

## Исследование свойств металлов при ударном индентировании с использованием нейросетевого анализа

*Н.Е. Бабушкина, А.А. Ляпин*

*Донской государственный технический университет, Ростов-на-Дону*

**Аннотация:** Индентирование является универсальным и практичным методом получения характеристик материалов, особенно когда нельзя или трудно подвергнуть материал другим измерительным методам. При помощи установки ударного нагружения были получены экспериментальные данные о механических свойствах различных видов материалов. Для верификации результатов эксперимента использована математическая модель, основанная на методе конечных элементов. В статье рассматривается решение задачи классификации нейронной металлов, отличающихся механическими свойствами. В рамках работы создана искусственная нейронная сеть, позволяющая провести распределение материалов по выделенным группам. Определено, что значимым преимуществом использования нейронных сетей является способность обрабатывать экспериментальные данные и выявлять сложные нелинейные зависимости, что делает их востребованными в задачах, связанных с исследованием свойств материалов.

**Ключевые слова:** ударное индентирование, нейронная сеть, задача классификации, искусственный интеллект, динамическое индентирование, неразрушающий контроль.

Оценка технического состояния строительных конструкций является важной задачей для обеспечения их безопасности и долговечности [1]. Особенно актуальна эта задача в условиях воздействия циклических нагрузок, которые могут приводить к усталостному разрушению материалов. Для оценки материалов необходимо знать их прочностные свойства.

Одним из источников получения информации о свойствах материалов является проведение экспериментов в лабораторных условиях. Существуют различные методы экспериментального исследования материалов, которые можно разделить на разрушающие и неразрушающие. Разрушающие методы доводят образцы материала до полного разрушения под действием нагрузок, температуры, среды и т.д. Неразрушающие методы основаны на измерении различных физических величин, характеризующих состояние материала, без его разрушения или повреждения.

Разрушающие методы имеют ряд недостатков [2], обеспечивающих низкую достоверность результатов в сочетании с высокой трудоемкостью и затратностью. Поэтому исследования в области оценки технического состояния строительных конструкций ведутся в сторону развития и совершенствования неразрушающих методов, которые показывают высокую точность результатов при минимальных затратах, обеспечивая возможность применения к объектам, находящимся в эксплуатации.

Одним из методов неразрушающего исследования материалов является индентирование. Под действием заданной силы индентор вдавливается в материал, создавая на его поверхности отпечаток. По форме и размеру отпечатка можно судить о твердости, модуле упругости, пластичности и других свойствах материала. Таким образом, индентирование является универсальным и эффективным методом исследования материалов, позволяющим без разрушения образца получить свойства материалов [3].

В настоящее время в сфере обработки информации приобрели популярность технологии искусственного интеллекта [4]. Согласно исследованию [5], за последние 10 лет данной тематике посвящено более 13 000 научных статей. В течение последних пяти лет наблюдается большой скачок в росте количества публикаций, посвященных применению нейронных сетей для решения широкого рода технических задач, этим и объясняется актуальность данного исследования. Многими исследователями по всему миру активно изучаются и используются нейросетевые технологии [6,7]. Главная способность искусственных нейронных сетей заключается в самостоятельном поиске и выделении признаков, характеризующих входные данные. Нейронные сети способны автоматически определять наиболее важные и информативные признаки для каждой задачи, не требуя предварительного описания [8]. Это делает искусственные нейронные сети

---

универсальными механизмом в сравнении с традиционными алгоритмами [9,10].

Нейронные сети обладают высокой точностью вычислений в задачах классификации материалов. В исследовании Клестова Р.А. и Столбова В.Ю. представлены результаты классификации твердости металлического сплава с помощью двух различных нейронных сетей: ResNet и VGG. Получены достаточно хорошие значения точности классификации, позволяющие использовать нейронную сеть в качестве компонента для комплексной оценки механических свойств материалов [11].

Применительно к процессу индентирования команда ученых в работе [12] продемонстрировала, что искусственные нейронные сети способны извлекать упругопластические свойства металлов и сплавов из результатов инструментального вдавливания. Авторами исследования [13] показано, что нейронные сети могут точно идентифицировать кривые нагрузок и перемещений, полученных в результате индентирования. Результаты данных исследований подчеркивают потенциал нейронных сетей в области анализа материалов.

