

Machine Training of the System of Functional Diagnostics of the Shaft Lifting Machine

Dovbysh A. S., Zimovets V. I., Zuban Y. A., , Prihodchenko A. S.

Sumy State University

Sumy, Ukraine

Abstract. The aim of the work is to increase the accuracy of functional diagnostics of a mine hoist by using the method of information-extreme machine teaching with a hierarchical data structure. The tasks set forth in the work were to develop a categorical model; to carry out synthesis based on its hierarchical machine teaching algorithm for a functional diagnosis system; and to optimize the system of acceptance tolerance. Functional diagnostics necessitates the analysis of a large number of diagnostic features and recognition classes that characterize not only possible malfunctions, but also intermediate technical conditions of nodes and assemblies of a complex machine. The proposed algorithm is developed in the framework of the so-called information-extreme intellectual data analysis technology based on maximizing the information ability of the system in the process of machine teaching. The main idea of the proposed method is to adapt the input mathematical description of the functional diagnostics system to the maximum reliability of diagnostic solutions in the process of machine teaching. The implementation of the proposed method of the information-extremal machine teaching is carried out by the example of functional diagnostics of a multi-rope mine hoist. The most significant result is the increase in the reliability of diagnostic solutions when using the hierarchical machine teaching algorithm of the functional diagnostics system as compared with the linear classifier. In addition, the crucial rules based on the optimal geometrical parameters of hyperspherical containers of recognition classes make it possible to take highly reliable diagnostic decisions in real time.

Keywords: information-extreme intellectual technology, machine learning, information criterion, functional diagnostics, shaft lifting machine.

DOI: 10.5281/zenodo.3367060

Sistem de diagnosticare funcțională a mașinii de ridicare a minelor

Dovbysh A.S., Zimovets V.I., Zuban Yu.A., Prihodchenko A.S.

Universitatea de Stat din Sumy

Sumy, Ucraina

Rezumat. Scopul lucrării constă în majorarea acurateței diagnosticării funcționale a nodurilor unei mașini de ridicat din mine, prin sintetizarea și implementarea unui algoritm de învățare robotizat, utilizând informații extreme cu structură ierarhică de date. Sarcinile lucrării: elaborarea unui model categorian; sinteza bazată pe algoritmul său ierarhic de învățare automată pentru un sistem funcțional de diagnostic; optimizarea sistemului de toleranță la control. Algoritmul este elaborat în cadrul tehnologiei analizei datelor intelegente extreme, bazate pe maximizarea capacității informaționale a sistemului în procesul de învățare automată. Ideea principală a metodei propuse constă în aceea, ca în rețelele neuronale este necesară adaptarea descrierii matematice de intrare a sistemului funcțional de diagnostic la fiabilitatea maximă a soluțiilor de diagnosticare în procesul de învățare automată. Spre deosebire de rețelele neuronale, regulile de decizie construite în procesul de învățare automată cu informații extreme sunt practic invariabile la multidimensionalitate atât a spațiului caracteristicilor de diagnosticare, cât și a alfabetului claselor de recunoaștere. Implementarea metodei propuse de învățare robotizată în baza se prezintă prin exemplul diagnosticării funcționale a unei mașini miniere de ridicare cu mai multe funii, care este un dispozitiv electromecanic complex cu cerințe sporite pentru siguranța operațională. S-a investigat influența sistemului de toleranță de control asupra caracteristicilor de diagnostic. S-a constatat creșterea fiabilității soluțiilor de diagnosticare la utilizarea algoritmului ierarhic de învățare automată a sistemului funcțional de diagnostic în comparație cu un clasificator liniar. Regulile de decizie bazate pe parametrii geometrici optimi ai containerelor hipersferice din clase de recunoaștere permit luarea deciziilor diagnostice fiabile în timp real.

Cuvinte-cheie: tehnologie extremum-informațională inteligentă, învățare automată, criteriu informațional, diagnosticare funcțională, mașină de ridicare minieră.

Машинное обучение системы функционального диагностирования шахтной подъемной машины

Довбыш А. С., Зимовец В. И., Зубань Ю. А., Приходченко А. С.

Сумской государственной университет

Сумы, Украина

Аннотация. Цель работы – повышение точности функционального диагностирования узлов шахтной

подъемной машины путем синтеза и реализации метода информационно-экстремального машинного обучения с иерархической структурой данных. Задачи, которые ставились в работе: разработать категориальную модель; синтез на основе ее иерархического алгоритма машинного обучения для системы функционального диагностирования; оптимизация системы контрольных допусков. Известно, что при функциональном диагностировании возникает необходимость анализа большого количества диагностических признаков и классов распознавания, характеризующих не только возможные неисправности, но и промежуточные технические состояния узлов и агрегатов сложной машины. При этом предложенный алгоритм разрабатывается в рамках так называемой информационно-экстремальной интеллектуальной технологии анализа данных, основанной на максимизации информационной способности системы в процессе машинного обучения. Основная идея предлагаемого метода, как и в нейронных сетях, заключается в адаптации в процессе машинного обучения входного математического описания системы функционального диагностирования к максимальной достоверности диагностических решений. Но в отличие от нейронных сетей построенные в процессе информационно-экстремального машинного обучения решающие правила являются практически инвариантными к многомерности как пространства диагностических признаков, так и алфавита классов распознавания. Реализация предложенного метода информационно-экстремального машинного обучения осуществляется на примере функционального диагностирования многоканатной шахтной подъемной машины, являющейся сложным электромеханическим устройством с повышенными требованиями к безопасности эксплуатации. Исследовано влияние системы контрольных допусков на диагностические признаки. Наиболее значимыми результатами является повышение достоверности диагностических решений при использовании иерархического алгоритма машинного обучения системы функционального диагностирования по сравнению с линейным классификатором. Кроме того, построенные по оптимальным геометрическим параметрам гиперсферических контейнеров классов распознавания решающие правила позволяют принимать высокодостоверные диагностические решения в реальном темпе времени.

Ключевые слова: информационно-экстремальная интеллектуальная технология, машинное обучение, информационный критерий, функциональное диагностирование, шахтная подъемная машина.

ВВЕДЕНИЕ

Одной из тенденций современной горной практики является освоение месторождений с глубоким залеганием полезных ископаемых. Поэтому повышение функциональной эффективности и безопасности эксплуатации многоканатных шахтных подъемных машин (ШПМ) является важной научно-технической задачей. Сложность решения этой задачи обусловлена тем, что автоматизированная система управления ШПМ функционирует при значительной вариативности нагрузки и при этом должна поддерживать заданную скорость на всех участках тахограммы.

Повышение технико-экономических показателей функционирования ШПМ существенно зависит от функциональной эффективности автоматизированной системы управления. При этом основным перспективным направлением достижения этой цели является предоставление системе свойства адаптивности путем применения интеллектуальных информационных технологий анализа данных. Одним из важных условий адаптивности автоматизированной системы управления ШПМ является наличие системы функционального диагностирования (СФД).


Основной задачей СФД является определение непосредственно в процессе эксплуатации ШПМ тенденции отклонения динамических характеристик ее устройств от нормального технологического режима. По результатам функционального диагностирования дается оценка остаточного ресурса и выдача рекомендаций о выполнении, в случае необходимости, компенсирующих мероприятий.

