломеративная кластеризация	27,91	1,55
Метод k -средних (k -means)	27,69	1,67
Метод опорных векторов (SVM)	89,13	0,507
Метод логистической регрессии	89,16	0,520
Метод ближайших соседей (kNN)	88,57	0,552

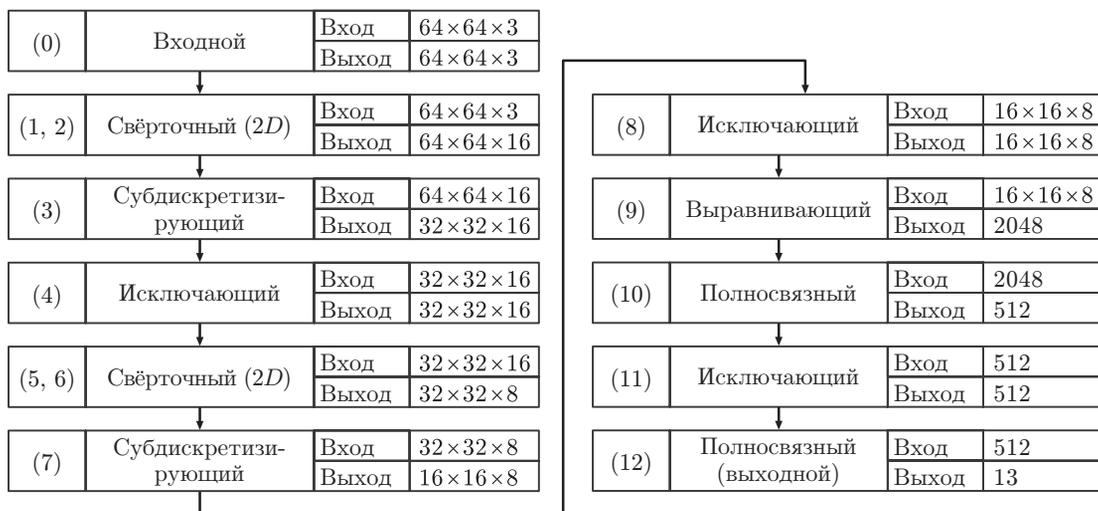


Рис. 3. Конфигурация свёрточной нейронной сети

камеры. Предложенный метод классификации основан на классической свёрточной нейронной сети (рис. 3), сочетающей свёрточные и субдискретизирующие слои. Архитектура CNN, т. е. используемые слои и их последовательность, была выбрана по аналогии с архитектурой сети AlexNet, продемонстрировавшей высокий результат в международном соревновании по классификации изображений ImageNet ILSVRC в 2012 году [11], при этом количество и размерность слоёв были уменьшены для достижения большей скорости работы, необходимой для классификации изображений из видеопотока в режиме on-line.

Данные в нейронной сети последовательно передаются от входного слоя к выходному. Сначала *RGB*-изображение проходит последовательно две свёрточные операции с ядром размером 3×3 . Аналогичная операция применяется после четвёртого слоя. Субдискретизирующие слои реализуют уплотнение карты признаков выбором максимального значения с ядром преобразования размером 3×3 и шагом 2. Исключающие слои являются регуляризирующими и предотвращают переобучение нейронной сети [12]. Выход последнего полносвязного слоя подаётся на завершающий слой Softmax, который вычисляет вероятность принадлежности изображения к классу. Для свёрточных и полносвязных слоёв сети использовалась функция активации «выпрямитель» ReLu [7], вычисление которой значительно менее ресурсоёмко, чем вычисление сигмоидальной функции или гиперболического тангенса.

В качестве функции потерь применялась кросс-энтропийная функция, а в роли метрики качества — доля правильных ответов. Дополнительными метриками являлись точность и полнота для каждого класса, характеризующие долю верных срабатываний в общем числе срабатываний и ложных пропусков алгоритма. Для оптимизации вектора весов нейронной сети использовался метод адаптивной инерции (Adam). Алгоритм Adam при поиске оптимума гораздо менее склонен «застревать» в локальных минимумах функции потерь и показывает наилучшие результаты при минимальном подборе параметров. Как и другие гиперпараметры, параметры Adam (скорость обучения и параметр изменения скорости обучения) подбирались методом кросс-валидации перебором по сетке параметров.

Оптимизация гиперпараметров и обучение свёрточной нейронной сети. Полная выборка использовавшихся изображений пламени состояла из 39000 маркированных *RGB*-изображений размером 1920×1080 пикселей — по 3000 изображений для каждого из 13 режимов. Выборка разбивалась на три непересекающихся подмножества: обучение 56 % изображений, валидация 14 % и тестовая выборка 30 %. При разбиении выборки, как

