

РАСПОЗНАВАНИЕ КЛАССОВ ПОДЗЕМНЫХ АВАРИЙ В УГОЛЬНЫХ ШАХТАХ НА ОСНОВЕ НЕЙРОСЕТЕВОЙ ТЕХНОЛОГИИ

В.В. Куприянов

НИТУ «МИСиС», Москва, Россия, e-mail: Kupriyanov.VV@misis.ru

Аннотация: Изучено принятие диспетчерским персоналом (ДП) оперативных решений по обеспечению безопасности в угольных шахтах при авариях. Рассмотрен комплекс вопросов, связанных с распознаванием подземных аварий на основе обучающей модели нечеткой нейронной сети (НС). Предложен алгоритм нечеткой нейросетевой классификации нештатных ситуаций (НшС) в угольных шахтах. Отнесение обучающего образа НшС к существующему или новому кластеру базируется на концепции максимального сходства. Мы определяем функцию, называемую степенью различия, для представления различия между обучающим образом НшС и кластером в нейронной сети, как Евклидово расстояние. Эта функция отображает два вектора (обучающий образ НшС и кластер) как действительное число. Образы каждого кластера (средние значения образов НшС в кластере) запоминаются в линиях связи (весах) нейронной сети в течение процесса классификации. Показана возможность применения алгоритма классификации в условиях, когда классы аварий частично перекрываются. Если классифицированные кластеры частично перекрываются, каждый образ НшС в обучающем множестве может принадлежать более чем одному кластеру. Бинарная матрица служит для записи каждого образа НшС кластера. Алгоритм, основанный на гипотезе, что существует модель для каждого кластера, определяемая как среднее значение моделей всех образов НшС в этом кластере, используется для оценки функции принадлежности. Степень принадлежности каждого образа НшС в кластере определяется исходя из того, насколько похож этот образ на модель кластера. Сходство может быть установлено как функция Евклидова расстояния между образом и моделью кластера. Используется треугольная функция принадлежности для выражения степени принадлежности в нечетком множестве. Эта функция является простой для математической манипуляции и адекватной предметной области. Было применено конкурирующее обучение. В этом случае процесс обучения корректирует весовой вектор, связанный с входными и выходными узлами нейронной сети. Обучающая модель была применена для области распознавания количества существующих классов типичных аварий, формирования моделей этих классов, классификации НшС в угольных шахтах. Качество функционирования этой модели было оценено ее применением на обучающем наборе с большим числом обучающих образов. Обучающая модель является основной, и может быть применена для решения крупномасштабных проблем распознавания взаимодействия НшС, причин и условий появления аварий. Сформулирована идея такого распознавания.

Ключевые слова: авария, угольная шахта, нештатная ситуация, нейронная сеть, кластер, алгоритм, нечеткая классификация, обучающая модель, функция принадлежности, раскрытие нечеткости.

Для цитирования: Куприянов В. В. Распознавание классов подземных аварий в угольных шахтах на основе нейросетевой технологии // Горный информационно-аналитический бюллетень. – 2022. – № 8. – С. 148–157. DOI: 10.25018/0236_1493_2022_8_0_148.

Identification of accident classes in coal mines using the neural network technology

V.V. Kupriyanov

National University of Science and Technology «MISiS», Moscow, Russia,
e-mail: Kupriyanov.VV@misis.ru

Abstract: The article addresses prompt decision-making on coal mine safety in case of accidents by the dispatching personnel. The discussion deals with issues connected with identification of underground accidents using the learning model of fuzzy neural network. The algorithm of fuzzy neural network classification of off-optimum situations (OOS) in coal mines is proposed. Belonging of the learning image of OOS to the existing or a new cluster is determined from the maximum similarity concept. The function of difference between the learning image of OOS and the cluster in the neural network is defined as the Euclidean distance. This function displays two vectors (the learning image of OOS and the cluster) as a real number. Images of each cluster (average values of OOS images in a cluster) are stored in the communication links (weights) of the neural network during the whole process of classification. Application of the classification algorithm in the conditions of partly overlapped classes of accidents is illustrated. If classified clusters are partly overlapped, each image of OOS in the learning family may belong to more than one cluster. Binary matrix serves for recording each image of OOS in a cluster. The algorithm based on a hypothesis that there exists a model for each cluster, which is determined as an average value of models of all images of OOS in this cluster, is used to determine the membership function. Membership of each image of OOS in a cluster is determined from similarity of this image to the cluster model. The similarity can be found as the function of the Euclidean distance between the image and the cluster model. This article uses the triangle membership function in fuzzy set. This function is simple for the mathematical manipulation in equivalent application domain. The competitive learning was applied. In this case, the learning processes is corrected by the weight factor connected with the input and output nodes of neural network. The learning model was applied to identification of existing classes of standard accidents, to modeling these classes and to classification of OOS in coal mines. The quality of this model performance was estimated using a learning set composed of many learning images. The learning model is the base model, and is applicable to dealing with large-scale problems connected with identification of OOS, as well as causes and initiation conditions of accidents. The idea of such identification is formulated.

