

ГЕОИНФОРМАТИКА

УДК 522.122

КЛАССИФИКАЦИЯ СТРУКТУРЫ УГЛЯ ИЗ ОКОЛОРАЗРЫВНЫХ ЗОН С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ

М. Скиба, К. Годин, М. Млинарчук

*Институт исследований механики горных пород Польской академии наук,
E-mail: skiba@img-pan.krakow.pl, ул. Реймонта, 27, 30-059, г. Краков, Польша*

Проведено исследование применения искусственных нейронных сетей для определения структуры угля. Показано, что предлагаемая методика классификации может успешно использоваться в качестве инструмента принятия решений, связанных с описанием угля из околоразрывных зон. Эффективность методики подтверждается более чем 90 % случаев “правильного” определения структуры угля.

Структура угля, искусственная нейронная сеть, количественный анализ трещин, околоразрывная зона

DOI: 10.15372/FTPRPI20210517

Согласно данным [1 – 7], большинство выбросов породы и газа в каменноугольных шахтах происходят в областях тектонических нарушений. Залегающий в этих областях уголь имеет повреждения структуры и неустойчив из-за низкой компактности и высокой газоёмкости. В [8] отмечено, что корректно проведенное исследование микротрещин угля позволяет определить параметр, который может использоваться в процессе более точного выявления локальных угроз выброса породы и газа на определенных участках угольного пласта. Тем не менее данный метод требует дальнейшего развития при проведении значительного объема лабораторных измерений.

Трещины в угольном массиве представляли интерес для исследователей начиная с первой половины XX в. [9]. Наличие трещин ассоциировалось с возможным присутствием метана в угольном пласте, поэтому исследование данного вопроса развивалось достаточно активно. Изучение свойств каменного угля из разных месторождений и пластов на микро- и макроскопическом уровне показало, что структура угля почти всегда представляет собой сложную систему изломов, трещин и пор [10 – 12].

В 1969 г. немецкие исследователи [13] предложили классификацию таких углей, в которой выделили пять типов: структурно неизменный уголь; уголь с малым количеством трещин; уголь с большим количеством трещин; милонитный уголь и брикетный уголь. На ее основе чешские ученые провели исследование структуры угля, добытого из пластов в шахтах “Пасков” и “Старик”, и дали описание структурно измененного угля [14]. Данная классификация включала в себя следующие типы угля: компактный уголь с малым количеством трещин; компактный уголь с повышенным количеством трещин и уголь с плотной сетью трещин.

В [15 – 17] представлена классификация, выделяющая обычный уголь, который не разделен на меньшие куски, катаклазный уголь нестандартной формы, гранулированный уголь и милонитный уголь, т. е. уголь со значительными повреждениями структуры. В [18] детально описан каменный уголь из зон сдвига и определены два основных его типа: катаклазный и милонитный.

В [19, 20] дана классификация структур измененного угля из областей тектонических дислокаций угольных пластов Верхнесилезского каменноугольного бассейна. Она основана на детальном анализе образцов угля, собранных в зонах разрыва, и охватывает следующие типы: неизменный уголь; уголь с трещинами; прекатаклаз; мезокатаклаз; порфирукатаклаз; чистый катаклаз; премилонит и милонит.

Все классификации требуют тщательного определения указанных в них структур. Ввиду значительного разнообразия углей эта задача является сложной даже для петрографов с многолетним стажем. Исследователи отмечают существенное влияние фактора субъективности, возникающего при анализе. В этой связи стоит задача повышения объективности такого анализа [21, 22].

Первые работы, рассматривающие автоматизированные количественные измерения угля с высокой объективностью, включали методы анализа изображений [23 – 27]. Предлагаемая методика связана с применением корректной степени бинаризации для отделения изображения угля от изображения полимера, в который погружены зерна угля. Методы анализа изображений могут стать отправной точкой применения методов искусственного интеллекта, широко используемых в различных областях современной науки. Среди методов искусственного интеллекта присутствуют искусственные нейронные сети, в основе которых лежит функционирование человеческого мозга, выраженное в упрощенной математической модели. Искусственные нейронные сети стали широко применяться и продолжают развиваться за счет обнаружения новых областей их применения, в том числе в геологии и горном деле [28, 29].