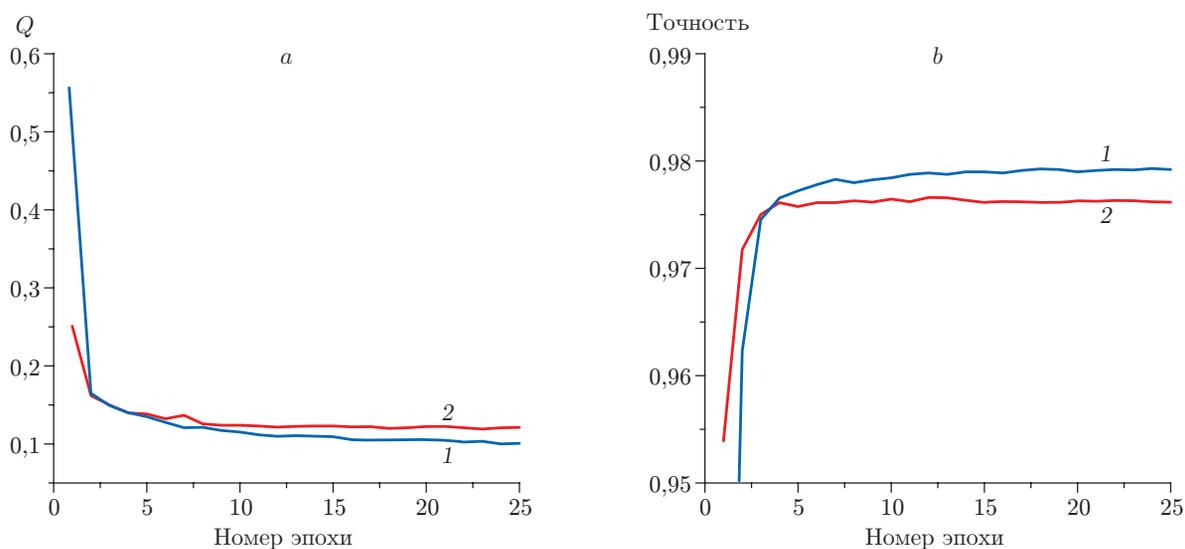


Рис. 4. Графики зависимости метрик качества от числа эпох: кросс-энтропийная функция потерь алгоритма (а) и точность модели (б) (кривые 1 — обучение, кривые 2 — валидация)

и для линейных методов, использовалось перемешивание с сохранением баланса классов в каждой подвыборке. Разрешение изображений понижалось до 64×64 RGB-пикселей для уменьшения времени обучения сети. Такой размер входных изображений выбран эмпирически исходя из компромисса между точностью классификации и временем обучения и прогноза модели.

Комбинация гиперпараметров модели подбиралась случайным перебором по сетке, при этом максимизировалась точность классификации на кросс-валидации, а финальная модель проверялась на отложенной выборке. В числе подбираемых гиперпараметров были: обучающие изображения, обрабатываемые за одну итерацию алгоритма градиентного спуска, итерации обучающего алгоритма по всему обучающему множеству, размер ядра и число ядер в свёрточных слоях, размер подвыборки в субдискретизирующих слоях, величина вероятности исключения нейрона в процедуре dropout и число нейронов в полносвязном слое. В результате подбора гиперпараметров нейронной сети точность классификации была повышена на 3,5 %. В наибольшей степени на качество классификации повлияли: размер свёрточного ядра, число ядер в каждом свёрточном слое, а также число нейронов в полносвязных слоях. Сходимость обучения сети при выбранных гиперпараметрах достигалась на 25 эпохах (рис. 4). Время обучения финальной модели составляло 24,2 мин, среднее время классификации одного изображения — 5,1 мс. Процедура подбора гиперпараметров заняла 40,8 часа.

Результаты применения нейросети для классификации изображений пламени. На рис. 5 показана матрица ошибок классификации для 13 классов, а в табл. 2 приводится метрика качества классификации изображений с помощью алгоритма CNN для отдельных режимов. Средняя по всем режимам точность классификации на отложенной выборке составила 97,9 %. Представленная матрица ошибок демонстрирует возникновение повышенной ошибки при классификации режимов 0, 7 и режимов 3, 4, 8, которые также классифицировались с ошибкой при применении линейных методов и, как видно из рис. 1, слабо различимы визуально. Тем не менее даже для этих режимов качество классификации с помощью CNN значительно превышает среднее качество классификации с использованием линейных методов, а для режимов с высокой вариативностью (1, 11, 12) предложенная модель демонстрирует уверенную классификацию с точностью до 99 %.