Key words: accident, coal mine, off-optimum situation, neural network, cluster, algorithm, fuzzy classification, learning model, membership function, fuzziness identity.

For citation: Kupriyanov V. V. Identification of accident classes in coal mines using the neural network technology. *MIAB. Mining Inf. Anal. Bull.* 2022;(8):148-157. [In Russ]. DOI: 10.25018/0236_1493_2022_8_0_148.

Введение

Возникающие изменения геофизических и горно-технологических факторов, состояния горно-шахтного оборудова-

ния, существенные колебания газодинамических процессов в различных выработках шахт от смены к смене, сложные горно-геологические условия приводят к

различным видам аварий [1 – 5]. Основным направлением повышения безопасности ведения подземных горных работ является создание автоматизированных систем мониторинга (АСМ) шахтных параметров, способных в рамках единой аналитической платформы оказывать поддержку ДП в распознавании НшС как причин аварий и получать ответы на целый ряд вопросов, касающихся характеристики НшС (тип, наложение, взаимодействие НшС), правомерности принятия ДП решений при выработке плана ликвидации аварий в сложившейся ситуации и т.д. Важным для АСМ является разработка алгоритмов классификации НшС с формированием моделей типичных аварий на основе методов интеллектуального анализа данных.

Сегодня сложились определенные технические и информационно-технологические условия, позволяющие применить нейросетевые алгоритмы, которые обеспечивают необходимую точность распознавания НшС, приводящих к авариям. Класс моделей НС имеет множество архитектур (сети радиально-базисных функций, многослойный перцептрон, сети обратного распространения, сеть Хопфилда, сверточные сети и др.) с разным принципом работы и, соответственно, своей оценкой эффективности. Деятельность ДП при распознавании аварий предполагает анализ больших накопленных данных и имеет индивидуальные особенности, а значит, универсальной модели не существует, тем более выбора архитектуры НС. Этот выбор зависит от решения задачи классификации НшС и используемой обучающей модели НС.

Теория вопроса

Задача распознавания аварий интерпретируется как отнесение НшС к тому или иному классу аварий. Идея формализации этой задачи сводится к анализу

информации о НшС и сопоставлению ее с некоторыми моделями классов аварий: если мера несоответствия реальных и модельных результатов не превышает некоторого порога, задача считается решенной. Мерой несоответствия или уверенности, что авария может быть распознана, может служить функция расстояния в той или иной метрике. Анализ отображений множества НшС на множество классов аварий позволил обосновать выбор алгоритма, который соответствует решаемой задаче. Этот алгоритм определен как самообучение НС.

Класс аварий – это группировка по множеству НшС, полученная методами кластеризации на основе критерия максимального сходства или разрешенности, согласно которому НшС внутри класса более «похожи» друг на друга, чем НшС из разных классов. Эти классы аварий составляют множество $C = U_{c_i}, i = 1, \bar{P}$ – индекс класса (типа) аварий. С учетом используемых способов описания НшС в пространстве лингвистических признаков удобной представляется геометрическая трактовка близости между НшС, в рамках которой расстояние между НшС вычисляется согласно выбранной метрике. Формирование образов типичных ситуаций осуществляется путем классификации выборки НшС $\{x_{nj}\}$, n – номер ситуации; j – индекс параметра.