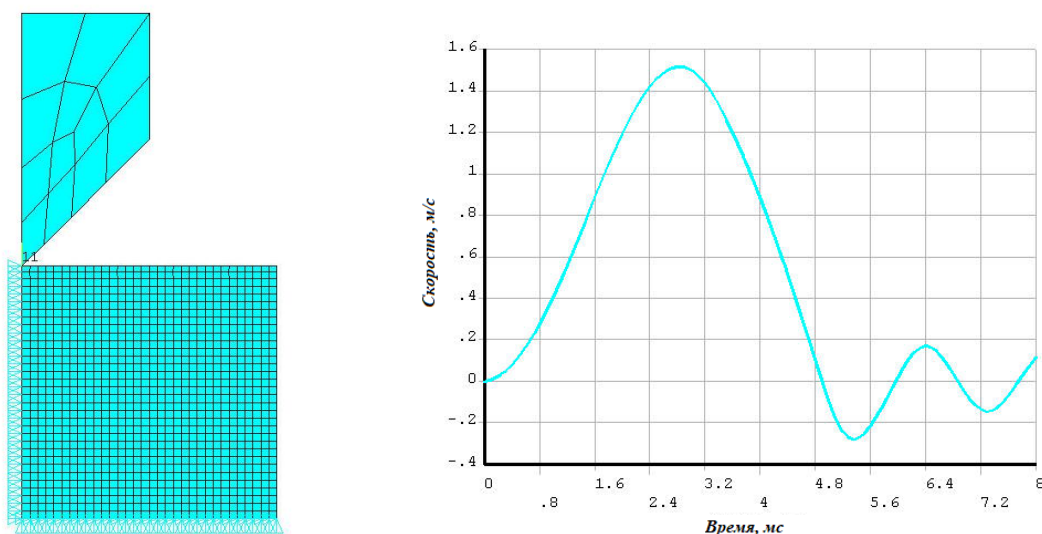
В настоящем исследовании ставится задача определения характерных свойств каждой группы металлов, полученных в результате индентирования нескольких образцов, и на их основе произвести построение классификационной нейронной сети.

Эксперимент проводился с помощью экспериментальной установки динамического нагружения. Описание прибора подробно представлено в работе [14].

Сила реакции  $F(t)$  со стороны материала при ударном воздействии коническим индентором подлежит определению из конечно-элементной модели индентируемого материала (рис. 1). При численных вычислениях используются классические модели, представленные в теории

---

упругопластического деформирования. Для описания поведения материала в области пластичности была выбрана опция мультилинейного изотропного упрочнения (Multilinear Isotropic Hardening, MISO). Данная модель использует критерий пластичности фон Мизеса. Для анализа модели использован пакет МКЭ Ansys.



а) б)  
Рис. 1. – Конечно-элементная модель: а) – сетка конечных элементов;  
б) – Скорость удара индентора, полученная моделью

При работе с конечно-элементной моделью выявлен ряд условий, определяющих устойчивый расчет элементов динамического напряженно-деформированного состояния испытываемого материала и получения достоверных результатов:

1. Необходимость учета нелинейности поведения материала.
2. Обеспечение контроля точности процесса сходимости.
3. Управление размерами сетки конечных элементов.

Данная модель имитирует процесс удара поверхности материала коническим индетором, с помощью которой можно варьировать параметры удара, соблюдая при этом параметры установки.

В ходе эксперимента с применением установки ударного индентирования были получены значения механических характеристик образцов разных металлов. Для дальнейшего анализа с целью изучения поведения материалов при воздействии ударной нагрузки было выбрано пять групп различных материалов: 40X13, 65Г, 08ПС, Л63 и СТ35 (табл. 1).


Таблица № 1

Характеристики групп материалов

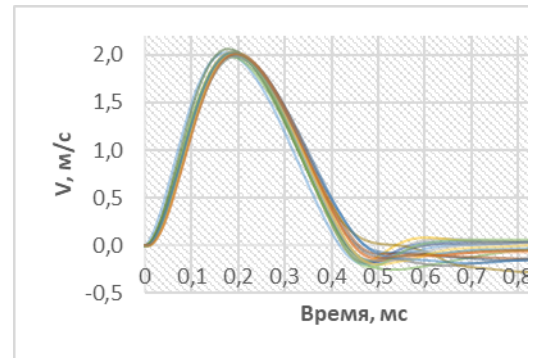
№ группы	I	II	III	IV	V
Материал	40X13	65Г	08ПС	Л63	СТ35
Твердость ( <i>HB</i> ), МПа	143-229	229-285	131-162	120-160	163-187
Предел прочности ( $\sigma_B$ ), МПа	850	900	410	270	700
Предел текучести ( $\sigma_T$ ), МПа	910	440	190	250	300