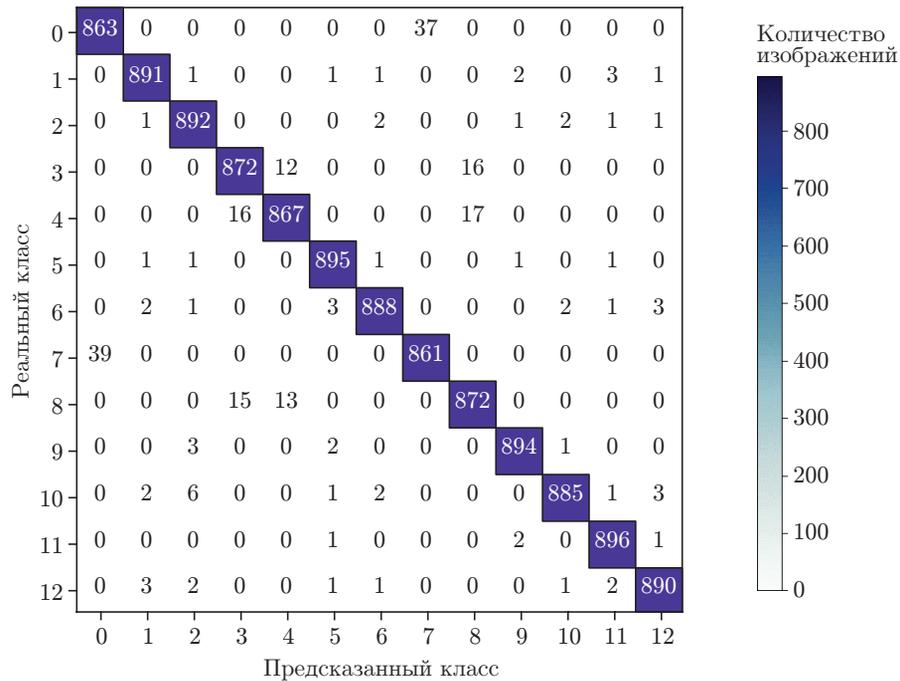


Рис. 5. Матрица ошибок классификации картин визуализации факела нейронной сетью

Таблица 2

Точность и полнота классификации по отдельным классам

Класс	Точность	Полнота
0	95,67	95,88
1	98,99	98,88
2	98,56	99,11
3	96,56	96,88
4	97,19	96,33
5	99,22	99,44
6	99,21	98,88
7	95,77	95,66
8	96,35	96,88
9	99,33	99,33
10	99,21	98,44
11	99,00	99,44
12	98,99	98,88

Заключение. Полученные результаты показывают, что использование предобученной на маркированных данных свёрточной нейронной сети позволяет с высокой (до 98 %) вероятностью правильно классифицировать режимы горения по изображениям факела. Точность нейронной сети значительно превышает точность линейных алгоритмов машинного обучения. Установлено, что алгоритмы, основанные на кластеризации объектов (без разметки), склонны объединять визуально схожие режимы в один кластер, разбивая другие, более вариативные, режимы на несколько кластеров, что значительно снижает точность классификации. Тем не менее результаты кластеризации изображений могут быть использованы в качестве предикторов в моделях следующего уровня. Полученная точность классификации нейронной сетью изображений с высокой вариативностью позволяет рассчитывать на эффективность метода в применении к прикладным задачам, таким как мониторинг работы угольных котлов.

Авторы выражают благодарность м. н. с. Д. К. Шараборину и м. н. с. А. С. Лобасову за предоставленные исходные данные.

СПИСОК ЛИТЕРАТУРЫ

1. Борзов С. М., Козик В. И., Потатуркин О. И., Шушков Н. Н. Оптимизация процесса горения газообразных углеводородов путем вариации состава топливной смеси // Теплофизика и аэромеханика. 2004. **11**, № 2. С. 309–315.
2. Анцыгин В. Д., Борзов С. М., Васьков С. Т. и др. Оптимизация процессов горения на основе анализа параметров пламени // Автометрия. 1999. № 5. С. 3–11.
3. González-Cencerrado A., Peña B., Gil A. Coal flame characterization by means of digital image processing in a semi-industrial scale PF swirl burner // Appl. Energy. 2012. **94**, Is. C. P. 375–384.
4. González-Cencerrado A., Peña B., Gil A. Experimental analysis of biomass co-firing flames in a pulverized fuel swirl burner using a CCD based visualization system // Fuel Process. Technol. 2015. **130**. P. 299–310.
5. Draper T. S., Zeltner D., Tree D. R. et al. Two-dimensional flame temperature and emissivity measurements of pulverized oxy-coal flames // Appl. Energy. 2012. **95**. P. 38–44.
6. Witten I., Frank E., Hall M., Pal C. Data Mining: Practical Machine Learning Tools and Techniques. San Francisco: Morgan Kaufmann, 2017. 654 p.
7. Hagan M. T., Demuth H. B., Beale M. H., de Jesus O. Neural Network Design. USA: Martin Hagan, 2014. 800 p.
8. Aghdam H., Heravi E. Guide to Convolutional Neural Networks. Springer, 2017. 282 p.
9. Alekseenko S. V., Dulin V. M., Kozorezov Y. S. et al. Flow structure of swirling turbulent propane flames // Flow, Turbulence and Combustion. 2011. **87**, N 4. P. 569–595.
10. Van der Maaten L. J. P., Hinton G. E. Visualizing high-dimensional data using t-SNE // Journ. Mach. Learning Res. 2008. **9**. P. 2579–2605.
11. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks // Proc. of the 25th Intern. Conf. on Neural Information Processing Systems. Nevada, USA, 03–06 Dec., 2012. P. 1097–1105.
12. Srivastava N., Hinton G., Krizhevsky A. et al. Dropout: A simple way to prevent neural networks from overfitting // Journ. Mach. Learning Res. 2014. **15**, N 1. P. 1929–1958.