Сложность решения задач нелинейной классификации и распознавания образов в рамках классических подходов, предполагающих определение (P) ситуаций X_p , наиболее удаленных друг от друга, и отнесение к классам C_p наиболее близких к X_p НшС, сопряжена с необходимостью полного перебора и проверки всех возможных комбинаций суммарных расстояний между ситуациями в пространстве параметров. А это при значительном количестве НшС требует громадного объема базы знаний и слож-

ной итерационной процедуры поиска. Кроме того, здесь параллельно решается задача распознавания количества существующих классов аварий. Известные для этой цели процедуры ориентированы на одномерный случай (ситуация с одним параметром) [6]. При переходе на многомерную ситуацию классификация становится неадекватной из-за «наложения» классов аварий (одна и та же НшС может принадлежать разным классам аварий). Дополнительные ограничения связаны с неизвестностью в нашем случае «идеальных» выходных образов НС (возможно задание лишь входных обучающих образов).

Алгоритмы обучения НС исследовались в разных предметных областях [7–16] и формировались при заранее заданных входных и выходных обучающих образах, сочетая сравнительно небольшое число параметров. Одним из подходов к решению этой проблемы является использование конкурирующего обучения, когда выходные нейроузлы конкурируют между собой за «право» стать активными при первоначальном вводе в сеть обучающих образов поодиночке и вычислении выходных образов для каждого образа, а весовые коэффициенты в линиях связи (ЛС) изменяются; свойства разрешенности НшС по отношению к формируемым классам аварий и рекурсивного оценочного метода для коррекции весовых коэффициентов в ЛС [7, 16]. Этот подход реализуется в алгоритме нечеткой нейросетевой классификации НшС, который использует методы теории нечетких множеств [17, 18]. Выделены основные виды информации, необходимые для его построения и функционирования, а именно: оперативная сенсорная информация, получаемая при помощи мониторинговых систем, включая данные о физических параметрах горно-технологических процессов, о параметрах состояния техно-

логического оборудования; данные диспетчерского контроля и управления; информационные массивы фактографической информации, включая геологические и технологические информационные базы, содержащие основные параметры и рабочие характеристики горношахтного оборудования, схемы ведения горных работ.

Описание методов решения.

Обработка данных.

Обсуждение результатов

Рассматривалась следующая задача: $\{X_1, X_2, \dots, X_N\}$ – множество НшС с M обучающими образами в каждой из них, заданными на множестве параметров НшС, т.е. $X_i = [x_{i1}, \dots, x_{iM}]$, причем N заранее не определено и зависит от факта достаточности представительности выборки НшС для осуществления самообучения; формирование выборки завершается после ее фильтрации; $C = \{C_1, \dots, C_p\}$ – нечеткое множество выходных значений НС, соответствующих кластерам аварий, число которых определяется процессом классификации. Необходимо N НшС классифицировать в P однородных кластеров, в которых ситуации имеют одинаковый вес. Число входов НС равно числу образов M , а количество выходов равно числу кластеров, которые образуют нечеткое множество. Топология НС динамически самоорганизуется в течение этого процесса. В качестве инструмента для решения нашей задачи используется двухуровневая НС, отличающаяся от сетей обратного распространения и классической сети Кохонена возможностью изменения топологии и весовых коэффициентов в ЛС между нейроузлами. Образы НшС в каждом кластере запоминаются в ЛС. Вначале образуется сеть с M входами и одним выходом $\Phi(M, 1)$, и первая НшС после ее ввода принадлежит первому кластеру. Если вторая НшС относится к первому

кластеру, то выход НС, представляющий этот кластер, становится активным. В этом случае топология НС не изменяется, но изменяются веса в ЛС, используя рекурсивный метод, который учитывает в весах ЛС добавление $N+1$ -й НшС к множеству из N НшС через оценку среднего вектора из $N+1$ -ой НшС:

$$\overline{X_{N+1}} = \left(\frac{N}{N+1} \right) \overline{X_N} + \left(\frac{1}{N+1} \right) X_{N+1}. \quad (1)$$

Топология НС остается как $\Phi(M, 1)$. Если же вторая НшС классифицируется как новый кластер, то дополнительный выход добавляется к НС. Значения весовых коэффициентов при этом не меняются, но топология НС модифицируется как $\Phi(M, 2)$. Процесс завершается, когда все НшС классифицируются. Способ решения задачи учитывает специфику классифицируемых кластеров: разделенные или перекрывающиеся [2].