Микроструктура угольного массива может обладать такими свойствами, как наличие в массиве трещин, катаклаза или милонита, благодаря чему увеличивается газоёмкость угля, представляющая потенциальную опасность при наличии газогеодинамики. Количественный анализ — основная задача корректного определения структуры измененного угля, которая осложняется его существенной неоднородностью. В связи с этим автоматизированные методы анализа могут рассматриваться в качестве альтернативы трудоемким ручным методам.

Цель настоящей работы — применение нейронных классификаторов и методов компьютерного анализа изображений для разработки автоматизированной, универсальной и надежной методики, позволяющей определять структурно измененные типы угля из околоразрывных зон на основе изображений, полученных с помощью микроскопа. Предполагается, что автоматизированная классификация рассматриваемых типов угля окажется корректной и позволит с достаточной точностью проводить описание их структуры.

МЕТОДЫ И МАТЕРИАЛЬНЫЕ ОБРАЗЦЫ

Материальные образцы углей для исследования получены из околоразрывных зон, расположенных в шахтах Верхнесилезского каменноугольного бассейна. В основе анализа лежит классификация структуры каменного угля из околоразрывных зон, предложенная в [12], с некоторыми изменениями из-за сложности получения двух исследуемых структур в достаточном для автоматизированной классификации количестве. В табл. 1 приведена классификация, использованная в настоящей работе и основанная на данных из [19].

ТАБЛИЦА 1. Классификация структур каменного угля из околоразрывных зон Верхнесилезского каменноугольного бассейна

Тип структуры угля		Характеристика структуры
Структурно неизменный уголь		Твердый уголь, отсутствие экзогенных трещин, возможное наличие эндомикротрещин, возникших при естественном процессе углефикации
Структурно измененный уголь	Уголь с трещинами	Сеть неравномерных трещин постдиагенной природы (экзомикротрещины)
	Прекатаклаз	Плотная сеть неравномерных трещин, общая структура отчетливо видна
	Мезокатаклаз	Очень плотная сеть неравномерных трещин, некоторые зерна разрушены и дислоцированы, общая структура частично размыта
	Катаклаз	Зерна угля разрушены и дислоцированы относительно друг друга. Общая структура полностью размыта
	Милонит	Почти полное отсутствие единичных зерен угля, сформированная новая трансформированная направленная структура с микроскладками и вторичными трещинами

Исходные изображения для анализа получены с помощью аншлифов угля в форме зерен и крупных кусков при 500-кратном увеличении в масляной среде. На изображениях каждой анализируемой структуры выделено 250 точек. Наблюдателем фиксировалось расположение точек и принадлежность структуры к одной из шести групп. В результате собран массив из 1500 точек с известной классификацией. В ходе автоматизированного анализа установлены участки, представляющие собой квадратные зоны с экспериментально определенным размером 151×151 пикселей. Выбор размера участков аналогичен процессу, описанному в исследовании классификации мацеральных групп и мацералов инертинитных групп [30–33]. На рис. 1 представлены образцы с выделенными зонами рассматриваемых структур.

Исследование начиналось с определения следующих параметров для каждой выделенной зоны исследования: средний уровень серого цвета изображения; среднее квадратическое отклонение уровня серого цвета изображения; средний уровень серого цвета поля градиентов изображения после морфологической обработки; среднее квадратическое отклонение уровня серого цвета поля градиентов изображения после морфологической обработки; энтропия изображения. Эти пять параметров определены для координаты L в цветовом пространстве

CIELab. Далее обнаружены границы трещин средствами алгоритма Канни. В этом случае исследователь получал изображения, в которых обнаруженные границы ограничивали пустоты, т. е. чем больше границ выявлено на изображении, тем больше трещин имеет структура угля и тем больше в нем пустот. Для описания полученных бинарных структур использовались изображение объема и число Эйлера. При этом определены семимерные векторы свойств, в дальнейшем используемые в качестве исходных параметров для применяемых нейронных классификаторов.

