

* *
*

УДК 629.783, 521.182

DOI: 10.17223/00213411/64/10/38

**ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ
В ИССЛЕДОВАНИИ ДИНАМИЧЕСКОЙ СТРУКТУРЫ
ОКОЛОЗЕМНОГО ОРБИТАЛЬНОГО ПРОСТРАНСТВА***

Д.С. Красавин, А.Г. Александрова, И.В. Томилова

Национальный исследовательский Томский государственный университет, г. Томск, Россия

Представлено описание методики исследования динамической структуры околоземного орбитального пространства с использованием технологии машинного обучения. Искусственные нейронные сети применялись для обработки временных рядов, связанных с эволюцией резонансных характеристик, определяющих динамическую структуру области околоземного пространства до 120 тыс. км по большой полуоси. Количество обрабатываемых рядов превысило полмиллиона, и их обработка в ручном режиме потребовала бы больших временных затрат. Приведены результаты применения методики к анализу резонансной структуры выбранной области космического пространства.

Ключевые слова: численное моделирование, динамика ИСЗ, орбитальная эволюция, искусственные нейронные сети, машинное обучение.

Введение

Настоящая статья является продолжением работы [1] по применению методов машинного обучения для исследования динамической структуры околоземного космического пространства (ОКП). В работе [1] средства машинного анализа для изучения резонансной структуры ОКП применялись в несколько упрощенном варианте, поскольку искусственные нейронные сети (ИНС) были способны находить только устойчивые резонансы, а в наших исследованиях важно распознавать и неустойчивые резонансы.

В данной работе мы рассмотрим алгоритм, который позволяет определять резонансы любого типа. Методика, как и ранее, основана на интегрировании уравнений движения с помощью «Численной модели движения систем ИСЗ» [2, 3] и численном определении частот движения околоземных объектов [4, 5] с последующим машинным анализом получаемых временных рядов с помощью искусственных нейронных сетей, но уже по новому алгоритму.

В данной статье мы не приводим методику выявления резонансов, поскольку она неоднократно подробно описывалась в наших работах, например в [4, 5], и ограничимся только пояснением, что для временного ряда, связанного с некоторым критическим аргументом, строится график, который затем визуально оценивается и относится в одну из категорий: «циркуляция», «либрация», «смешанный тип», что соответствует «отсутствию резонанса», «устойчивому резонансу» и «неустойчивому резонансу».

1. Машинное обучение

Машинное обучение позволяет решать задачи, которые сложно формализуются, например задачи классификации или извлечения информации из изображений или временных рядов [6, 7].

Задачу машинного обучения в общем виде можно сформулировать следующим образом [8].

Пусть задано множество объектов (признаковых переменных) X , множество допустимых ответов (целевых переменных) Y и существует некоторая целевая функция $y^* : X \rightarrow Y$. Кроме того, заданы некоторое конечное подмножество объектов $\{x_i\} \in X$ и соответствующие им значения целевой функции $y^* \{y_i = y^*(x_i)\}$. Совокупность соответствующих пар из этих подмножеств $\{(x_i, y_i)\}$ называется *обучающей выборкой*. Задача машинного обучения заключается в нахожде-

* Исследование выполнено за счет гранта Российского научного фонда (проект № 19-72-10022).

нии некоторой функции, которая бы наилучшим образом приближала целевую функцию на всей обучающей выборке. Такая функция называется *алгоритмом* или *моделью машинного обучения*.

Для реализации машинного обучения с помощью ИНС нами был выбран язык python, поскольку на нем написано большое число библиотек, которые можно использовать в наших задачах [9–12].

2. Схема эксперимента

Для получения модели, способной сопоставлять временным рядам метку класса, потребовалось несколько принципиально разных шагов, требующих вовлечения алгоритмов из разных областей машинного обучения [13, 14].

Шаг первый: обучение ИНС-автокодировщика [15] для получения скрытых представлений временных рядов. После выполнения этого шага получается модель, способная преобразовывать временной ряд в вектор размерности 16.