Рассматриваемые виды металлов имеют сопоставимые механические характеристики, но при этом заметна разница между конкретными показателями. На основе выделенных групп металлов произведена их классификация. В качестве инструмента классификации была выбрана нейронная сеть [15], имеющая полносвязную структуру [16]. Построение нейронной сети осуществлялось с помощью библиотеки для Python – Keras. Нейронная сеть содержит четыре слоя, скрытые слои которой содержат функцию активации ReLU. Исходная выборка данных разделена на обучающее и тестовое множества в соотношении 80 % и 20 %, соответственно, состоит из 100 экспериментальных измерений. Для оценки достоверности экспериментальных данных и увеличения обучающей выборки с помощью математической модели был получен синтетический


набор данных, состоящий из 50 значений. Практическими исследованиями доказано, что применение синтетических данных для обучения нейронной сети способствует ее более быстрому обучению и повышению точности вычислений [17,18].



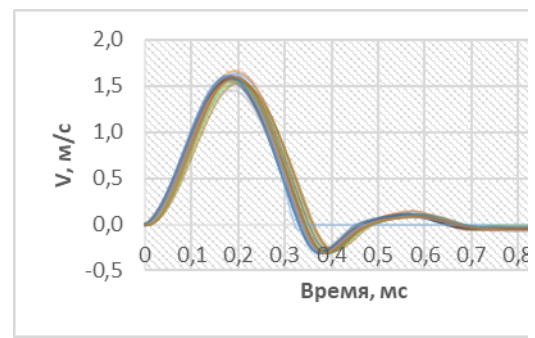
а) Полная выборка




б) Л63




в) 40X13



г) 65Г



д) 08ПС



е) СТ35

Рис. 2. – Набор для обучения нейронной сети

Для обучения нейронной сети определен наиболее информативный параметр: скорость проникновения индентора в материал. На рис. 2

представлен набор экспериментальных данных, используемый для обучения нейронной сети. Предварительно проведена статистическая оценка выборки, определены числовые характеристики, математическое ожидание, дисперсия, которые свидетельствуют о достаточно высокой степени взаимосвязи данных.

Результаты обучения показали, что нейросеть способна с точностью до 95 % определять принадлежность материала к классификационной группе. На рис. 3 представлены результаты вычислений нейронной сети по каждой группе металлов. Из гистограммы видно, что материал 65Г имеет самый низкий уровень классификации. В ходе исследования было выяснено, что это связано с погрешностью проведения эксперимента.

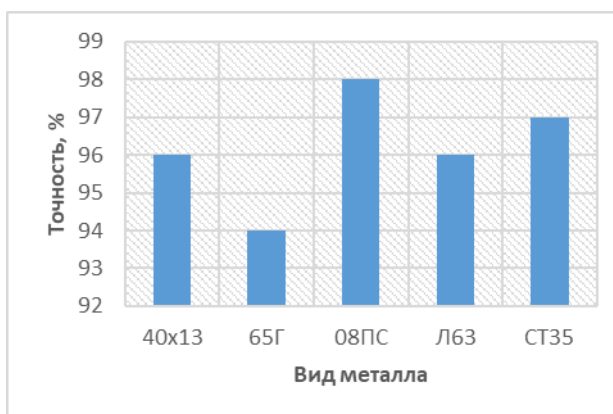


Рис. 3. – Результаты работы нейронной сети по каждой классификационной группе

Исходя из данных рис. 3, можно утверждать, что в рамках рассматриваемой задачи нейронная сеть показывает высокие и точные результаты вычислений. Для оценки ошибок работы нейронной сети выбрана функция потерь MSE (среднеквадратичная ошибка).

Результаты функции потерь нейронной сети (рис. 4) позволяют судить о быстром процессе приближения данных к эталонным значениям.