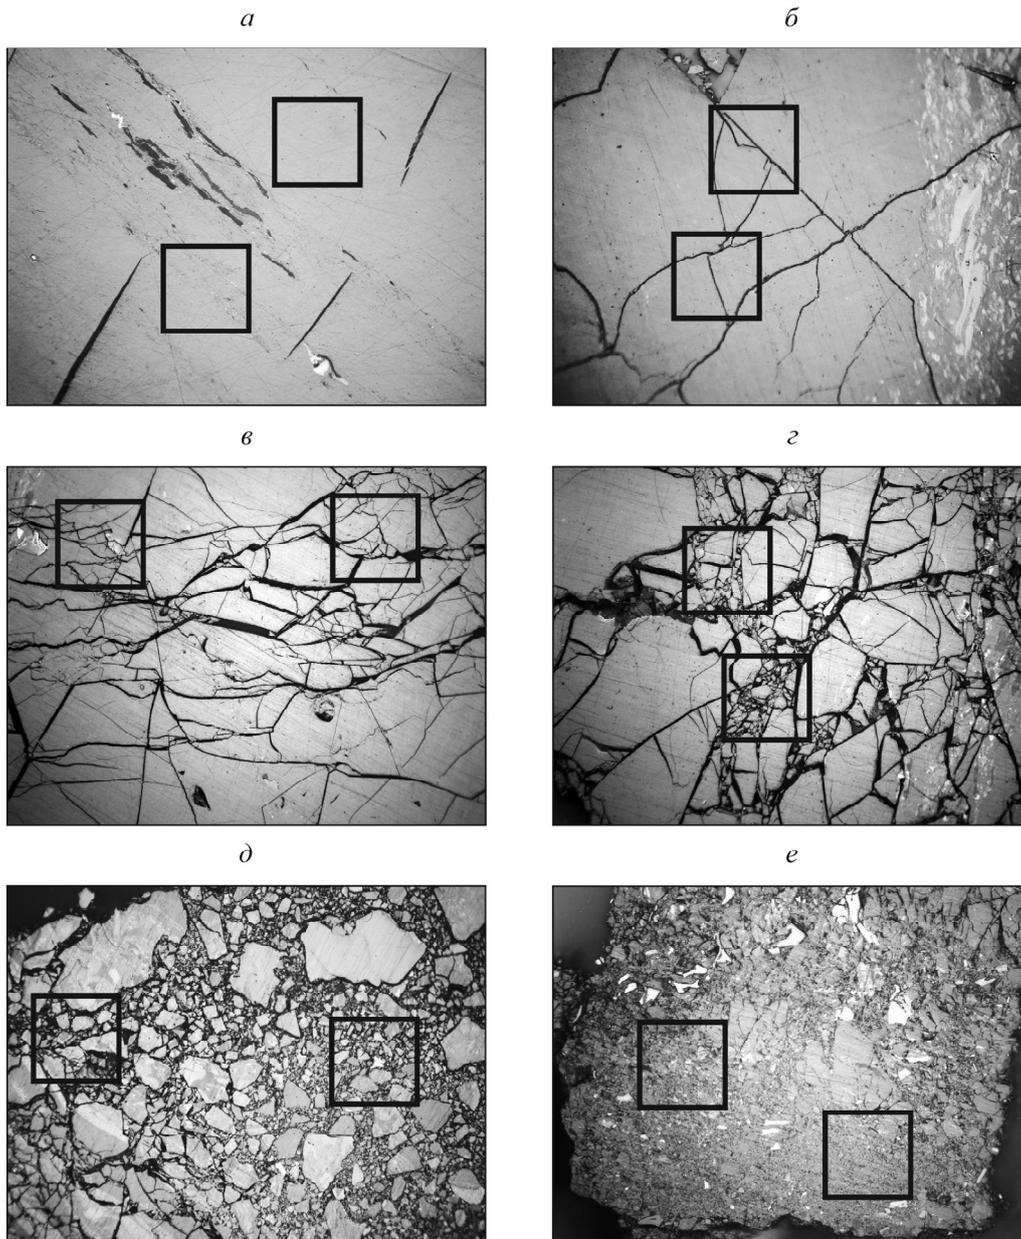


Рис. 1. Примеры выделения зон, содержащих рассматриваемые структуры угля: *a* — структурно неизменный уголь; *б* — уголь с трещинами; *в* — прекатаклаз; *г* — мезокатаклаз; *д* — катаклаз; *е* — милонит. Размер зон 151×151 пиксель, 500-кратное увеличение

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Классификация с помощью самоорганизующейся карты Кохонена [34]. Основная цель классификации структурно измененного угля с помощью самоорганизующейся карты Кохонена (рис. 2) — проверка классификации с целью установить, может ли описание структуры угля, выполненное наблюдателем, подтвердиться нейронной сетью, которая не обладает знаниями наблюдателя.