Шаг второй: кластеризация скрытых представлений для последующей разметки человеком. Кластеризация позволяет сократить количество меток в десятки раз и соответственно время на разметку. Кластеризация проводилась посредством алгоритма HDBSCAN [16]. Его несомненное достоинство для данной задачи заключается в том, что количество кластеров определяется автоматически, так как мы заранее не знаем, на какое количество кластеров делятся наши данные.

Шаг третий: построение классификатора на скрытых представлениях. Классификатор ставит в соответствие скрытому представлению число от 0 до 1, которое соответствует отсутствию или наличию резонанса. Использование скрытых представлений позволяет снизить количество параметров модели-классификатора, что, во-первых, ускоряет обучение, а во-вторых, снижает вероятность переобучения.

ИНС - автокодировщик

Автокодировщик – это такая архитектура ИНС, которая обучается повторять на выходе тот же самый сигнал, который получает на входе. Таким образом, обучающая выборка для такой сети состоит не из пар (объект, ответ), а из пар (объект, объект), что позволяет отнести такую архитектуру к классу моделей частичного обучения с учителем (semi-supervised learning) [14].

В общем виде схема автокодировщика представлена на рис. 1. Такую ИНС можно разделить на две части: кодировщик $e(X)$ и декодировщик $d(z)$. Первый является отображением из $[0; 2\pi)^N$ в R^L , где L – размерность скрытого пространства. В нашей реализации $L = 16$, $N = 3650$. Таким образом, временному ряду X ставится в соответствие элемент $z \in R^L$, называемый кодом. Декодировщик же является обратным отображением. Тогда элементом обучающей выборки для задачи обучения автокодировщика являются пары (X, X) , результатом работы $\tilde{X} = d(e(X))$, а функцией потерь – сумма квадратов отклонений элементов \tilde{X} и X . Примеры работы автокодировщика представлены на рис. 2. Темно-серым цветом на рис. 2 на графиках слева показаны значения исходного ряда, а светло-серым – результат работы автокодировщика. На графиках справа дана визуализация скрытого представления. В скобках приведены значения классификатора. Чем сильнее отклоняется восстановленный ряд от исходного, тем выше функция потерь.