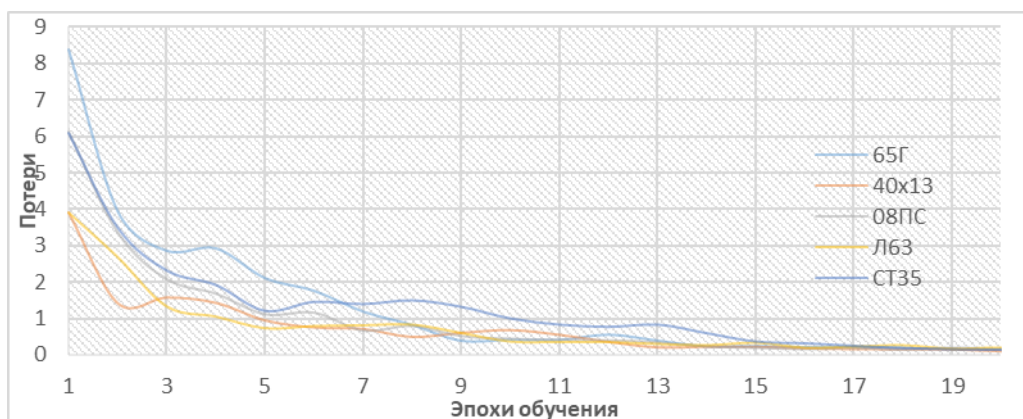


Рис. 4. – Функция потерь НС

Таким образом, в данной статье был представлен подход к определению типа материала с использованием нейронной сети. Экспериментальным методом доказано, что нейронные сети позволяют с высокой точностью классифицировать материалы по группам на основе динамических характеристик процесса индентирования. В рамках работы исследованы процессы обучения и анализа точности работы нейронной сети, демонстрирующие хорошие результаты на тестовых данных.

Было обнаружено, что возникающие в данных шумы, вызванные условиями проведения эксперимента, могут существенно снижать точность работы нейронной сети. В этом случае предложено развитие подхода в направлении получения более чистых экспериментальных данных за счет предварительной цифровой обработки сигналов, увеличения размера набора данных как экспериментальных, так и синтезированных моделью, и количества типов материалов для расширения классифицируемых категорий.

### Литература

1. Пачурин Г.В. Исследование механических свойств конструкционных материалов в разных эксплуатационных условиях: учебное пособие / Г. В. Пачурин; под общ. ред. Г.В. Пачурина. - 2-е изд., испр. и доп. - Москва; Вологда: Инфра-Инженерия, 2022. - 148 с.



2. Горбунова Т.С. Измерения, испытания и контроль. Методы и средства: учебное пособие / Т.С. Горбунова. – Казань, КНИТУ, 2012. – 117 с.
  3. Скотникова М.А., Попов А.А., Иванова Г.В., Цветкова Г.В. Исследование свойств поверхности сплавов с помощью инструментального индентирования // Изв. вузов. Приборостроение. 2020. Т. 63, № 5. С. 460-466. URL: [doi.org/10.17586/0021-3454-2020-63-5-460-466](https://doi.org/10.17586/0021-3454-2020-63-5-460-466)
  4. Banitaan Shadi, Al-refai Ghaith, Almatarneh Sattam, Alquran Hebah. A Review on Artificial Intelligence in the Context of Industry 4.0. International Journal of Advanced Computer Science and Applications, 14(2). 2023. URL: [doi.org/10.14569/IJACSA.2023.0140204](https://doi.org/10.14569/IJACSA.2023.0140204)
  5. Lin Keng-Yu, Chang Kuei-Hu Artificial Intelligence and Information Processing: A Systematic Literature Review, Mathematics, MDPI, 2023. vol. 11(11), pages 1-20, May. URL: [doi.org/10.3390/math11112420](https://doi.org/10.3390/math11112420)
  6. Gibadullin R.F., Lekomtsev D.V., Perukhin M.Y. Analysis of Industrial Network Parameters Using Neural Network Processing. Scientific and Technical Information Processing. 2021. 48. Pp. 446–451. URL: [doi.org/10.3103/S0147688221060046](https://doi.org/10.3103/S0147688221060046)
  7. Villarrubia Gabriel, De Paz Juan F., Chamoso Pablo, De la Prieta Fernando. Artificial neural networks used in optimization problems, Neurocomputing. V. 272, 2018, pp. 10-16. URL: [doi.org/10.1016/j.neucom.2017.04.075](https://doi.org/10.1016/j.neucom.2017.04.075)
  8. Fedorenko Y.S., Gapanyuk Y.E. Multilevel neural net adaptive models using the metagraph approach. Optical Memory and Neural Networks. 2016. № 25, Pp. 228–235. URL: [doi.org/10.3103/S1060992X16040020](https://doi.org/10.3103/S1060992X16040020)
  9. Lotfi E., Rezaee A.A. A competitive functional link artificial neural network as a universal approximator. Soft Computing. 2018. № 22. Pp. 4613–4625. URL: [doi.org/10.1007/s00500-017-2644-1](https://doi.org/10.1007/s00500-017-2644-1)
-