Создание интеллектуальных автоматизированных систем управления ШПМ с интегрированными, а них СФД позволяет применять методы классификационного управления. Такие методы, в отличие от традиционных, позволяют системе управления оценивать текущие функциональное и техническое состояния. В соответствии с текущим состоянием диагностируемого объекта система выдает оператору рекомендации по осуществлению необходимых мероприятий с целью обеспечения высокой функциональной эффективности объекта управления.

Таким образом, повышение функциональной эффективности СФД, интегрированной в автоматизированную систему управления ШПМ является актуальной задачей, решение которой

достигается на основе машинного обучения и распознавания образов.

Структурная схема ШПМ показана на рис.1.



а - общая схема: I – электродвигатель подъема; II - редуктор; III - барабан; IV - копровые блоки; V - подземный бункер для полезных ископаемых; VI - весовой дозатор подземного бункера VII - разгрузочные кривые; VIII - процесс разгрузки скипа; IX - поверхностный бункер для полезного ископаемого; б - электропривод: 1 - датчики температуры подшипника электродвигателя; 2 - датчики температуры подшипника двигателя; 3 - датчик температуры подшипника барабана, 4 – датчик натяжения канатов [1].

Рис. 1. Структурная схема шахтной подъемной машины.¹

Транспортировка полезного ископаемого в этой установке производится в подъемном сосуде VIII, которую называют скипом. Скип подвешен на подъемном канате, который наматывается на барабан III. Вращение барабана осуществляется от подъемного двигателя I через редуктор II. Подъемный канат от барабана до скипа проходит через отклоняющие (копровые) блоки IV. Полезные ископаемые из подземного бункера V автоматически загружаются в скип через дозатор VI. На поверхности разгрузки скипа в поверхностный бункер IX. В качестве привода подъемных установок применяют электропривод I.

Элементы, которые подвергались диагностированию: натяжение канатов ШПМ, обмотка и подшипники электропривода.

Данные для проведения исследования отбирались со следующих датчиков (рис. 1):

1 – датчики температуры подшипника электродвигателя;

2 – датчики температуры подшипника двигателя;

3 – датчик температуры подшипника барабана,

4 – датчик натяжения канатов.

Для оценки состояния объекта по данным показателям может быть использована информационно-экстремальная технология, которая по совокупности значений множества параметров определяет о принадлежности объекта к тому или иному классу, например, 1-й класс – «Нормальный режим работы», 2-й класс – «Больше нормы», 3-й класс – объект не работоспособен и нуждается в ремонте, или же «Аварийный режим».

МЕТОДЫ, РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

В работах [1, 2] показано, что современные системы диагностирования ШПМ оценивают техническое состояние отдельных подсистем и узлов дифференцированно, без учёта их взаимосвязи. При этом системы

диагностирования, как правило, не реализуют алгоритмы оценки технического состояния машины и её узлов, а лишь фиксируют локальные проявления неисправностей. В этом случае оценку технического состояния ШПМ по совокупности диагностических параметров осуществляет оператор [3]. Кроме того, стационарные системы диагностирования не учитывают разнообразные динамические нагрузки, действующие на рабочие органы машины, что значительно уменьшает точность прогнозирования технического состояния ШПМ. Как основной путь устранения этих недостатков в работах [4, 5] обоснована целесообразность применения функционального диагностирования. Это позволяет в режиме реального времени по данным текущих измерений диагностических параметров идентифицировать динамические нагрузки, и состояние машины.

Такая стратегия функционального диагностирования предусматривает возможность проведения: как полноценного технического обслуживания в процессе эксплуатации ШПМ, так и планирования профилактических работ. При этом основные осложнения повышения точности функционального диагностирования ШПМ обусловлены неопределенностью входных данных и неоднозначностью процесса принятия диагностических решений. Учет этих факторов требует отказа от традиционных методов и моделей принятия диагностических и управляющих решений и переход к технологиям интеллектуального анализа данных [5].

Широкое распространение в машиностроении нашли методы оценки технического состояния объектов по параметрам вибраций [6]. Вибрационные сигналы содержат обширную информацию о состоянии машины. При преобразовании и анализе сигнала, можно получить состояние работы диагностируемого узла [7]. В настоящее время для вибрационной диагностики используется большое количество методов обработки сигналов. Однако из-за нелинейных факторов, например, трения, жесткости и наличие зазоров в исследуемой области, вибрационные сигналы имеют не стационарный и не линейный характер [8]. Кроме того, измеренные вибрационные сигналы содержат не только информацию о

рабочем состоянии, касающуюся самого диагностируемого узла, но и информацию о других движущихся деталях и конструкциях. Даная информация относится к категории фоновых шумов [9]. Поскольку фоновый шум часто сравнительно велик, существует проблема извлечения полезного сигнала. Следовательно, обычные методы вибрационной диагностики (например, вейвлет-преобразование), могут не давать точной оценки состояния работоспособности сложной машины [10].

С развитием теории нелинейной динамики было предложено большое количество методов нелинейного анализа, направленных на распознавание и прогнозирование нелинейного динамического поведения сложных машин [11]. Одним из наиболее распространенных способов выделения полезных сигналов и снижение уровня шума является сочетание нескольких методов обработки сигналов (например, пакетное вейвлет-преобразование [12], преобразование Гильберта (НТ) [13], эмпирическая модовая декомпозиция [14] и спектры более высокого порядка [15]). Однако вибрационные методы имеют ряд недостатков, а именно: особенность требования к способу крепления датчика вибрации; низкая точность диагностирования [16].

В настоящее время для диагностики неисправностей был введен ряд методов распознавания образов, среди которых наиболее распространенными являются искусственные нейронные сети [16, 17, 18] и метод опорных векторов [19]. Метод опорных векторов основан на статистической теории обучения. Точность классификатора в значительной степени определяется выбором оптимальных параметров [20, 21]. Для обеспечения точности диагностики необходимо дополнительно использовать алгоритм оптимизации [20, 21].

Применения нейронных сетей на практике ограничено из-за чувствительности к многомерности пространства диагностических признаков. Кроме того, функциональное диагностирование сложных технических объектов, к которым относятся ШПМ, характеризуется существенным пересечением классов распознавания в пространстве диагностических признаков, что также значительно уменьшает достоверность классификационных решений. Поэтому в работе [23, 24] предложено при

функциональном диагностировании применять нечеткие нейронные сети. Но при этом также не решается для нейронных сетей проблема уменьшения влияния многомерности пространства диагностических признаков. Кроме того, применение нечетких методов представления и вывода новых знаний является обоснованным при качественных шкалах измерения диагностических признаков [25].

При количественных шкалах измерения признаков целесообразно использовать более эффективные и хорошо развитые методы многомерного статистического анализа, принимая во внимание тот факт, что функция принадлежности Заде является аналогом функции плотности вероятности [26].

С другой стороны, известно, что действенным способом снижения влияния многомерности на функциональную эффективность машинного обучения является переход к иерархическим структурам данных.