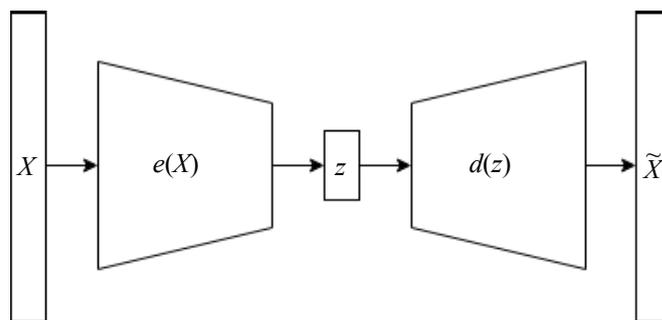


Рис. 1. Принципиальная схема автокодировщика

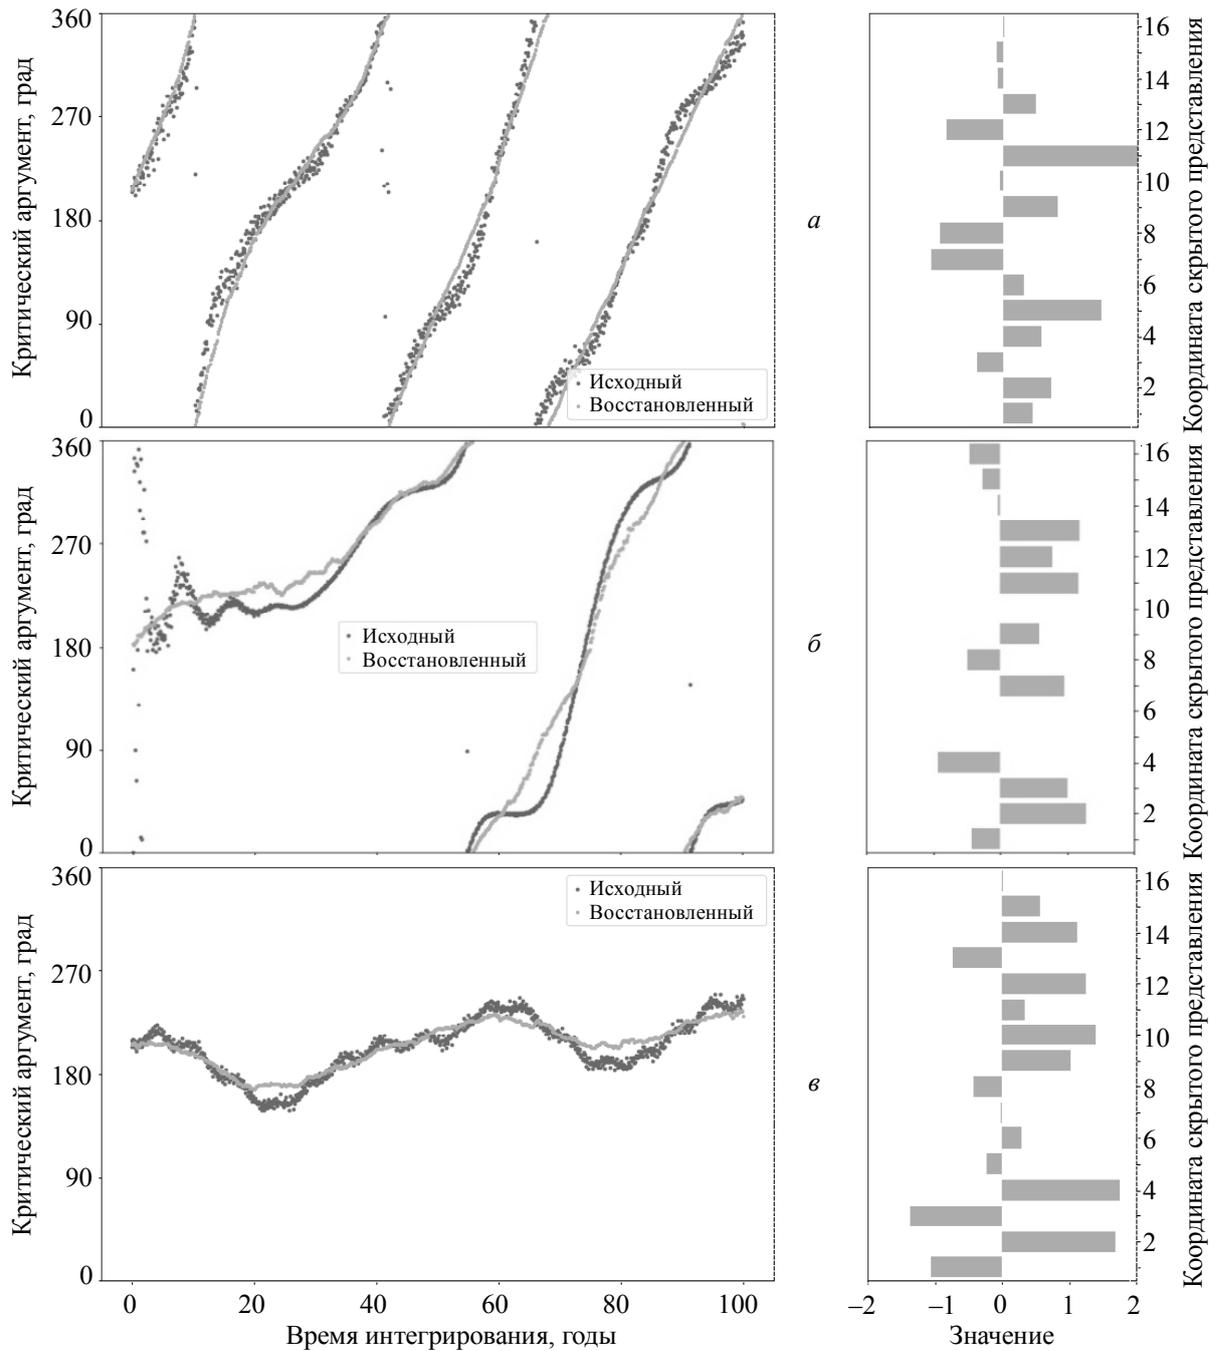


Рис. 2. Результат работы автокодировщика (слева) и визуализация скрытого представления (справа):
 а – отсутствие резонанса (0.05); б – неустойчивый резонанс (0.39); в – устойчивый резонанс (0.89)

Поскольку кодировщик и декодировщик есть набор линейных преобразований (за исключением функции активации ReLU), можно считать, что гипотеза компактности выполняется. То есть похоже с точки зрения человека временные ряды будут иметь близкие коды. Более того, можно сделать предположения, что коды неустойчивых резонансов будут находиться в скрытом пространстве в областях между устойчивыми резонансами и их отсутствием.

Помимо описанных выше преимуществ, формирование новой обучающей выборки $T' = (z := e(X), y)$ из $T = (X, y)$, т.е. замена временных рядов на соответствующие им коды, кардинально снижает размерность задачи.

ИНС-автокодировщик тренируется воспроизводить временной ряд, соответствующий эволюции критического аргумента, имея размерность скрытого представления равную 16. То есть слой, являющийся выходом кодировщика и входом декодировщика, имеет 16 нейронов.

Схема формирования новой выборки T' и обучения на ней ИНС представлена на рис. 3.