Нечеткая классификация осуществляется в три этапа. На первом этапе НшС классифицируются в активные или новые кластеры с помощью некоторой меры сходства образов НшС X и каждого кластера C_p в сети $\Phi(M, P)$ в виде $r_p(X, C_p)$ в Евклидовой метрике:

для активного кластера

$$C_{\text{ак}} = C_p \text{ при } \min r_p,$$

для нового кластера

$$C_{\text{нов}} = X, \text{ если } \min r_p > r_o,$$

где

$$r_p(X, C_p) = \left[\sum_{j=1}^M (x_j - c_{pj})^2 \right]^{\frac{1}{2}},$$

$p = 1, 2, \dots, P$ — индекс кластера аварий; r_o — допустимый предел близости X и C_p .

Для сети $\Phi(M, 1)$ устанавливается число элементов n_1 в первом кластере, равное 1, а число элементов в других кластерах n_2, \dots, n_N , равно 0. Множество весовых коэффициентов сети $\Phi(M, 1)$ равно вектору образов x_{1j} ($j = 1, 2, \dots, M$). Классифицированные кластеры могут

быть полностью разделены, т.е. каждая НшС в обучающем множестве может принадлежать только одному из кластеров, или частично перекрываться. В этом случае НшС может принадлежать более чем одному кластеру, а границы кластеров являются размытыми. Можно этот случай формализовать. Обозначим: n_j — количество НшС, находящихся полностью или частично в кластере j ; F_{ij} — бинарная матрица для записи каждой НшС, причем если i -я НшС принадлежит j -му кластеру, то $F_{ij} = 1$, иначе $F_{ij} = 0$. Тогда запишем:

$$\sum_{j=1}^P F_{ij} \geq 1, i = 1, 2, \dots, N;$$

$$\sum_{j=1}^P n_j \geq N; C_j \cap_{j \neq p} C_p \neq 0$$

Изменение весовых коэффициентов F_{ij} в ЛС согласно (1) осуществляется по правилу:

$$F_{sj} = \left(\frac{n_s}{n_s + 1} \right) \overline{F_{sj}} + \left(\frac{1}{n_s + 1} \right) x_{sj}, j = 1, 2, \dots, M, \quad (2)$$

где

$$\overline{F_{ij}} = \frac{1}{N} \sum_{i=1}^N F_{ij}, s = P + 1,$$


$\overline{F_{ij}}$ — средний вектор весовых коэффициентов для обучающих образов X_1, \dots, X_N .

После завершения классификации всех НшС модели образов каждого p -го кластера запоминаются в весовых коэффициентах ЛС НС в виде вектора средних значений всех ситуаций в p -м кластере (p -й типичной аварии):

$$C_p = [c_{p1}, \dots, c_{pM}] = \frac{1}{n_p} \sum_{i=1}^{n_p} X_i^p, \quad (3)$$

где n_p — представительность p -го кластера; $X_i^p = \{x_{1M}^p, \dots, x_{iM}^p\}$ — вектор образов параметров i -й НшС, отнесенной к p -му кластеру;

$$c_{pj} = \frac{1}{n_p} \sum_{i=1}^{n_p} x_{ij}^p, j = 1, 2, \dots, M.$$



Функции принадлежности НшС X_i кластерам C_1-C_4 [11]
 Functions of membership of OOS X_i in clusters C_1-C_4 [11]

На втором этапе вычислялись значения нечеткой принадлежности каждой НшС множеству классифицированных кластеров типичных аварий. Степень принадлежности каждой НшС кластеру основана на том, насколько «схожа» эта НшС с моделью образа кластера. Использовались функции «сходства» i -й НшС с p -й моделью (3) в виде метрического Евклидова расстояния $r(X_i^p; C_p)$ и заданный порог Δ межклассовых пересечений кластеров [9, 15]:

$$\mu_p(X_i^p) = r(X_i^p; C_p) = \begin{cases} 0, & \text{если } r(\cdot) > \Delta \\ 1 - \frac{r(\cdot)}{\Delta}, & \text{если } r(\cdot) \leq \Delta \end{cases}$$

где

$$r(X_i^p; C_p) = \left[\sum_{j=1}^M (x_{ij}^p - c_{pj})^2 \right]^{1/2}, \quad (4)$$

$\mu_p(X_i^p)$ — функция принадлежности i -й НшС к p -му кластеру.