Таким образом, можно констатировать, что нерешёнными задачами информационного синтеза обучающейся системы функционального диагностирования ШПМ являются:

- повышение функциональной эффективности машинного обучения системы функционального диагностирования с иерархической структурой данных;

- обеспечение инвариантности построенных в процессе машинного обучения решающих правил к многомерности пространства диагностических признаков.

Одним из перспективных путей повышения функциональной эффективности машинного обучения является использование идей и методов так называемой информационно-экстремальной интеллектуальной технологии (ИЭИ-технологии) анализа данных, разрабатываемой авторами данной статьи. Основная идея методов в рамках ИЭИ-технологии состоит в максимизации информационной способности системы в процессе её машинного обучения. В методах ИЭИ-технологии, как и в нейронных сетях осуществляется адаптация входного математического описания системы к максимальной функциональной эффективности её машинного обучения. При этом основное преимущество информационно-экстремальных методов машинного обучения состоит в построении решающих правил в рамках геометрического

подхода, что делает их практически инвариантными к многомерности пространства диагностических признаков.

Новизна работы заключается в том, что предложен метод машинного обучения для функциональной диагностики в рамках информационно-экстремальной технологии с иерархической структурой данных.

Цель работы – повышение точности функционального диагностирования шахтной подъёмной машины путем реализации метода информационно-экстремального машинного обучения с иерархической структурой данных.

Рассмотрим формализованную постановку задачи информационного синтеза СФД, обучающейся по иерархическому алгоритму. Пусть задана иерархическая структура классов распознавания диагностируемых $\{X_{h,s,m}^o | h = \overline{1, H}; s = \overline{1, S}; m = \overline{1, M}\}$, где H – количество ярусов иерархической структуры; S – количество страт h -ого яруса; M – количество классов распознавания в s -й страте.

При этом каждый класс распознавания характеризует техническое состояние соответствующего узла ШПМ. По результатам регистрации диагностических признаков в процессе всех технологических циклов перемещения скипа, согласно диаграмме скорости сформировано для каждого класса распознавания входную обучающую матрицу $\|y_{h,s,m,i}^{(j)} | i = \overline{1, N}, j = \overline{1, n}\|$, где N – количество диагностических признаков в структурированном векторе-реализации (далее просто реализация) класса распознавания $X_{h,s,m}^o$; n – количество реализаций, равное числу периодов считывания информации с датчиков на всех технологических циклах работы ШПМ. Таким образом, i -й столбик матрицы $\|y_{h,s,m,i}^{(j)}\|$ содержит значение обучающей выборки, а j -я строка, является реализацией класса распознавания $X_{h,s,m}^o$. Кроме того, для класса $X_{h,s,m}^o$ задан структурированный вектор параметров обучения системы функционального диагностирования

$$g_{h,s} = \langle x_{h,s,m}, d_{h,s,m}, \delta_{K,h,s,m,i} \rangle,$$

где $x_{h,s,m}$ – двоичная усредненная реализация класса распознавания $X_{h,s,m}^o$; $d_{h,s,m}$ – кодовое расстояние, определяющее радиус гиперсферического контейнера класса $X_{h,s,m}^o$; $\delta_{K,h,s,m,i}$ – параметр, равный половине симметричного поля контрольных допусков для i -го диагностического признака реализации $x_{h,s,m}$.

При этом задано ограничения:

$$d_{h,s,m} \in [0; d(x_{h,s,m} \oplus x_{h,s,c}) - 1],$$

где $d(x_{h,s,m} \oplus x_{h,s,c})$ – кодовое расстояние между реализацией класса распознавания $x_{h,s,m}$ и усредненной реализацией $x_{h,s,c}$ ближайшего соседнего класса распознавания $X_{h,s,c}^o$;

$$\delta_{K,h,s,i} \in [0; \delta_{E,h,s,i} / 2],$$

где $\delta_{E,h,s,m,i}$ – поле эксплуатационных допусков i -го диагностического признака реализации $x_{h,s,m}$.

На этапе машинного обучения необходимо:

1) оптимизировать параметры вектора (1) по усредненному по алфавиту классов распознавания $\{X_{h,s,m}^o\}$ информационному критерию

$$\bar{E}_{h,s} = \frac{1}{M} \sum_{m=1}^M \max_{G_E \cap G_d} E_{h,s,m}(d_{h,s,m}), \quad (2)$$

где $E_{h,s,m}(d_{h,s,m})$ – информационный критерий оптимизации параметров машинного обучения системы функционального диагностирования распознавать реализации класса $X_{h,s,m}^o$; G_E – рабочая (допустимая) область определения информационного критерия оптимизации; G_d – допустимая область изменения радиуса гиперсферического контейнера класса распознавания;

2) по полученным в процессе машинного обучения оптимальным геометрическим параметрам контейнеров классов распознавания построить для каждой страты

иерархической структуры решающие правила;

3) на этапе экзамена необходимо по построенным на этапе машинного обучения решающим правилам принять высокодостоверное классификационное решение о принадлежности текущей реализации к одному из классов заданного алфавита.

Проведенные исследования ставили целью повышение функциональной эффективности машинного обучения системы функционального диагностирования ШПМ с иерархической структурой данных. Для достижения поставленной цели решались следующие задачи:

- провести сравнительный анализ методов функционального диагностирования узлов шахтной подъемной машины;

- разработать в виде ориентированного графа категориальную модель информационно-экстремального машинного обучения системы функционального диагностирования ШПМ с иерархической структурой данных;

- на основе категориальной модели разработать алгоритм иерархического информационно-экстремального машинного обучения системы функционального диагностирования ШПМ;

- по полученным в процессе машинного обучения оптимальным (здесь и далее в информационном смысле) геометрическим параметрам гиперсферических контейнеров классов распознавания построить решающие правила;

- исследовать влияние контрольных допусков на функциональную эффективность машинного обучения системы функционального диагностирования ШПМ;

- осуществить сравнительный анализ эффективности машинного обучения системы функционального диагностирования ШПМ с иерархической и линейной структурами данных.

I. КАТЕГОРИАЛЬНАЯ МОДЕЛЬ ИЕРАРХИЧЕСКОГО МАШИННОГО ОБУЧЕНИЯ

Входное математическое описание обучающейся СФД представим в виде структуры

$$\Delta_B = \langle G, T, \Omega, Z, Y, X, f_1, f_2 \rangle,$$

где G – множество входных факторов; T – множество моментов времени снятия информации; Ω – пространство диагностических признаков; Z – пространство возможных состояний управляемого процесса; Y – множество векторов-реализаций классов распознавания, образующее входную обучающую матрицу; X – рабочая бинарная обучающая матрица; $f_1 : G \times T \times \Omega \times Z \rightarrow Y$ – оператор формирования входной матрицы Y , где $G \times T \times \Omega \times Z$ – декартово произведение, задающее универсум испытаний; $f_2 : Y \rightarrow X$ – оператор формирования бинарной обучающей матрицы X .

Категориальная модель машинного обучения системы функционального диагностирования ШПМ с иерархической структурой данных представим в виде ориентированного графа (рис. 1). При этом ребрами графа являются операторы, отображающие одно на другое множества, задействованные в процессе машинного обучения.