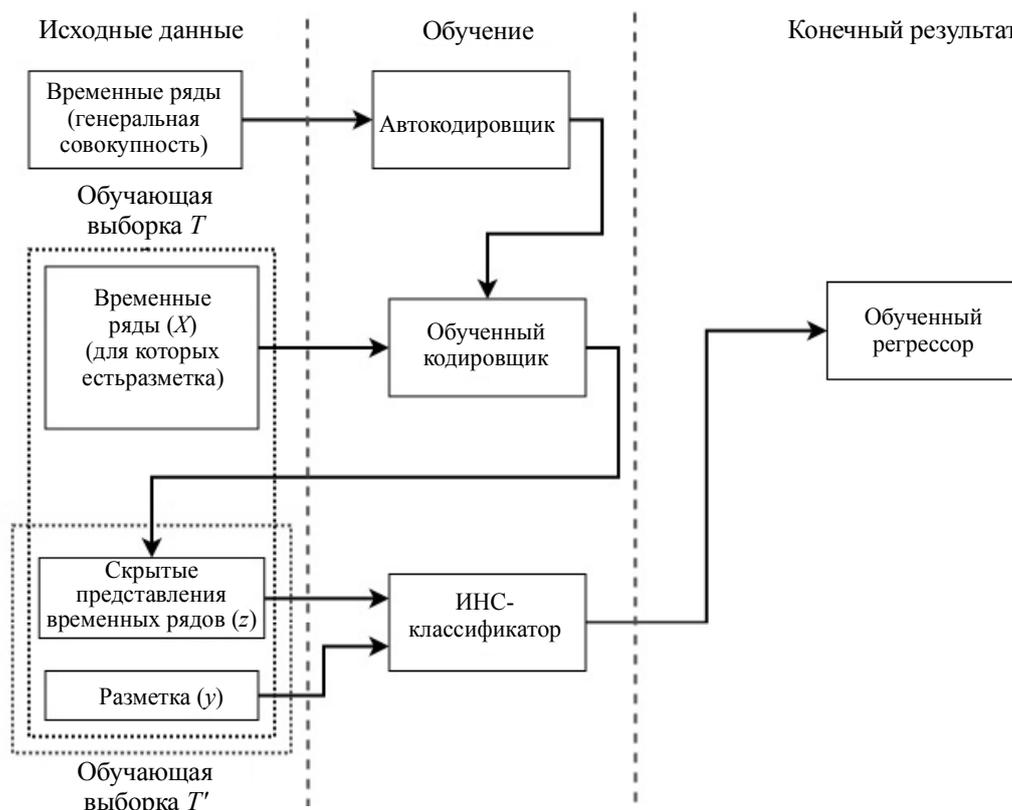


Рис. 3. Процесс формирования обучающей выборки T' и обучения на ней новой модели

Кластеризация

Кластеризация (или кластерный анализ) – многомерная статистическая процедура, выполняющая сбор данных, содержащих информацию о выборке объектов, и затем упорядочивающая объекты в сравнительно однородные группы [17].

После обучения автокодировщика и перевода временных рядов в их скрытые представления появляется возможность автоматически кластеризовать временные ряды для их дальнейшей разметки в смысле наличия устойчивого резонанса, проводя разметку не по каждому примеру в отдельности, а по целому кластеру. Кластеризация проводится алгоритмом HDBSCAN.

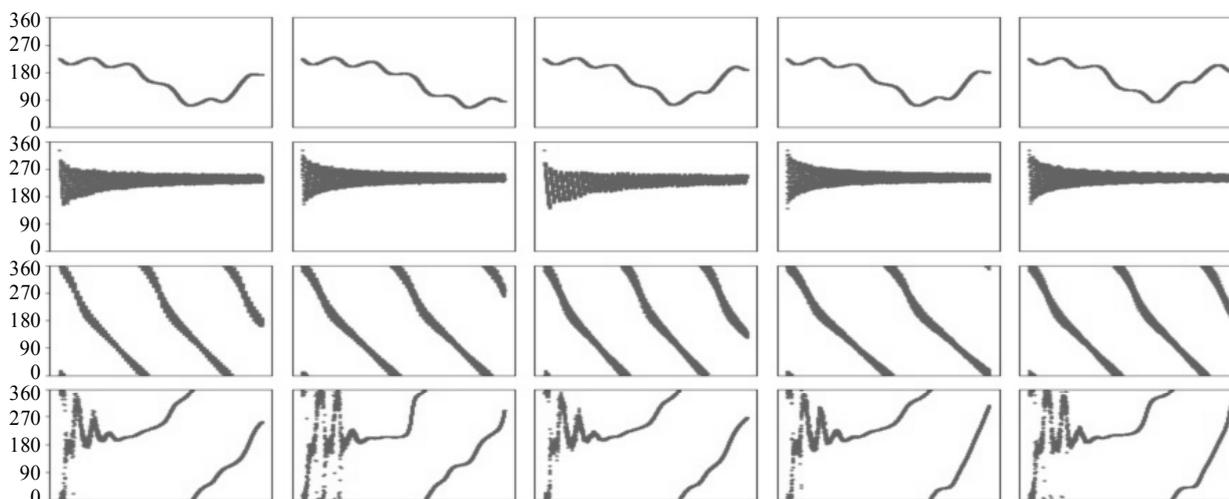


Рис. 4. Пример кластеризации при помощи HDBSCAN (каждый ряд представляет собой один из кластеров)

Кластеризация также позволяет найти интересные и нетипичные примеры для ручной обработки.

Построение классификатора на скрытых представлениях

На размеченных данных обучается еще одна ИНС, представляющая собой многослойный перцептрон. Именно эта ИНС и является классификатором. ИНС сопоставляет временному ряду число от 0 до 1 в соответствии с разметкой.

Стоит отметить, что коды временных рядов, соответствующие неустойчивому резонансу, не участвовали в обучении. Значения ответов ИНС на них оказались между значениями ответов на классах 0 и 1.