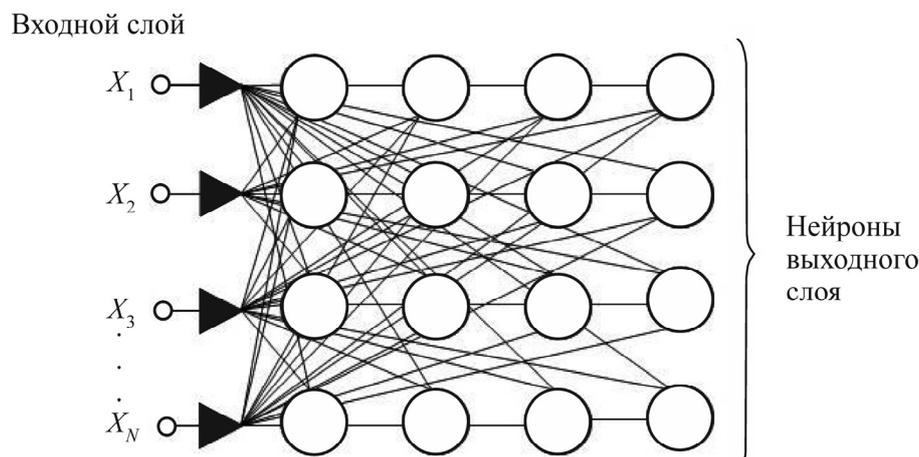


Рис. 2. Структура самоорганизующейся карты Кохонена (СОК)

В случае использования самоорганизующейся карты Кохонена набор данных для обучения включает только входные переменные, т. е. любая информация о том, какие значения ожидаются на выходе сети, отсутствует. На основе предложенных примеров нейронная сеть самостоятельно определяет их значимость и выявляет взаимосвязи, присутствующие в наборе данных. Нейронная сеть, созданная в процессе самообучения, также может использоваться для выявления особенностей массива данных, которые обычно пренебрегаются алгоритмами, созданными в ходе контролируемого обучения. Обученная нейронная сеть предлагает некую модель, содержащую информацию о структуре входящего в нее массива данных. Такая модель может применяться для классификации и упорядочивания данных, отсутствующих в сети, в течение процесса обучения. В данном типе нейронной сети каждый входной параметр будет предписан к одному из типов, определенных в ходе процесса самообучения [35, 36].

В настоящем исследовании применялся семимерный входной вектор [37]. Ввиду того, что использован алгоритм самостоятельного обучения СОК-сети, в выходном слое используется большее количество нейронов по сравнению с количеством рассматриваемых типов. После ряда опытов с разными размерами сети получен наиболее оптимальный размер (6×6). На основе частоты “выигрышей” каждого из 36 нейронов отдельные нейроны предписаны к одному из шести типов, так как информация отдельного элемента обучающего массива данных активирует соответствующий нейрон. Таким образом, получено распределение анализируемых объектов по типам на карте (рис. 3). Видно, что нейроны, соответствующие четырем анализируемым структурным типам угля, составляют компактные кластеры. Следует учесть, что в центральной части карты, соответствующей прекатаклазу и мезокатаклазу, наблюдается смешение объектов упомянутых классов, т. е. при заданных входных параметрах они определены нейронной сетью “некорректно”. Также можно установить сходство структуры одного рассматриваемого угля с другим при их близком расположении на топологической карте.

4	4	5	5	5	5
3	3	4	3	5	5
2	3	4	4	4	6
1	2	2	3	3	6
1	2	2	2	4	6
1	1	2	2	6	6

Рис. 3. Распределение отдельных типов структуры угля на топологической карте: 1 — структурно неизменный уголь; 2 — уголь с трещинами; 3 — прекатаклаз; 4 — мезокатаклаз; 5 — катаклаз; 6 — милонит

В табл. 2 представлены результаты классификации отдельных структур. Наибольшая точность (свыше 97 %) соответствует структурно неизменному углю. Уголь с трещинами имеет несколько меньшую точность определения (~94 %). Наименьшая точность определения соответствует прекатаклазу и мезокатаклазу (73 и 61 % “правильного” определения соответственно). Это подтверждается и схемой распределения отдельных структурных типов. Из табл. 2 видно, что использованные параметры, характеризующие анализируемые типы, отражают похожие друг на друга структуры (они активируют соседние нейроны). Основные ошибки анализа — “некорректное” определение прекатаклаза как мезокатаклаза и наоборот, мезокатаклаза как прекатаклаза.