Рис. 2. Категориальная модель машинного обучения системы функционального диагностирования.²

На рис. 2 оператор θ отображает двоичные реализации обучающей матрицы X на разбиение пространства диагностических признаков на классы распознавания, а оператор ψ проверяет основную статистическую гипотезу о принадлежности реализации соответствующему классу распознавания. По результатам статистической проверки гипотез формируется множество гипотез $I^{|S|}$, где S – количество статистических гипотез, а оператор γ формирует множество точностных характеристик. Оператор ϕ вычисляет множество E значений информационного критерия оптимизации параметров машинного обучения, а оператор r на каждом шаге машинного обучения восстанавливает в радиальном базисе пространства диагностических признаков контейнеры классов распознавания. В категориальной модели контур оптимизации контрольных допусков на диагностические признаки замыкается через терм-множество D – систему контрольных допусков, которые используются как уровни квантования призна-

ков при формировании рабочей бинарной обучающей матрицы. Контур, в котором находится заданная иерархическая структура классов распознавания H , максимизирует усредненный по финальным стратам структуры информационный критерий оптимизации параметров машинного обучения. Оператор u регламентирует процесс машинного обучения

Таким образом, показанная на рис. 1 категориальная модель может рассматриваться как обобщенная структурная схема алгоритма иерархического информационно-экстремального обучения СФД любой сложной машины и системы. При этом согласно принципу отложенных решений для максимизации информационной способности системы может потребоваться оптимизация других параметров, влияющих на функциональную эффективность машинного обучения. В этом случае категориальная модель будет иметь дополнительные контуры оптимизации этих параметров. Кроме того, согласно принципу полной композиции контуры оптимизации должны иметь общее термножество E , элементы которого вычисляются на каждом шаге машинного обучения.

II. ИНФОРМАЦИОННЫЙ КРИТЕРИЙ ОПТИМИЗАЦИИ ПАРАМЕТРОВ МАШИННОГО ОБУЧЕНИЯ

В качестве критерия оптимизации параметров машинного обучения в методах ИЕИ-технологии может использоваться любая информационная статистическая мера. Наибольшее распространение в методах ИЕИ-технологии анализа данных нашли энтропийный (по Шеннону) критерий и информационная мера Кульбака. Для оптимизации параметров машинного обучения применим модификацию критерия Кульбака в виде

$$J_{h,s,m}^{(k)} = \{1 - [\alpha_{h,s,m}^{(k)}(d) + \beta_{h,s,m}^{(k)}(d)]\} * \log_2 \left(\frac{2 - (\alpha_{h,s,m}^{(k)}(d) + \beta_{h,s,m}^{(k)}(d)) + 10^{-r}}{\alpha_{h,s,m}^{(k)}(d) + \beta_{h,s,m}^{(k)}(d) + 10^{-r}} \right), \quad (3)$$

где $\alpha_{h,s,m}^{(k)}(d)$ – ошибка первого рода при принятии диагностических решений, вычисляемая на k -м шаге машинного обучения в процессе восстановления гиперсферического контейнера класса распознавания $X_{h,s,m}^o$; $\beta_{h,s,m}^{(k)}(d)$ – ошибка второго рода; d – дистанционная мера, определяющая радиус гипер-

² Appendix 1

сферического контейнера класса распознавания; 10^{-r} – достаточно малое число, которое вводится для устранения деления на ноль.

В выражении (3) целочисленная величина параметра r на практике выбирается из интервала $1 < r \leq 3$. Кроме того, на каждом шаге машинного обучения вместо точностных характеристик вычисляются их оценки

$$\alpha_{h,s,m}^{(k)}(d) = \frac{K_{1,h,s,m}^{(k)}}{n_{\min}}; \beta_{h,s,m}^{(k)}(d) = \frac{K_{2,h,s,m}^{(k)}}{n_{\min}},$$

где $K_{1,h,s,m}^{(k)}$ – количество событий за k шагов обучения системы, в которых своя реализация не относилась к классу $X_{h,s,m}^o$; $K_{2,h,s,m}^{(k)}$ – количество событий за k шагов обучения системы, в которых чужая реализация относилась к классу $X_{h,s,m}^o$; n_{\min} – минимальный объём репрезентативной обучающей выборки.

С целью нормализации информационного критерия (3) представим его в виде

$$E_m^{(k)} = \frac{J_m^{(k)}}{J_{\max}^{(k)}}, \quad (4)$$

где $J_{\max}^{(k)}$ – максимальное значение информационного критерия (3) при подстановке в него значений точностных характеристик $\alpha_m^{(k)}(d) = 0$ и $\beta_m^{(k)}(d) = 0$.

При вычислении в процессе машинного обучения информационного критерия необходимо принять во внимание, что его функция является не взаимно-однозначной. Поэтому поиск максимального значения критерия осуществляется в рабочей (допустимой) области определения его функции, где первая и вторая достоверности диагностических решений превосходят соответственно ошибки первого и второго рода.

III. АЛГОРИТМ МАШИННОГО ОБУЧЕНИЯ

Согласно категориальной модели (рис 1) информационно-экстремальный алгоритм обучения СФД с заданной иерархической структурой данных представим в виде процедуры поиска глобального максимума усредненного по алфавиту $\{X_m^o\}$ критерия (3)

$$\delta_{K,h,s}^* = \arg \max_{G_{\delta,h,s}} \{ \max_{G_E \cap G_d} \bar{E}_{h,s}(d) \} \quad (5)$$

где $G_{\delta,h,s}$ – область допустимых значений параметра $\delta_{K,h,s}$ поля контрольных допусков на диагностические признаки для классов распознавания s -й страты h -го яруса иерархической структуры.

Внутренний цикл процедуры (5) реализует базовый алгоритм, функциями которого является вычисление на каждом шаге обучения критерия (4), поиск его глобального максимума и определения оптимальных геометрических параметров контейнеров классов распознавания.

Входными данными базового алгоритма машинного обучения является массив реализаций $\{y_{m,i}^{(j)} | m = \bar{1}, M; i = \bar{1}, N, j = \bar{1}, n\}$, система контрольных допусков на диагностические признаки $\{\delta_{K,i}\}$ и уровни квантования значений диагностических, которые по умолчанию $\rho_{m,i} = 0,5$.

Оптимизация геометрических параметров контейнеров классов распознавания происходит по следующим основным этапам базового алгоритма машинного обучения:

- 1) формирование в евклидовом пространстве входной структурированной обучающей матрицы;
- 2) определение усредненных реализаций классов распознавания;
- 3) формирование бинарной обучающей матрицы при заданной системе контрольных допусков на диагностические признаки;
- 4) определение усредненных векторов-реализаций классов распознавания, координаты которых вычисляются путем статистического усреднения соответствующих двоичных бинарных обучающих выборок;
- 5) определение межцентрового расстояния для заданного алфавита классов распознавания путем вычисления кодовых расстояний между усредненными векторами-реализациями классов распознавания.
- 6) поиск ближайшего соседа или K -ближайших соседей путем определения минимальных кодовых расстояний между центрами классов распознавания;
- 7) вычисление на каждом шаге обучения точностных характеристик и усредненного информационного критерия оптимизации параметров машинного обучения;
- 8) поиск глобального максимума усредненного информационного критерия

оптимизации параметров машинного обучения, который находится в рабочей (допустимой) области определения функции критерия;

9) определение оптимальных радиусов контейнеров классов распознавания, которые на каждом шаге обучения восстанавливаются в радиальном базисе пространства диагностических признаков:

$$d_{m,h,s}^* = \arg \max_{G_E \cap G_d} \overline{E}_{h,s}(d_{h,s,m}), m = \overline{1, M}_{h,s} \quad (6)$$

где $M_{h,s}$ – количество классов распознавания, принадлежащих s -й страте h -го яруса.