Так, в ходе тестирования значения классификатора в случае отсутствия резонанса находятся в окрестности 0, для неустойчивого резонанса – в окрестности 0.4 и для устойчивого близки к 1, что подтверждает сделанное на базе гипотезы компактности предположение.

Как уже упоминалось выше, на рис. 2 справа в виде столбчатой диаграммы представлена визуализация кода в скрытом пространстве для каждого примера: ось ординат соответствует номеру координаты в скрытом пространстве, а ось абсцисс – значению этой координаты. В подписях к графикам в скобках указано значение обученного классификатора на данном коде.

3. Численные результаты

В ходе эксперимента моделируемые объекты равномерно распределялись по изучаемой области ОКП с шагом 200 км по большой полуоси и 5° по наклонению. Рассматривалась область орбитального пространства, простирающаяся по большой полуоси от 45000 до 120000 км и по наклонению от 0 до 180° . В данной области околоземного пространства мы исследовали около 14 тыс. объектов, и для каждого объекта изучили эволюцию 39 резонансных аргументов [1], т.е. более полумиллиона временных рядов. Поэтому привлечение к решению задачи машинного анализа было вполне естественным.

На рис. 5 приведена карта распространности вековых апсидально-нодальных резонансов. Таблицу с перечнем исследуемых резонансов можно найти в работе [4]. По данной карте легко отследить области с максимальным наложением резонансов, а значит, с наиболее интересной динамикой. Результаты тестирования показали, что применение методов машинного обучения для выявления резонансов в околоземном пространстве дает хороший результат и значительно ускоряет процесс исследований. К сожалению, в данной модели иногда встречаются случаи ложного присвоения того или иного класса, соответственно модель нуждается в дальнейшем усовершенствовании.

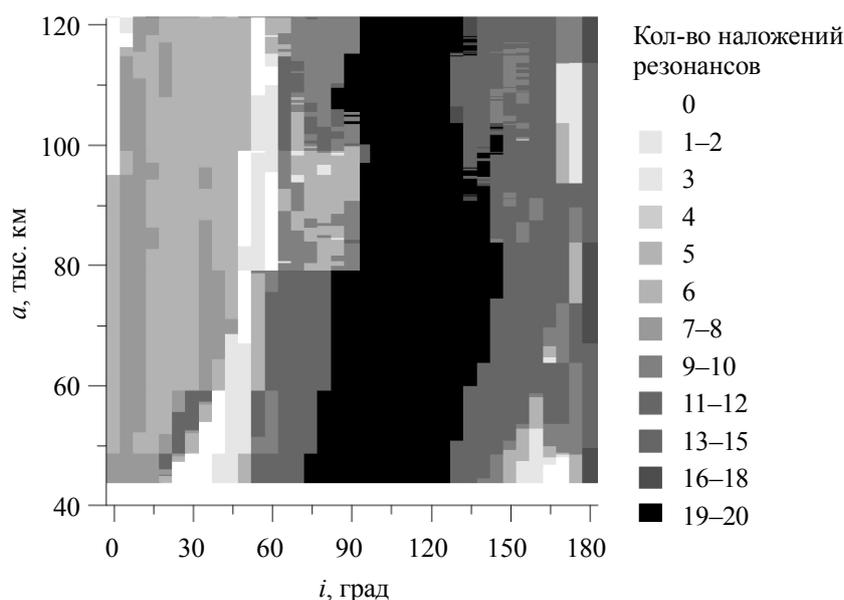


Рис. 5. Карта распространности вековых резонансов

Заключение

В данной работе описан новый эксперимент по применению искусственных нейронных сетей для решения задачи обработки и анализа большого массива данных численного моделирования динамической структуры ОКП. Приведенный алгоритм способен выявлять не только устойчивые, но и неустойчивые резонансы. Показано, что анализ временных рядов, связанных с эволюцией резонансных характеристик, определяющих динамическую структуру, в обширных экспериментах целесообразно проводить с использованием методов машинного анализа, поскольку число временных рядов, которые необходимо обработать, превышает 0.5 млн. С применением методов машинного анализа получена карта распространенности вековых апсидально-нодальных резонансов в обширной области ОКП от 45 тыс. до 120 тыс. км по большой полуоси.