ТАБЛИЦА 2. Результаты классификации рассматриваемых структур с помощью СОК-сети Кохонена, %

Параметр	Тип 1	Тип 2	Тип 3	Тип 4	Тип 5	Тип 6
Точность	97.5	93.7	72.5	61.0	83.6	86.5
Средняя точность	82.50					
Среднеквадратическое отклонение	1.72					

Примечание. Тип 1 — структурно неизменный уголь, 2 — уголь с трещинами, 3 — прекатаклаз, 4 — мезокатаклаз, 5 — катаклаз, 6 — милонит.

Классификация с помощью нейронной сети со структурой многослойного перцептрона. После подтверждения описательной классификации, принятой в настоящей работе, последняя использована в исследовании на основе нейронной сети со структурой многослойного перцептрона (MLP-сеть) в режиме контролируемого обучения. Сначала определялся оптимальный размер скрытого слоя сети в соответствии с поставленной задачей классификации измененных структур угля. Выходной слой сети состоит из шести нейронов, соответствующих рассматриваемым типам структуры. На основании предыдущих опытов в скрытом слое использована гиперболическая тангенциальная функция активации, тогда как в выходном слое — линейная функция. Для обучения сети применен алгоритм ошибки обратного распространения Левенберга–Марквардта [38]. Обучение сети осуществлялось на основе набора данных, состоящего

из 180 элементов, выбранных случайно из каждого типа. В результате получен обучающий массив данных из 1080 пар входящих параметров сети и соответствующих выходных значений. Оставшиеся участки наблюдения (70 для каждого типа) использованы для оценки функционирования предлагаемой нейронной модели путем создания двух равных наборов данных (проверочного и контрольного). Предполагалось, что результаты будут отвечать среднему процентному значению “правильно” классифицированных образцов после 100 повторений в режиме обучения с соответствующим массивом данных. Сеть с 11 нейронами в скрытом слое принята оптимальной для рассматриваемой задачи классификации. Предлагаемая модель характеризуется наивысшей точностью с долей “правильных” определений на уровне 87.5 % и наибольшей устойчивостью среди всех сетей.

В табл. 3 представлена точность классификации для рассматриваемых шести структур угля. Результат — среднее значение правильно классифицированных образцов после ста повторений в режиме обучения. Основные ошибки предлагаемой методики заключаются в “некорректной” классификации прекатаклаза и мезокатаклаза. Здесь точность классификации структуры является наименьшей и находится на уровне 74 и 70 % соответственно.

ТАБЛИЦА 3. Результаты классификации рассматриваемых структур с помощью MLP-сети, %

	Тип 1	Тип 2	Тип 3	Тип 4	Тип 5	Тип 6
Тип 1	97.6	0.9	0.0	0.0	0.0	1.2
Тип 2	0.0	93.1	6.5	0.8	0.0	0.0
Тип 3	0.0	6.0	74.1	20.8	0.0	1.2
Тип 4	0.0	0.0	19.0	70.4	3.8	0.8
Тип 5	0.0	0.0	0.4	7.6	94.6	1.6
Тип 6	2.4	0.0	0.0	0.4	1.6	95.2

Обозначение типов см. табл. 2.

Полученные ошибки могут возникать из-за схожести структур прекатаклаза и мезокатаклаза, что также подтверждается самоорганизующейся сетью, поэтому параметры, характеризующие вектор свойств, могут привести к множественному “некорректному” определению рассматриваемых типов структур. Другие типы структуры разработанной нейронной сетью определялись “корректно”. Наибольшая точность с долей “правильного” определения более 97 % принадлежит неизменному углю, тогда как точность остальных трех типов составляет 93 – 95 %.

Классификация с помощью группы сетей со структурой многослойного перцептрона. Проверка решения рассматриваемой задачи проводилась с помощью группы MLP-сетей с единичным выходным значением в каждой сети. Предыдущий опыт классификации мацералов из инертинитной группы показал, что здесь возможно получить более точные результаты по сравнению с одиночной сетью с несколькими выходными параметрами по числу классифицируемых типов [31]. Выполненный анализ включает использование алгоритма на основе группы из шести MLP-сетей, каждая из которых определяет только один тип структуры угля. На рис. 4 приведена концептуальная схема предлагаемого решения.