Однако практика показала, что реализация базового алгоритма машинного обучения не позволяет получить высокую достоверность классификационных решений, так как исходные контрольные допуски на диагностические признаки, как правило, не являются оптимальными. Поэтому с целью увеличения глубины машинного обучения рассмотрим основные этапы алгоритма иерархического машинного обучения с параллельной оптимизацией контрольных допусков на диагностические признаки:

- 1) обнуление счетчика ярусов: $h := 0$;
- 2) инициализация счетчика ярусов: $h := h + 1$;
- 3) обнуление счетчика страт h -го яруса иерархической структуры: $s := 0$;
- 4) инициализация счетчика страт яруса: $s := s + 1$;
- 5) обнуление счетчика шагов изменения параметра поля контрольных допусков: $\delta_{K,h,s} := 0$;
- 6) инициализация счетчика шагов изменения параметра поля контрольных допусков: $\delta_{K,h,s} := \delta_{K,h,s} + 1$;
- 7) реализация базового алгоритма машинного обучения, который для s -й страты h -го яруса иерархической структуры на каждом шаге машинного обучения вычисляет максимальное значение информационного критерия $E_{h,s,m}(d_{h,s,m})$ и по процедуре (6) определяет оптимальные геометрические параметры контейнеров классов распознавания
- 8) если $\delta < \delta_H / 2$, то выполняется пункт 6, иначе – пункт 9.
- 9) вычисляется максимальное значение информационного критерия, усредненного по

алфавиту классов распознавания s -й страты h -го яруса;

10) для s -й страты h -го яруса определяется оптимальное значение параметра поля контрольных допусков на диагностические признаки

$$\delta_{h,s}^* = \arg \overline{E}_{h,s}^*$$

по которому вычисляются оптимальные допуски: нижние $A_{HK_i}^*$ и верхние $A_{BK_i}^*$

$$A_{HK_i}^* = y_{h,s,m} - \delta_{h,s}^*; A_{BK_i}^* = y_{h,s,m} + \delta_{h,s}^*, \quad (7)$$

где $y_{h,s,m}$ – номинальное усредненное значение i -го диагностического признака реализации класса $X_{h,s,m}$;

11) для оптимальной системы контрольных допусков (7) формируется оптимальная бинарная обучающая матрица $\|x_{h,s,m,i}^{(j)*}\|$ по правилу

$$x_{h,s,m,i}^{(j)*} = \begin{cases} 1, & \text{if } A_{HK,i}^* \leq y_{h,s,m,i}^{(j)} \leq A_{BK,i}^*; \\ 0, & \text{if else;} \end{cases}$$

12) для заданного алфавита классов распознавания формируются оптимальные усредненные реализации $\{x_{h,s,m}^*\}$, координаты которых вычисляются по правилу

$$x_{h,s,m}^* = \begin{cases} 1, & \text{if } \frac{1}{n} \sum_{j=1}^n x_{h,s,m,i}^{(j)*} \leq \rho_{h,s,m}; \\ 0, & \text{if else,} \end{cases}$$

где $\rho_{h,s,m}$ – уровень квантования значений диагностических признаков классов распознавания s -й страты h -го яруса;

13) если $s \leq S_h$, то выполняется пункт 4, иначе - пункт 14.

14) если $h \leq H$, то выполняется пункт 2, иначе – пункт 15;

15) останов.

Таким образом, алгоритм информационно-экстремального машинного обучения адаптирует входное математическое описание СФД к ее максимальной информационной способности.

По полученным в процессе машинного обучения оптимальным геометрическим

параметрам гиперсферических контейнеров классов распознавания формируются решающие правила, которые в предикатной форме имеют вид

$$\begin{aligned}
 & (\forall X_{m,h,s}^o \in \mathfrak{R}^{Ml})(\forall x^{(j)} \in \mathfrak{R}^{Ml})\{if [(\mu_m > 0) \\
 & \& (\mu_m = \max_{\{m\}} \{\mu_m \mid m = \overline{1, M}\})\} \\
 & then x^{(j)} \in X_{m,h,s}^o else x^{(j)} \notin X_{m,h,s}^o \},
 \end{aligned} \tag{8}$$

где $x^{(j)}$ – распознаваемая реализация; μ_m – функция принадлежности вектора $x^{(j)}$ гиперсферическому контейнеру класса распознавания $X_{m,h,s}^o$, определяемая по формуле

$$\mu_m = 1 - \frac{d(x^{(j)} \oplus x_{h,s,m}^*)}{d_{h,s,m}^*}. \tag{9}$$

Таким образом, распознаваемая реализация относится к тому классу из заданного алфавита, для которого функция принадлежности (9) является положительной и максимальной.

Кроме того, построенные в рамках геометрического подхода решающие правила (8) позволяют принимать диагностические решения в реальном темпе времени, что особенно актуально при функциональном диагностировании сложных машин и систем.

IV. РЕЗУЛЬТАТЫ РЕАЛИЗАЦИИ ИЕРАРХИЧЕСКОГО АЛГОРИТМА МАШИННОГО ОБУЧЕНИЯ

Реализация рассмотренного выше алгоритма осуществлялась на примере машинного обучения СФД узлов ШПМ.

Для наглядности диагностирование осуществлялось для четырех классов распознавания: класс X_1^o характеризовал функциональное состояние электропривода «Норма», класс X_2^o – состояние повышенной температуры обмотки статора электродвигателя, класс X_3^o – состояние тормозных колодок «Норма» и класс X_4^o – радиусы канавок канатопроводящих шкивов, соответствующие функциональному состоянию «Больше нормы».

Для заданных классов распознавания по архивным данным, предоставленным предприятием «УЛИС Системс», выполняющего модернизацию автоматизированной системы управления ШПМ в «ГТЭК Павлоградуголь»

(г. Павлоград, Украина) была сформирована входная обучающая матрица.

Каждая реализация соответствующего класса распознавания состояла из 60 структурированных количественных и категориальных диагностических признаков, характеризующих электрические, температурные и механические характеристики узлов ШПМ, в том числе учитывалась и разница натяжения главных канатов.

На рис. 3 показан график зависимости усредненного по алфавиту классов распознавания критерия (4) от параметра δ поля контрольных допусков, полученный в процессе их параллельной оптимизации для линейной структуры данных ($h = 1$ и $s = 1$).