10. Faouzi J., Colliot O. (2023). Classic Machine Learning Methods. In: Colliot, O. (eds) Machine Learning for Brain Disorders. Neuromethods. 2023. № 197. New York, NY. Pp. 25-75. URL: [doi.org/10.1007/978-1-0716-3195-9\\_2](https://doi.org/10.1007/978-1-0716-3195-9_2)
  11. Клестов Р.А. Сравнение моделей классификации на основе нейронных сетей глубокого обучения Resnet и VGG8 / Р. А. Клестов, В. Ю. Столбов // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: Сборник статей по материалам Четвертой всероссийской научно-практической конференции, проводимой в рамках Пермского естественнонаучного форума «Математика и глобальные вызовы XXI века», Пермь, 21–23 мая 2019 года. Том Часть I. – Пермь: Пермский государственный национальный исследовательский университет, 2019. – С. 50-56.
  12. Lu Lu, Dao Ming, Kumar Punit, Ramamurty Upadrasta, Em Karniadakis George, Suresh Subra «Extraction of mechanical properties of materials through deep learning from instrumented indentation» Proceedings of the National Academy of Sciences of the United States of America. 2020. 117. Pp. 7052-7062.
  13. Kossman S, Bigerelle M. Pop-In Identification in Nanoindentation Curves with Deep Learning Algorithms. Materials. 2021; 14(22):7027. URL: [doi.org/10.3390/ma14227027](https://doi.org/10.3390/ma14227027)
  14. Бескопыльный А.Н., Веремеенко А.А., Копылов Ф.С., Крымский В.С. Задача о статическом внедрении конического индентора в область с поверхностным упрочнением // Инженерный вестник Дона. 2018. №2. URL: [ivdon.ru/ru/magazine/archive/ny2018/4720](http://ivdon.ru/ru/magazine/archive/ny2018/4720)
  15. Beskopylny A, Lyapin A, Anysz H, Meskhi B, Veremeenko A, Mozgovoy A. Artificial Neural Networks in Classification of Steel Grades Based on Non-Destructive Tests. Materials (Basel). 2020 May 27;13(11):2445. URL: [doi: 10.3390/ma13112445](https://doi.org/10.3390/ma13112445).
-

16. Babushkina N. Solving the problem of classification of material properties using a neural network / N. Babushkina, A. Lyapin // Journal of Physics Conference Series 2131(3):032084, 2021. URL: doi: 10.1088/1742-6596/2131/3/032084

17. Бабушкина Н.Е., Ляпин А.А. Сравнительный анализ использования нейронной сети в задаче идентификационных свойств материалов // Инженерный вестник Дона. 2021. №11. URL: ivdon.ru/ru/magazine/archive/n11y2021/7305

18. Пчелинцев С.Ю., Ляшков М.А., Ковалева О.А. Метод создания синтетических наборов данных для обучения нейросетевых моделей распознаванию объектов. Информационно-управляющие системы, 2022, № 3, с. 9–19. doi :10.31799/1684-8853-2022-3-9-19

19. Парасич А.В., Парасич В.А., Парасич И.В. Формирование обучающей выборки в задачах машинного обучения. Обзор. Информационно-управляющие системы, 2021, № 4, с. 61–70. doi: 10.31799/1684-8853-2021-4-61-70

### References

1. Pachurin, G.V. Uchebnoe posobie. 2-e izd. Moskva; Vologda: Infra-Inzhenerija. 2022. 148 P.

2. Gorbunova T.S. Uchebnoe posobie. Kazan', KNITU. 2012. 117 P.

3. Skotnikova M.A., Popov A.A., Ivanova G.V., Cvetkova G.V. Izvestiya vuzov. Priborostroenie. 2020. 63, №5. Pp. 460-466. URL: doi.org/10.17586/0021-3454-2020-63-5-460-466