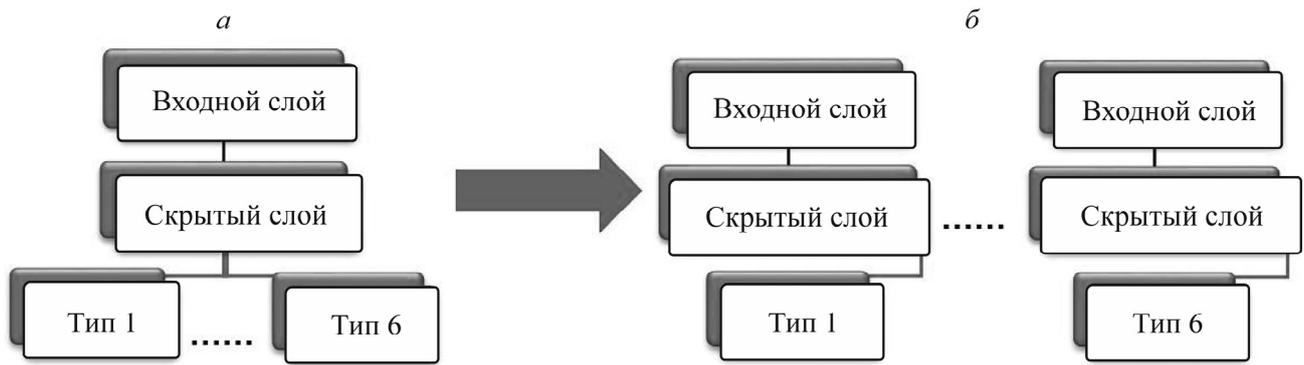


Рис. 4. MLP-сеть с шестью выходами (а) и использование группы из шести MLP-сетей с единичным выходом в каждой (б)

Во входном слое каждой сети, так же как и в случае с классификацией с помощью СОК-сети и MLP-сети, использован семимерный вектор свойств, тогда как в скрытом слое использовано пять гиперболических тангенциальных нейронов. Выходной слой сети состоит из одного линейного нейрона, каждый раз разделяющего данные на две категории: одна охватывает данные из исследуемого типа, другая — данные, соответствующие оставшимся типам. Затем исследуемый объект предписывается в заданный тип на основе значения функции решения, т. е. к типу с наибольшим значением функции решения. Результаты классификации после ста повторений в режиме обучения представлены на рис. 5.

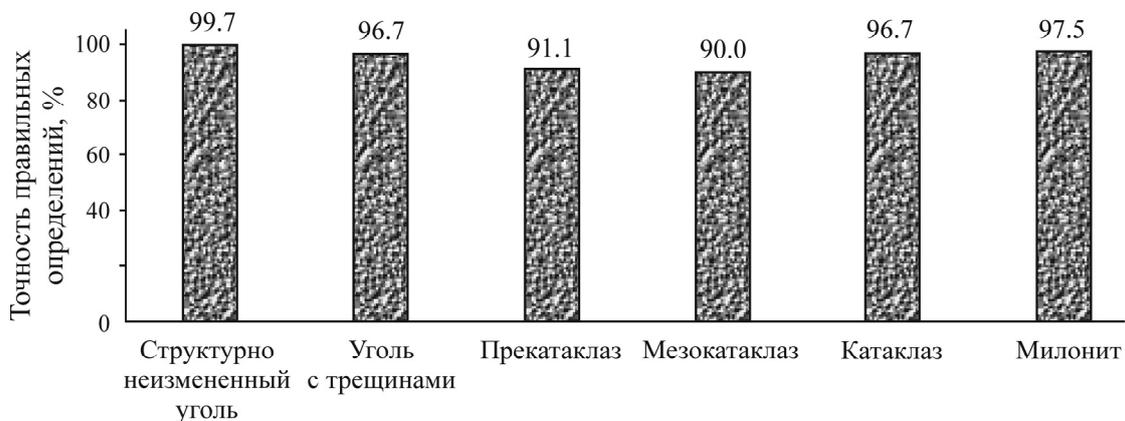


Рис. 5. Результаты классификации рассматриваемых структур с помощью группы из шести MLP-сетей

Использование группы MLP-сетей с единичными выходными слоями значительно повысило точность классификации рассматриваемых структур по сравнению с полученными ранее результатами. Проведенный анализ показал среднюю точность определения на уровне, превышающем 95 %, с наилучшим результатом 97 % “правильно” классифицированных изображений. Наивысшая точность определения составила почти 100 % для структуры неизменного угля. Отметим, что даже в случае с прекатаклазом и мезокатаклазом, чье определение ранее сопровождалось значительной ошибкой, полученные результаты продемонстрировали точность 91 и 90 % “правильных” классификаций.