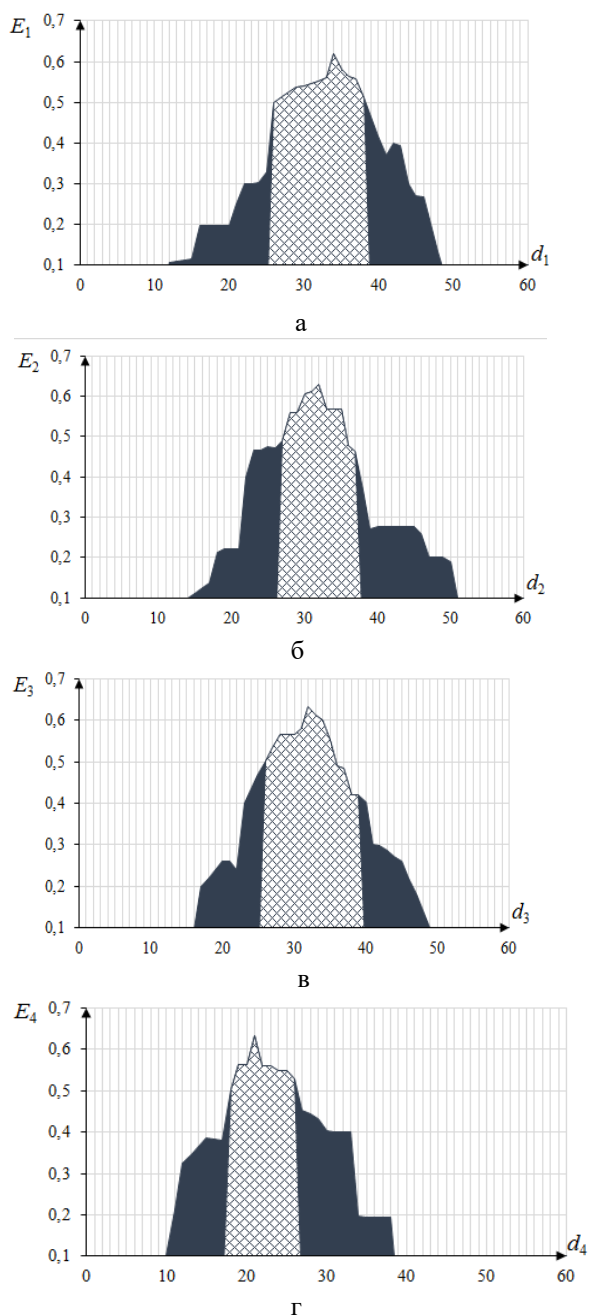


Рис. 3. График зависимости информационного критерия от параметра поля контрольных допусков на диагностические признаки.³

На рис. 3 и далее двойной штриховкой обозначены рабочие области определения функции критерия (4), в которых точностные характеристики принимают допустимые значения.

Анализ рис. 3 показывает, что усредненный критерий после проведения параллельной оптимизации контрольных допусков достигает своего максимального значения $\bar{E}_{max} = 0,64$ при оптимальном значении параметра $\delta^* = 33$ (в процентах от номинальных значений диагностических признаков).

На рис. 4 показано графики зависимости информационного критерия (4) от радиусов контейнеров классов распознавания, полученные в процессе реализации алгоритма параллельной оптимизации контрольных допусков диагностических признаков при оптимальном параметре поля контрольных допусков.



а – класс X_1^o ; б – класс X_2^o ; в – класс X_3^o ; г – класс X_4^o .

Рис. 4. Графики зависимости критерия (4) от радиусов контейнеров.

Анализ рис. 4 показывает, что оптимальные радиусы контейнеров классов распознавания равны: $d_1^* = 35$ для класса X_1^o ; $d_2^* = 34$ для класса X_2^o ; $d_2^* = 34$ для класса X_3^o и $d_4^* = 23$ для класса X_4^o

Реализация алгоритма иерархического машинного обучения для заданного алфавита осуществлялась по структуре данных, показанной на рис. 5.




Рис. 5. Иерархическая структура данных.⁵

На рис. 6 показан график зависимости критерия (4), усредненного для классов распознавания первого яруса структуры (рис. 4) от параметра δ поля контрольных допусков на диагностические признаки.




Рис. 6. График зависимости информационного критерия от параметра поля контрольных допусков на диагностические признаки для первого яруса иерархической структуры.⁶

На рис. 7 показан график зависимости усредненного по алфавиту классов распознавания первой страты второго яруса структуры (рис. 4) критерия (4) от параметра поля контрольных допусков на диагностические признаки.




Рис. 7. График зависимости критерия (4) от параметра поля контрольных допусков для первой страты второго яруса иерархической структуры.⁷

Анализ рис. 7 показывает, что максимальное значение усредненного по алфавиту классов распознавания первой страты второго яруса критерия равно $\bar{E}_{\max} = 0,68$.

На рис. 8 показано графики зависимости критерия (4) от радиусов контейнеров классов распознавания первой страты второго яруса, полученные в процессе параллельной

оптимизации контрольных допусков на диагностические признаки.

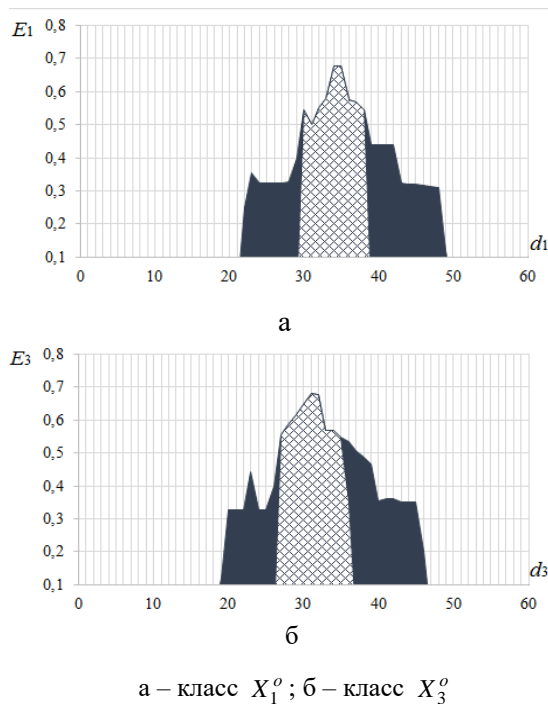


Рис. 8. Графики зависимости информационного критерия от радиусов контейнеров классов распознавания первой страты второго яруса.⁸

Анализ рис. 8 показывает, что оптимальные радиусы контейнеров равны: для класса $X_1^o - d_1^* = 35$ и для класса $X_3^o - d_3^* = 32$.

На рис. 9 показан график зависимости усредненного по алфавиту классов распознавания второй страты второго яруса критерия (4) от параметра поля контрольных допусков на диагностические признаки.




Рис. 9. График зависимости информационного критерия от параметра поля контрольных допусков для второй страты второго яруса.⁹

Анализ рис. 9 показывает, что максимальное значение усредненного для классов распознавания второй страты второго яруса информационного критерия равно $\bar{E}^* = 0,76$. Таким образом, среднее значение информационного критерия для заданного алфавита

классов распознавания равняется $\bar{E}^* = 0,72$, что превосходит его значение, полученное для линейного классификатора (рис. 3).




Рис. 10. Графики зависимости критерия от радиусов контейнеров классов распознавания второй страты второго яруса.¹⁰

На рис. 10 показано графики зависимости критерия (4) от радиусов контейнеров классов распознавания второй страты второго яруса иерархической структуры, полученные в процессе параллельной оптимизации контрольных допусков на диагностические признаки.