Если величина (4) для какой-либо НшС меньше Δ , то эта НшС принадлежит кластеру p , а величина нечеткой принадлежности лежит в интервале $[0, 1]$. В противном случае НшС не принадлежит p -му кластеру, а $\mu_p = 0$. На рисунке показан случай определения функций принадлежности X_i четырьмя пересекающимися кластерами $C_1 \div C_4$. Очевидно, что кластер C_4 не поддерживает эту ситуацию.

На третьем этапе проводилась идентификация лингвистических описаний классов типичных аварий. Как правило, полное их априорное описание отсутствует. Известно лишь, что ситуаций типа «не норма» большинство. Поэтому искалась модель, для которой справедливо отображение $C_p \geq$ «не норма», ес-

ли $n_p > N/2$. Например, для класса $C_p \geq$ «взрыв» логично записать, что $C_p \geq$ «накопление взрывоопасных скоплений метана, повышенное газовыделение, недостаточная вентиляция, искрение электрооборудования и др.». Другие описания классов аварий задаются в диалоговом режиме на основе запросов на ввод недостающих сведений.

На основе рассмотренного алгоритма была сформирована обучающая модель НС, включающая три стадии.

Первая из них — стадия нечеткой классификации набора обучающих образов в виде матрицы T размером $N \times M$ в C кластерах с $P \times M$ элементами. Из-за пересечения кластеров формируется множество значений нечетких принадлежностей, которые записываются в матрицу W с $N \times P$ элементами, причем вектор μ_N характеризует нечеткие принадлежности N -й НШС к 1-му, 2-му, ..., $(P-1)$ -му, P -му кластерам, в частности, $\mu_{N(P-1)}$ — значение функции принадлежности N -й НШС к $(P-1)$ -му кластеру.

Вторая стадия — стадия обучения, использующая нечеткие кластеры C как обучающие образы. Результатом этой стадии являются вычисленные нейровыходы сети C^* .

Третья стадия — это процесс раскрытия нечеткости, оператор которого используется для восстановления входных обучающих образов НС на основе C^* и функций принадлежности:

$$T_i^* = \left(\sum_{k=1}^s \mu_{ik} \right)^{-1} \left[\mu_{i1} C_1^* + \mu_{i2} C_2^* + \dots + \mu_{is} C_s^* \right].$$

Значения μ_{ik} определяют возможное взаимное расположение кластеров. В качестве критерия оценки ошибки распознавания НС-моделью использовался квадратичный критерий:

$$\sum_{i=1}^P \sum_{j=1}^M (c_{ij} - c_{ij}^*[k])^2,$$

где c_{ij} — выходной образ, представляющий собой нечеткий выход при входном обучающем образе x_{ij} на первой стадии обучения; c_{ij}^* — выход НС, соответствующий i -му классу множества кластеров C на k -й итерации второй стадии обучения.

В компьютерных исследованиях классифицировались 250 обучающих образов в неизвестное число кластеров. Число выходных нейроузлов изменялось в процессе классификации. Общее число ЛС — 185, число итераций — 12, входных параметров — 25. При решении задачи распознавания НШС ошибка в процентах составила 3,4%. Статья дополняет известные работы [5–12], но, в отличие от них, в данной работе использовано изменение весовых коэффициентов в линиях связей нейросети через матричные формы. Модель была реализована с применением инструментов MATLAB. Сформированы 19 кластеров типичных аварий в угольных шахтах. Этот список может дополняться другими видами аварий, обусловленными горно-геологическими и горнотехническими условиями разрабатываемых месторождений, которые выражаются в форме обучающих наборов. Для исключения недообученности НС, когда обычно наблюдается зависимость ее выходного образа от начального распределения весов сети, в нашем случае используется изменение весовых коэффициентов в ЛС согласно (2).