ВЫВОДЫ

Показана высокая точность результатов применения нейронных сетей для классификации структурно измененного угля. Наиболее точные результаты (в среднем 95 %) получены с помощью алгоритма на основе группы MLP-сетей. При этом наивысшая точность (около 100 %) отмечена для структуры неизмененного угля.

При использовании самоорганизующейся карты получена меньшая точность (в среднем 82.5 %). “Правильно” определенными при этом оказались структура неизмененного угля и угля с трещинами (более 93 % “правильных” определений). Наименьшая точность соответствует структурам прекатаклаза и мезокатаклаза.

Нейронные сети, обученные в контролируемом режиме, могут эффективно использоваться в качестве объективного инструмента обоснования принимаемых решений в области геологии при описании структур угля в околоразрывных зонах.

СПИСОК ЛИТЕРАТУРЫ

1. **Shepherd J., Rixon L. K., and Creasey J. W.** Analysis and prediction of geological structures associated with outbursts at Collinsville, Queensland. The Occurrence, Prediction and Control of Outbursts in Coal Mines Symp., Australian Institute of Min. and Metallurgy. Parkville, Victoria, Australia, 1980. — P. 159–171.
2. **Beamish B. and Crosdale P. J.** Instantaneous outbursts in underground coal mines: An overview and association with coal type, *Int. J. Coal Geol.*, 1998, Vol. 35. — P. 27–55.
3. **Cao Y., Mitchell G. D., Davis A., and Wang D.** Deformation metamorphism of bituminous and anthracite coals from China, *Int. J. Coal Geol.*, 2000, Vol. 43. — P. 227–242.
4. **Li H., Ogawa Y., and Shimada S.** Mechanism of methane flow through sheared coals and its role on methane recovery, *Fuel*, 2003, Vol. 82. — P. 1271–1279.
5. **Skoczylas N.** Laboratory study of the phenomenon of methane and coal outburst, *Int. J. Rock Mech. Min. Sci.*, 2012, Vol. 55. — P. 102–107.
6. **Oparin V. N., Kiryaeva T. A., and Potapov V. P.** Methods and models for analyzing methane sorption capacity of coal based on its physicochemical characteristics, *J. Min. Sci.*, 2017, Vol. 53, No. 4. — P. 614–629.
7. **Kudasik M., Skoczylas N., and Pajdak A.** The repeatability of sorption processes occurring in the coal-methane system during multiple measurement series, *Energies*, 2017, Vol. 10, No. 5. — 661 p.
8. **Lama R. D. and Bodziony J.** Management of outburst in underground coal mines, *Int. J. Coal Geol.*, 1998, Vol. 35. — P. 83–115.
9. **Kendall P. E. and Briggs H.** The formation of rock joints and the cleat of coal, *Proc. R. Soc. Edinburgh*, 1933, Vol. 53. — P. 164–187.
10. **Barker-Read G. R.** The geology and related aspects of coal and gas outbursts in the Gwendraeth valley, MSc Thesis. Univ. Wales, Cardiff, 1980.
11. **Lama R. D. and Bodziony J.** Outburst of gas, coal and rock in underground coal mines, R. D. Lama and Associates, Wollongong, NSW Australia, 1996.
12. **Shadrin A. V.** Geophysical criterion of pre-outburst crack propagation in coal beds, *J. Min. Sci.*, 2016, Vol. 52, No. 4. — P. 670–682.
13. **Jüntgen H. and van Heek K. H.** *Brennstoff-Chemie*, 1969, Vol. 50. — P. 172.