Анализ рис- 9 показывает, что оптимальный радиус контейнера класса X_2^o равняется $d_{12}^* = 37$ и для класса $X_4^o - d_4^* = 27$.

V. ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ МАШИННОГО ОБУЧЕНИЯ СИСТЕМЫ ФУНКЦИОНАЛЬНОГО ДИАГНОСТИРОВАНИЯ

Оценка функциональной эффективности информационно-экстремального машинного обучения СФД узлов ШПМ осуществлялась для линейной и иерархической структур данных. При этом исследовалось влияние контрольных допусков на полную вероятность правильного распознавания технического состояния узлов ШПМ. Сначала было реализовано машинное обучение СФД информационно-экстремальным алгоритмом для линейной структуры данных четырех классов рас-

познавания, которые характеризовали диагностические состояния соответствующих узлов ШПМ. Анализ полученных результатов (рис. 3) показал недостаточно высокую функциональную эффективность машинного обучения. Этот факт объясняется тем, что увеличение мощности алфавита классов распознавания приводит к увеличению степени пересечения классов распознавания в пространстве диагностических признаков. При этом соответственно увеличиваются ошибки первого и второго рода диагностических решений, что приводит к уменьшению усредненного по алфавиту классов распознавания информационного критерия оптимизации параметров машинного обучения.

С целью уменьшения влияния многомерности алфавита классов распознавания на функциональную эффективность машинного обучения было реализовано иерархический алгоритм (5) с параллельной оптимизацией контрольных допусков диагностических признаков. Анализ приведенных на рис. 6 –10 результатов машинного обучения по иерархической структуре данных показал, что максимальное значение информационного критерия удалось повысить по сравнению с линейным классификатором. Такой результат получен из-за уменьшения степени пересечения классов распознавания путем их разделения на страты соответствующего яруса иерархической структуры.

При применении решающих правил (8), построенных в процессе иерархического информационно-экстремального обучения по процедуре (5), полная вероятность правильного распознавания равна $P_i = 0,91$ для класса X_1^o , $P_i = 0,89$ для класса X_2^o , $P_i = 0,92$ для класса X_3^o и $P_i = 0,94$ для класса X_4^o , что для функционального диагностирования является достаточно высокими показателями. Кроме того, решающие правила (8), построенные в рамках геометрического подхода, являются практически инвариантными к многомерности пространства диагностических признаков и оперативно обеспечивают принятие диагностических решений. При этом построенные в примере по результатам иерархического машинного обучения решающие правила являются не безошибочными. Поэтому для повышения функциональной эффективности СФД необходимо увеличивать глубину машинного обучения путем оптимизации других параметров функционирования и форми-

рования входного математического описания системы.

В заключение отметим, что сходимость алгоритма информационно-экстремального обучения существенно зависит от априорного распределения реализаций классов распознавания в пространстве диагностических признаков. При этом необходимым условием сходимости алгоритма является попадание в процессе машинного обучения значений информационного критерия оптимизации в рабочую (допустимую) область определения его функции, в которой первая и вторая достоверности превышают соответственно ошибки первого и второго рода. А поскольку функция информационной меры по определению знакоположительная и имеет экстремум, то это является и достаточным условием сходимости алгоритма информационно-экстремального обучения.

VI. Выводы

1. Предложена категориальная модель информационно-экстремального машинного обучения СФД с иерархической структурой данных в виде ориентированного графа, ребрами которого являются операторы, отображающие одно на другое терм-множества перемешанных процесса машинного обучения.

2. На основе категориальной модели и модифицированного информационного критерия Кульбака разработан иерархический алгоритм информационно-экстремального машинного обучения СФД узлов ШПМ, позволивший получить высокую полную вероятность правильного диагностирования для заданного алфавита классов распознавания.

3. Показано, что функциональная эффективность машинного обучения СФД узлов ШПМ зависит от системы контрольных допусков на диагностические признаки, что требует их оптимизации по информационному критерию.

4. Сравнительный анализ показал, что при машинном обучении СФД по иерархической структуре данных максимальное значение усредненного по алфавиту классов распознавания информационного критерия оптимизации параметров обучения превосходит его значение, полученное для линейного классификатора.

APPENDIX 1 (ПРИЛОЖЕНИЕ 1)

¹Fig. 1. Structural diagram of mine hoisting machine: a - general scheme; I - electric lift motor; II - gear; III

- drum; IV - pile blocks; V - underground bunker for minerals; VI - weight batcher of the underground bunker; VII - discharge curves; VIII - skip unloading process; IX - surface bunker for minerals; b - electric drive: 1 - temperature sensors of motor bearing; 2 - temperature sensors of the engine bearing; 3 - drum bearing temperature sensor; and 4 - rope tension sensor.

²**Fig. 2.** Categorical model of machine teaching system functional diagnosis.

³**Fig. 3.** Graph of dependence of information criterion on parameter of field control tolerances for diagnostic signs.

⁴**Fig. 4.** Graphs of dependence of criterion (4) on radii of containers: a - class X_1^o ; b - class X_2^o ; c - class X_3^o ; d - class X_4^o .

⁵**Fig. 5.** Hierarchical data structure.

⁶**Fig. 6.** Graph of dependence of information criterion on parameter field control tolerances for diagnostic signs for the first tier of hierarchical structure.

⁷**Fig. 7.** Graph of dependence of criterion (4) on the parameter of acceptance tolerance field for the first stratum of the second tier of hierarchical structure.

⁸**Fig. 8.** Graphs of dependence of information criterion on the radii of the containers of the recognition classes of the first stratum of the second tier: a - class X_1^o ; b - class X_3^o .

⁹**Fig. 9.** Graph of dependence of information criterion on parameter of field of acceptance tolerances for the second stratum of the second tier.

¹⁰**Fig. 10.** Graphs of dependence of criterion on radii of containers of recognition classes of the second stratum of the second tier: a - class X_2^o ; b - class X_4^o .

Литература (References)

[1] Trifanov G.D. *Ekspluatatsiya shahtnih podemnih ustanovok* [Operation of mine hoisting installations]. Perm, 2015. 315 p.

[2] Kaschich A., Marischenko A., Bojok N. Sistema upravleniya i kompleksnoi zaschiti shahtnoi podemnoi ustanovki [Control system and integrated protection of mine lifting installation] *Cistemnaya integraciya, dobyvayushchaya promyshlennost' – System Integration, Mining*, 2005, no. 2, pp. 26–34. (In Russian)

[3] Ershov D. YU. Tekhnicheskoe diagnostirovanie i metody kontrolya mekhanicheskikh uzlov v mashinostroenii [Technical diagnostics and control methods of mechanical units in mechanical engineering]. *Molodoj uchenyj – Young scientist*, 2013, no.4, pp. 62-64. (In Russian).

[4] Sidorenko V.N., Chernyy A.P. Monitoring moschnykh elektroprivodov na osnove tehnologii Data Mining [Monitoring of powerful electric drives based on Data Mining technology]. *Elektrotexnichni ta komp'yuterni sy'stemy` – Electrical and computer systems*, 2011, no. 3, pp. 414-416. (In Russian).