СПИСОК ЛИТЕРАТУРЫ

1. Красавин Д.С., Александрова А.Г., Томилова И.В. // Изв. вузов. Физика. – 2020. – Т. 63. – № 3. – С. 70–75.
2. Александрова А.Г., Бордовицына Т.В., Чувашов И.Н. // Изв. вузов. Физика. – 2017. – Т. 60. – № 1. – С. 69–76.
3. Александрова А.Г., Авдюшев В.А., Попандопуло Н.А., Бордовицына Т.В. // Изв. вузов. Физика. – 2021. – Т. 64. – № 8. – С. 168–175.
4. Александрова А.Г., Блинкова Е.В., Бордовицына Т.В. и др. // Астрон. вест. – 2021. – Т. 55. – № 3. – С. 272–287.
5. Александрова А.Г., Бордовицына Т.В., Попандопуло Н.А. и др. // Изв. вузов. Физика. – 2020. – Т. 63 – № 1. – С. 57–62.
6. Bishop C.M. Pattern Recognition and Machine Learning. – Springer, eBook, 2006. – 761 p.
7. Goodfellow I., Bengio Y., Courville A. Deep Learning. – The MIT Press, eBook, 2016. – 800 p. – URL: <http://www.deeplearningbook.org/contents/TOC.html> (05.12.2020).
8. Воронцов К.В. Математические методы обучения по прецедентам (машинное обучение). Курс лекций. – URL: <http://www.machinelearning.ru> (05.12.2020)
9. Описание библиотеки torch для python. – URL: <https://github.com/pytorch/pytorch> (05.12.2020).
10. Описание пакет nn библиотеки torch для языка python. – URL: <https://pytorch.org/docs/stable/nn.html> (06.12.2020).
11. Плас Дж. Вандер. Python для сложных задач: наука о данных и машинное обучение. – СПб.: Питер, 2018. – 576 с.
12. Рашка С. Python и машинное обучение: пер. с англ. – М.: ДМК Пресс, 2017. – 420 с.
13. Ismail Fawaz H., Forestier G., Weber J., et al. // Data Mining and Knowledge Discovery. – 2019. – V. 33. – Iss. 4. – P. 917–963. – DOI: 10.1007/s10618-019-00619-1.
14. Hagan M.T., Demuth H.B., Hudson Beale M., Jesús O. Neural Network Design. – 2nd Edition. – eBook, 2019. – 1012 p. – URL: <https://hagan.okstate.edu/nnd.html> (06.12.2019).
15. Kingma D.P., Welling M. An Introduction to Variational Autoencoders // arXiv.org. – 2019. – URL: <https://arxiv.org/abs/1906.02691>.
16. McInnes L., Healy J., Astels S. // JOSS. – 2017. – V. 2(11). – P. 205. – DOI: 10.21105/joss.00205.
17. Ester M., Kriegel H.-P., Sander J., Xu X. // Proceedings of the Second International Conference on Knowledge Discovery and Data Mining (KDD-96). – AAAI Press, 1996. – P. 226–231.

Поступила в редакцию 19.02.2021.

Красавин Дмитрий Сергеевич, аспирант, инженер НИ ТГУ, e-mail: iosfixed@gmail.com;

Александрова Анна Геннадьевна, к.ф.-м.н., ст. науч. сотр. НИ ТГУ, e-mail: aleksandrovaannag@mail.ru;

Томилова Ирина Владимировна, к.ф.-м.н., ст. науч. сотр. НИ ТГУ, e-mail: irisha_tom@mail.ru.