4. Banitaan Shadi, Al-refai Ghaith, Almatarneh Sattam, Alquran Hebah. International Journal of Advanced Computer Science and Applications, 14(2). 2023. URL: doi.org/10.14569/IJACSA.2023.0140204

5. Lin Keng-Yu, Chang Kuei-Hu. Mathematics, MDPI, 2023. vol. 11(11), Pp. 1-20. URL: doi.org/10.3390/math11112420

6. Gibadullin R.F., Lekomtsev D.V., Perukhin M.Y. Scientific and Technical Information Processing. 2021. 48. Pp. 446–451. URL: [doi.org/10.3103/S0147688221060046](https://doi.org/10.3103/S0147688221060046)
7. Villarrubia Gabriel, De Paz Juan F., Chamoso Pablo, De la Prieta Fernando. Neurocomputing. 2018. № 272, Pp. 10-16. URL: [doi.org/10.1016/j.neucom.2017.04.075](https://doi.org/10.1016/j.neucom.2017.04.075)
8. Fedorenko Y.S., Gapanyuk Y.E. Optical Memory and Neural Networks. 2016. № 25, Pp. 228–235. URL: [doi.org/10.3103/S1060992X16040020](https://doi.org/10.3103/S1060992X16040020)
9. Lotfi E., Rezaee A.A.. Soft Computing. 2018. № 22. Pp. 4613–4625. URL: [doi.org/10.1007/s00500-017-2644-1](https://doi.org/10.1007/s00500-017-2644-1)
10. Faouzi J., Colliot O. Neuromethods. 2023. № 197. New York, NY. Pp. 25-75. URL: [doi.org/10.1007/978-1-0716-3195-9\\_2](https://doi.org/10.1007/978-1-0716-3195-9_2)
11. Klestov R.A. Iskusstvennyj intellekt v reshenii aktual'nyh social'nyh i jekonomicheskikh problem HHI veka: Sbornik statej po materialam Chetvertoj vsrossijskoj nauchno-prakticheskoy konferencii, provodimoj v ramkah Permskogo estestvennonauchnogo foruma «Matematika i global'nye vyzovy XXI veka». 2019. Pp. 50-56.
12. Lu Lu, Dao Ming, Kumar Punit, Ramamurty Upadrasta, Em Karniadakis George, Suresh Subra. Proceedings of the National Academy of Sciences of the United States of America. 2020. 117. Pp. 7052-7062. URL: [doi.org/10.1073/pnas.1922210117](https://doi.org/10.1073/pnas.1922210117)
13. Kossman S, Bigerelle M. Materials. 2021; 14(22):7027. URL: [doi.org/10.3390/ma14227027](https://doi.org/10.3390/ma14227027)
14. Beskopyl'nyj A.N., Veremeenko A.A., Kopylov F.S., Krymskij V.S. Inzhenernyj vestnik Dona. 2018. № 2. URL: [ivdon.ru/ru/magazine/archive/ny2018/4720](https://ivdon.ru/ru/magazine/archive/ny2018/4720).



15. Beskopylny A, Lyapin A, Anysz H, Meskhi B, Veremeenko A, Mozgovoy A. Materials (Basel). 2020. 27;13(11):2445. URL: doi: 10.3390/ma13112445.
16. Babushkina N. Journal of Physics Conference Series. 2021. 2131(3):032084. URL: doi: 10.1088/1742-6596/2131/3/032084.
17. Babushkina N.E., Lyapin A.A. Inzhenernyj vestnik Dona. 2021. № 11. URL: ivdon.ru/ru/magazine/archive/n11y2021/7305.
18. Pchelincev S.Ju., Ljashkov M.A., Kovaleva O.A. Informacionno-upravljajushhie sistemy. 2022. № 3, Pp. 9–19. doi: 10.31799/1684-8853-2022-3-9-19
19. Parasich A.V., Parasich V.A., Parasich I.V. Informacionno-upravljajushhie sistemy. 2021. № 4. Pp. 61–70. doi: 10.31799/1684-8853-2021-4-61-70

**Дата поступления: 15.03.2024**

**Дата публикации: 16.04.2024**