14. **Rakowski Z., Kraussová J., and Beneš K.** Studium změn textury a struktury uhlí ve slojích náchylných k průtřím uhlí a plynů v dolech Paskov a Staříč v OKR, Sborník vědeckých prací Vysoké školy báňské v Ostravě, Řada Hornicko-Geologická, 1977, Vol. 23, No. 1. — P. 1–29.
15. **Cao Y., Mitchell G. D., Davis A., and Wang D.** Deformation metamorphism of bituminous and anthracite coals from China, *Int. J. Coal Geol.*, 2000, Vol. 43. — P. 227–242.
16. **Cao Y. X., He D., and David G. C.** Coal and gas outbursts in footwalls of reverse faults, *Int. J. Coal Geol.*, 2001, Vol. 48. — P. 47–63.
17. **Cao Y., Davis A., Liu R., Liu X., and Zhang Y.** The influence of tectonic deformation on some geochemical properties of coals — a possible indicator of outburst potential, *Int. J. Coal Geol.*, 2003, Vol. 53. — P. 69–79.
18. **Jiang B., Ju Y., and Quin Y.** Textures of tectonic coals and their porosity, *Min. and Sci. Technol.*, Taylor and Group, London, 2004.
19. **Godyń K.** Structurally altered hard coal in the areas of tectonic disturbances — an initial attempt at classification, *Arch. Min. Sci.*, 2016, Vol. 61, No. 3. — P. 677–694.
20. **Godyń K. and Kožušnicková A.** Microhardness of coal from near-fault zones in coal seams threatened with gas-geodynamic phenomena, Upper Silesian Coal Basin, Poland, *Energies*, 2019, Vol 12, No. 9. — P. 1756.
21. **Bodziony J., Gabzdyl W., and Ratajczak T.** Evaluation of effect of a subjective factor on the results of stereological analysis of coal, *Arch. Min. Sci.*, 1986, Vol. 31. — P. 689–702.
22. **Skiba M.** The influence of the discrepancies in the observers' decisions on the process of identification of maceral groups using artificial neural networks, *J. Sustainable Min.*, 2016, Vol. 15. — P. 151–155.
23. **England B. A., Mikka R. A., and Knott A. C.** The characterisation of coal by automated petrographic analysis, *NERDDC research report BHPCL*, 1981.
24. **Choa E. C. T., Minkin J. A., and Thompson C. L.** Application of automated image analysis to coal petrography, *Int. J. Coal Geol.*, 1982, Vol. 2. — P. 113–150.
25. **Pratt K.** The use of composite and mosaic imaging of polished surfaces to enhance petrographic analysis of coal by image analysis, *Org Geochem*, 1993, Vol. 20. — P. 759–768.
26. **Cloke M., Lester E., Allen M., and Miles N. J.** Repeatability of maceral analysis using image analysis systems, *Fuel*, 1995, Vol. 74, No. 5. — P. 654–658.
27. **O'Brien G., Jenkins B., Esterle J., and Beath H.** Coal characterisation by automated coal petrography, *Fuel*, 2003, Vol. 82. — P. 1067–1073.
28. **Tadeusiewicz R.** Neural networks in Mining sciences — general overview and some representative examples, *Arch. Min. Sci.*, 2015, Vol. 60, No. 4. — P. 971–984.
29. **Bychkov I. V., Vladimirov D. Ya., Oparin V. N., Potapov V. P., and Shokin Yu. I.** Mining information science and big data concept for integrated safety monitoring in subsoil management, *J. Min. Sci.*, 2016, Vol. 52, No. 6. — P. 1195–1209.
30. **Młynarczuk M., Godyń K., and Skiba M.** The application of artificial neural networks for the classification of altered structures of hard coal in near-fault zones, *Przegląd Górniczy*, 2015, Vol. 11. — P. 15–20 (in polish).
31. **Młynarczuk M. and Skiba M.** The application of artificial intelligence for the identification of the maceral groups and mineral components of coal, *Comput. Geosci.*, 2017, Vol. 103. — P. 133–141.
32. **Skiba M. and Młynarczuk M.** Identification of macerals of the inertinite group using neural classifiers, based on selected textural features, *Arch. Min. Sci.*, 2018, Vol. 63, No. 4. — P. 827–837.

33. **Skiba M.** Investigating structural and petrographic properties of coal in the aspect of methane hazard using methods of image analysis and artificial neural networks, PhD thesis, Strata Mechanics Research Institute of the Polish Academy of Sciences, Cracow, 2018 (in polish).
34. **Kohonen T.** Self-organizing maps, Springer-Verlag, Berlin, 1995.
35. **Tadeusiewicz R.** Sieci neuronowe, Akademicka Oficyna Wydawnicza, Warszawa, 1993.
36. **Tadeusiewicz R., Chaki R., and Chaki N.** Exploring neural networks with C#, CRC Press, Taylor and Francis Group, Boca Raton, 2014.
37. **Skiba M. and Mlynarczuk M.** The application of self-organizing map to the classification of altered structures of coal, Transactions of the Strata Mechanics Research Institute, 2016, Vol. 18, No. 3. — P. 61 – 66 (in polish).
38. **Hagan M. T. and Menhaj M. B.** Training feedforward networks with the Marquardt algorithm, IEEE Trans. Neural Net., 1994, Vol. 5, No. 6. — P. 989 – 993.

Поступила в редакцию 11/VI 2021

После доработки 20/VII 2021

Принята к публикации 10/IX 2021