Заключение

Обучающая модель НС с изменяемой топологией обеспечивает автоматическое формирование знаний в виде кластеров типичных аварий с учетом их «наложения». Она адаптивна к изменению геотехнологических характеристик, не теряет своей эффективности по скорости обучения без ограничений размеров и количества обучающих образов и обеспечивает приемлемую точность распознавания НШС. Данный подход

может быть рекомендован к использованию в методиках распознавания взаимодействий НшС, причин и условий возникновения аварий. Идея первой из них

состоит в оценке связанности параметров НшС и формировании множества НшС, выбор любой пары которых рассматривается как обучающий образ.

СПИСОК ЛИТЕРАТУРЫ

1. *Куприянов В. В.* Методология оперативного обнаружения нештатных газовых ситуаций на выемочных участках шахт // Вестник университета. — 2020. — № 3. — С. 76–83. DOI: 10.26425/1816-4277-2020-3-76-83.

2. *Куприянов В. В.* Автоматизация распознавания нештатных ситуаций в угольных шахтах на основе нейронной сети с изменяемыми топологией и весовыми коэффициентами / Труды XVIII-й Всероссийской научной конференции «Нейрокомпьютеры и их применение». — М.: МГППУ, 2020. — С. 59–60.

3. *Мурацев С. И., Тимошенко А. М., Сухоруков В. А.* К анализу техногенных аварий с катастрофическими последствиями, произошедшими на предприятиях угольной промышленности России // Вестник НЦ по безопасности работ в угольной промышленности. — 2012. — № 1. — С. 55–60.

4. *Смирняков В. В., Смирнякова В. В.* Трудноуправляемые факторы в статистике причин аварийных пылегазовых взрывов в угольных шахтах России // Горный журнал. — 2016. — № 1. — С. 30–34. DOI: 10.17580/gzh.2016.01.07.

5. *Темкин И. О., До Чи Тхань, Агабубаев А.* Повышение безопасности ведения горных работ в метанообильных шахтах Вьетнама с использованием моделей прогнозной аналитики // Горный информационно-аналитический бюллетень. — 2017. — № 8. — С. 142–151. DOI: 10.25018/0236-1493-2017-8-0-142-151.

6. *Svetlov V. A., Persiantsev I. G., Shugay I. S.* A new implementation of the algorithm of adaptive construction of hierarchical neural network classifiers // *Optical Memory and Neural Networks (Information Optics)*. 2015, vol. 24, no. 4, pp. 288–294.

7. *Adeli H., Yeh C.* Neural network learning in engineering design / *Proceedings of International Neural Network Conference*, 2000, pp. 412–415.

8. *Krizhevsky A., Sutskever I., Geoffrey H.* ImageNet classification with deep convolutional neural networks // *Communications of the ACM*. 2017, vol. 60, no. 6, pp. 84–90.

9. *Kolenov D., Davidse D., Le Cam J., Pereira S. F.* Convolutional neural network applied for nanoparticle classification using coherent scatterometry data // *Applied Optics*. 2020, vol. 59, no. 27, pp. 8426–8433. DOI: 10.1364/AO.399894.

10. *Ahamed A. K., Azeem M. F.* Robust stabilization and control of Takagi-Sugeno fuzzy systems with parameter uncertainties and disturbances via state feedback and output feedback // *International Journal of Fuzzy Systems*. 2019, vol. 21, no. 8, pp. 2556–2574.

11. *Hung S. L., Adeli H.* A model of perceptron learning with a hidden layer for engineering design // *Neurocomputing*. 1991, vol. 3, no. 1, pp. 3–14. DOI: 10.1016/0925-2312(91)90016-5.

12. *Jafari M., Mobayen S.* Second-order sliding set design for a class of uncertain nonlinear systems with disturbances: An LMI approach // *Mathematics and Computers in Simulation*. 2019, vol. 156, pp. 110–125. DOI: 10.1016/j.matcom.2018.06.015.


13. *The Coalmining History Resource Centre*: [official website]. URL: <http://www.cmhrc.co.uk/site/disasters/> [accessed 30.01.2021].

14. *Jong-Chih Chien, Ming-Tao Wu, Jiann-Der Lee* Inspection and classification of semiconductor wafer surface defects using CNN deep learning networks // *Applied Sciences*. 2020, vol. 10, no. 15, pp. 13–21, article 5340. DOI: 10.3390/app10155340.