[5] Makotrynskyi O.V., Vashchenko Ya.V., Yatsko S.I. Shtuchna neiromerezheva systema neperervnoho typu dlia diahnostyky tiahovoho elektroprivoda [Artificial neural network system of continuous type for diagnostics of traction drive]. *Zbirnyk naukovykh prats ukrainskoho derzhavnogo universytetu zaliznychnoho transportu – Collection of scientific papers of ukrainian state university of railway transport*, 2013, no.141, pp. 230-234. (In Ukrainian).

[6] Andrzej O., Zygmunt S. Modern Methods Control and Diagnostics of Hoisting-Machines with Application of Artificial. *Intelligence Methods. Archives of Mining Sciences*, 2010, vol. 55, no. 1, pp. 217-231.

[7] Zhang X., Hu N., Hu L., Chen L., Cheng Z. A bearing fault diagnosis method based on the low-dimensional compressed vibration signal. *Advances in Mechanical Engineering*, 2015, vol. 7, no. 7, pp. 1-7. doi: 1687814015593442.

[8] Zhang D. D. Bearing fault diagnosis based on the dimension-temporal information. *Proceedings of the Institution of Mechanical Engineers, Part J: Journal of Engineering Tribology*, 2011, vol. 225, no.8, pp. 806-813. doi: 10.1177/1350650111410254.

[9] Tiwari R, Gupta V K, Kankar P K. Bearing fault diagnosis based on multi-scale permutation entropy and adaptive neuro fuzzy classifier. *Journal of Vibration and Control*, 2015, vol. 21, no. 3 pp. 461–467

[10] Vakharia V, Gupta V K, Kankar P K. A multiscale permutation entropy based approach to select wavelet for fault diagnosis of ball bearings. *Journal of Vibration and Control*, 2014, vol. 21, no. 16, pp. 3123-3131. doi: 1077546314520830.

[11] Sun W., Yang G. A., Chen Q., Palazoglu A., Feng K. Fault diagnosis of rolling bearing based on wavelet transform and envelope spectrum correlation. *Journal of Vibration and Control*, 2013, vol. 19, no. 6, pp. 924–941. doi: 10.1177/1077546311435348

[12] Wang H, Chen J, Dong G. Fault diagnosis of rolling bearing's early weak fault based on minimum entropy de-convolution and fast Kurtogram algorithm. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 2014, vol. 229, no. 16, pp. 2890-2907 doi: 0954406214564692.

[13] Wang D., Tse P.W., Tsui K.L., An enhanced Kurtogram method for fault diagnosis of rolling element bearings. *Mech. Syst. Signal Process.*, 2013, vol. 35, no. 1, pp. 176-199.

[14] Cai J. Fault diagnosis of rolling bearing based on empirical mode decomposition and higher order statistics. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of*

- Mechanical Engineering Science*, 2014: vol. 229, no. 9, pp. 1630-1638. doi: 0954406214545820.
- [15] Liu, Q., Chen, F., Zhou, Z., Wei, Q. Fault Diagnosis of Rolling Bearing Based on Wavelet Package Transform and Ensemble Empirical Mode Decomposition. *Advances in Mechanical Engineering*, 2013, vol. 2013, pp. 1-6. doi: 10.1155/2013/792584
- [16] Yunusa-Kaltungo A, Sinha J K. Faults Diagnosis in Rotating Machines Using Higher Order Spectra[C]. ASME Turbo Expo 2014: Turbine Technical Conference and Exposition. *American Society of Mechanical Engineers*, 2014, pp. V07AT31A002-V07AT31A002.
- [17] Wang C. C., Kang Y., Shen P. C., Chang Y. P., Chung Y. L. Applications of fault diagnosis in rotating machinery by using time series analysis with neural network. *Expert Systems with Applications*, 2010, vol. 37, no. 2, pp. 1696-1702.
- [18] Jayaswal P, Verma S N, Wadhvani A K. Development of EBP-Artificial neural network expert system for rolling element bearing fault diagnosis. *Journal of Vibration and Control*, 2011, vol. 17, no. 8, pp. 1131-1148.
- [19] Samanta B, Al-Balushi K R. Artificial neural network based fault diagnostics of rolling element bearings using time-domain features. *Mechanical systems and signal processing*, 2003, vol. 17, no. 2, pp. 317-328.
- [20] Dong S., Xu X., Liu J., Gao Z. Rotating Machine Fault Diagnosis Based on Locality Preserving Projection and Back Propagation Neural Network-Support Vector Machine Model. *Measurement and Control*, 2015, vol. 48, no. 7, pp. 211-216
- [21] Ao H., Cheng J., Yang Y., Truong T. K. The support vector machine parameter optimization method based on artificial chemical reaction optimization algorithm and its application to roller bearing fault diagnosis. *Journal of Vibration and Control*, 2013, vol. 21, no. 12, pp. 2434-2445. doi: 1077546313511841.
- [22] Zhang X L, Chen X F, He Z J. Fault diagnosis based on support vector machines with parameter optimization by an ant colony algorithm. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 2010, 224(1): 217-229.
- [23] Zhang, Sheng Asakura, Toshiyuki Xu, Xiaoli Xu, Baojie. Fault Diagnosis System for Rotary Machine Based on Fuzzy Neural Networks. *Jsm International Journal Series C-mechanical Systems Machine Elements and Manufacturing - JSME INT*, 2003, vol.46, no. 3, pp. 1035-1041.
- [24] Subbotin S. The neuro-fuzzy network synthesis and simplification on precedents in problems of diagnosis and pattern recognition *Optical Memory and Neural Networks (Information Optics)*. 2013, vol. 22, pp. 97-103. DOI:: 10.3103/s1060992x13020082
- [25] Bhowmik P.S., Pradhan S., Prakash M. Fault diagnostic and monitoring methods of induction motor: a review. *International Journal of Applied Control, Electrical and Electronics*, 2013, vol. 1, pp. 1-18.
- [26] Hasan A. Yousef, Manal Wahba A. Adaptive fuzzy mimo control of induction motors. *Expert Systems with Applications: An International Journal*. 2009, vol. 36, issue 3, pp. 4171-4175. DOI 10.1016/j.eswa.2008.04.004.

Сведения об авторах.



Зимова Виктория Игоревна,
Преподаватель индустриально-педагогического техникума
Конотопского института
Сумского государственного
университета.
Область научных интересов:
искусственный интеллект.
E-mail: zc.vika@gmail.com



Довбыш Анатолий Степанович,
доктор
технических наук, профессор,
заведующий кафедры
компьютерных наук Сумского
государственного университета
Область научных интересов:
интеллектуальные системы
анализа данных
E-mail: a.dovbysh@cs.sumdu.edu.ua



Зубань Юрий Александрович,
кандидат технических наук,
доцент,
директор организационно-методического центра технологий
электронного обучения СумГУ
Область научных интересов:
искусственный интеллект
E-mail: zuban@elearning.sumdu.edu.ua



Приходченко Александр Сергеевич, аспирант кафедры
компьютерных наук Сумского
государственного университета
Область научных интересов:
Интеллектуальные
информационные технологии.
E-mail: prihodchenko@gmail.com