15. *Aristov A. O.* Quasi-cellular nets based on models of flow-systems // *Journal of Physics: Conference Series*. 2019, vol. 1392, no. 1, pp. 1–5, article 012064. DOI: 10.1088/1742-6596/1392/1/012064.

16. Montana D. J., Davis L. Training feedforward networks using genetic algorithms / Proceedings of the 11th International Joint Conference on Artificial Intelligence, vol. 1. Morgan Kaufman Publishers, San Mateo, California. 1989, pp. 762 – 767.

17. Takagi T., Sugeno M. Fuzzy identification of systems and its applications to modeling and control // IEEE Transactions on Systems, Man, and Cybernetics. 1985, vol. 15, no. 1, pp. 116 – 132. DOI: 10.1109/TSMC.1985.6313399.

18. Ramirez I. E., Minami Y. Design of neural network quantizers for networked control systems // Electronics. 2019, vol. 8, no. 3, pp. 318 – 326. DOI: 10.3390/electronics8030318. 

REFERENCES

1. Kupriyanov V. V. Methodology of gas-nonregular situations operative discovery at the panels of mine. *Vestnik Universiteta*. 2020, no. 3, pp. 76 – 83. [In Russ]. DOI: 10.26425/1816-4277-2020-3-76-83.

2. Kupriyanov V. V. Automation of nonregular situations recognition in coal mines on the basis of topology and weight coefficients – change neural network. *Trudy XVIII Vserossiyskoy nauchnoy konferentsii «Neyrokomp'yutery i ikh primeneniye»* [Proceedings of XVIII All-Russian scientific conference «Neuralcomputers and their application»], Moscow, MGPPU, 2020, pp. 59 – 60. [In Russ].

3. Murashchev S. I., Timoshenko A. M., Sukhorukov V. A. About analysis of technogenous accidents with catastrophic effects which took place at coal enterprises in Russia. *Industrial Safety*. 2012, no. 1, pp. 55 – 60. [In Russ].

4. Smirnyakov V. V., Smirnyakova V. V. Unhandy factors in statistics of accidental gas and dust explosions in coal mines in Russia. *Gornyi Zhurnal*. 2016, no. 1, pp. 30 – 34. [In Russ]. DOI: 10.17580/gzh.2016.01.07.

5. Temkin I. O., Do Chi Thanh, Agabubaev A. Enhancement of safety in Veitnam mines with high methane content using models of prediction analytics. *MIAB. Mining Inf. Anal. Bull.* 2017, no. 8, pp. 142 – 151. [In Russ]. DOI: 10.25018/0236-1493-2017-8-0-142-151.

6. Svetlov V. A., Persiantsev I. G., Shugay I. S. A new implementation of the algorithm of adaptive construction of hierarchical neural network classifiers. *Optical Memory and Neural Networks (Information Optics)*. 2015, vol. 24, no. 4, pp. 288 – 294.

7. Adeli H., Yeh C. Neural network learning in engineering design. *Proceedings of International Neural Network Conference*, 2000, pp. 412 – 415.

8. Krizhevsky A., Sutskever I., Geoffrey H. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*. 2017, vol. 60, no. 6, pp. 84 – 90.

9. Kolenov D., Davidse D., Le Cam J., Pereira S. F. Convolutional neural network applied for nanoparticle classification using coherent scatterometry data. *Applied Optics*. 2020, vol. 59, no. 27, pp. 8426 – 8433. DOI: 10.1364/AO.399894.

10. Ahammed A. K., Azeem M. F. Robust stabilization and control of Takagi-Sugeno fuzzy systems with parameter uncertainties and disturbances via state feedback and output feedback. *International Journal of Fuzzy Systems*. 2019, vol. 21, no. 8, pp. 2556 – 2574.

11. Hung S. L., Adeli H. A model of perceptron learning with a hidden layer for engineering design. *Neurocomputing*. 1991, vol. 3, no. 1, pp. 3 – 14. DOI: 10.1016/0925-2312(91)90016-5.

12. Jafari M., Mobayen S. Second-order sliding set design for a class of uncertain nonlinear systems with disturbances: An LMI approach. *Mathematics and Computers in Simulation*. 2019, vol. 156, pp. 110 – 125. DOI: 10.1016/j.matcom.2018.06.015.

13. *The Coalmining History Resource Centre*, available at: <http://www.cmhc.co.uk/site/disasters/> [accessed 30.01.2021].

14. Jong-Chih Chien, Ming-Tao Wu, Jiann-Der Lee Inspection and classification of semiconductor wafer surface defects using CNN deep learning networks. *Applied Sciences*. 2020, vol. 10, no. 15, pp. 13 – 21, article 5340. DOI: 10.3390/app10155340.

15. Aristov A. O. Quasi-cellular nets based on models of flow-systems. *Journal of Physics: Conference Series*. 2019, vol. 1392, no. 1, pp. 1 – 5, article 012064. DOI: 10.1088/1742-6596/1392/1/012064.

16. Montana D. J., Davis L. Training feedforward networks using genetic algorithms. *Proceedings of the 11th International Joint Conference on Artificial Intelligence*, vol. 1. Morgan Kaufman Publishers, San Mateo, California. 1989, pp. 762 – 767.

17. Takagi T., Sugeno M. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*. 1985, vol. 15, no. 1, pp. 116 – 132. DOI: 10.1109/TSMC.1985.6313399.

18. Ramirez I. E., Minami Y. Design of neural network quantizers for networked control systems. *Electronics*. 2019, vol. 8, no. 3, pp. 318 – 326. DOI: 10.3390/electronics8030318.

ИНФОРМАЦИЯ ОБ АВТОРЕ

Куприянов Вячеслав Васильевич – д-р техн. наук, профессор,
НИТУ «МИСиС», e-mail: Kupriyanov.VV@misis.ru,
ORCID ID: 000-0003-3793-8361.

INFORMATION ABOUT THE AUTHOR

V.V. Kupriyanov, Dr. Sci. (Eng.), Professor,
National University of Science and Technology «MISiS»,
119049, Moscow, Russia, e-mail: Kupriyanov.VV@misis.ru,
ORCID ID: 000-0003-3793-8361.

Получена редакцией 18.06.2021; получена после рецензии 05.10.2021; принята к печати 10.07.2022.
Received by the editors 18.06.2021; received after the review 05.10.2021; accepted for printing 10.07.2022.



РУКОПИСИ, ДЕПОНИРОВАННЫЕ В ИЗДАТЕЛЬСТВЕ «ГОРНАЯ КНИГА»

ГАЗОТУРБИННАЯ УСТАНОВКА ГТЭ-190 КАК АЛЬТЕРНАТИВНЫЙ ИСТОЧНИК ЭНЕРГИИ

(№ 1256/08-22 от 02.06.2022; 6 с.)

Косарева-Володько Ольга Владимировна¹ – канд. техн. наук, доцент,
e-mail: kosareva-volodko@rambler.ru, Шпанков Иван Сергеевич – магистр,
¹ ГИ НИТУ «МИСиС».

Рассмотрен принцип работы газотурбинной установки. Дано подробное описание турбокомпрессора, компрессора, рабочего колеса и камеры сгорания. Применение такой турбины является хорошей альтернативой классическим источникам электроэнергии, в труднодоступных местах, удаленных от других источников электроэнергии. Газотурбинная установка достаточно экономична, возможен быстрый ввод в эксплуатацию, не занимает больших площадей и что особенно важно на сегодняшний день, не оказывает большого вреда на окружающую среду.

Ключевые слова: газотурбинная установка, газотурбинная электростанция, попутный нефтяной газ, турбина.

GAS TURBINE INSTALLATION GTE-190 AS AN ALTERNATIVE ENERGY SOURCE

O.V. Kosareva-Volod'ko¹, Cand. Sci. (Eng.), Assistant Professor, e-mail: kosareva-volodko@rambler.ru,
I.S. Shpankov¹, Magister,

¹ Mining Institute, National University of Science and Technology «MISiS», 119049, Moscow, Russia.

The principle of operation of a gas turbine installation is considered. A detailed description of the turbocharger, compressor, impeller and combustion chamber is given. The use of such a turbine is a good alternative to classical sources of electricity, in hard-to-reach places remote from other sources of electricity. The gas turbine plant is quite economical, quick commissioning is possible, does not occupy large areas and, what is especially important today, does not cause much harm to the environment.

Key words: gas turbine plant, gas turbine power plant, associated petroleum gas, turbine.