

8. СHerkasskij, B. L. Listerioz / B. L. СHerkasskij, YU. A. Il'inskij // Rukovodstvo po zoonozam. – Moskva, 1983. – S. 179-184.
9. СHerkasskij, B. L. Epidemiologicheskij nadzor za zoonozami / B. L. СHerkasskij, S. N. Amireev, A. G. Knop. – Alma-Ata, 1988. – 157 s.
10. Epidemiologiya i profilaktika listerioza. Metodicheskie ukazaniya. MU 3.1.7.1104-02 (utv. Glavnym gosudarstvennym sanitarnym vrachom RF 27.01.2002)
11. Agnieszka Chlebicz, Katarzyna 'Sli' zewska. Campylobacteriosis, Salmonellosis, Yersiniosis, and Listeriosis as Zoonotic Foodborne Diseases: A Review. Int. J. Environ. Res. Public Health 2018, Received: 4 April 2018; Accepted: 24 April 2018; Published: 26 April 2018.
12. Evans Jacquelyn R., Allen Alexander C. et al. Perinatal listeriosis: report of an outbreak // Pediat. infec. Disease. -1985. -V.4. - № 3. - P.237–241.
13. Jansen W, Müller A, Grabowski NT, Kehrenberg C, Muylkens B, Al Dahouk S. Foodborne diseases do not respect borders: Zoonotic pathogens and antimicrobial resistant bacteria in food products of animal origin illegally imported into the European Union. Vet J. 2019 Feb; 244:75-82. doi: 10.1016/j.tvjl.2018.12.009. Epub 2018 Dec 12.
14. Mead P.S., Slutsker L., Dietz V., et al. Food-related illness and death in the United States. Emerging Infect Dis 1999; 5:607-26.

Information about authors

1. **Alexandrova Yana Rashitovna**, post-graduate student, All-Russian Scientific Research Institute of the Poultry Processing Industry – branch of the Federal Scientific Center All-Russian Scientific Research and Technological Institute of Poultry Farming of the Russian Academy of Sciences; 141552, Moscow region, Solnechnogorsk, Rzhavki, b. 1; e-mail: yana-mail@mail.ru, tel. +79688899598;

2. **Kozak Sergey Stepanovich**, Doctor of Biological Sciences, Chief Researcher, Head of the Research and Development Center of the All-Russian Scientific Research Institute of the Poultry Processing Industry – branch of the Federal Scientific Center All-Russian Scientific Research and Technological Institute of Poultry Farming of the Russian Academy of Sciences; 141552, Moscow region, Solnechnogorsk, Rzhavki, b. 1; e-mail: viipkozak@gmail.com, tel. +7(499)1102804;

3. **Baranovich Evgenia Sergeevna**, Candidate of Veterinary Sciences, Associate Professor of the Department of Morphology and Veterinary and Sanitary Expertise of the Institute of Zootechnics and Biology, RSAU-MAA named after K.A. Timiryazev; 127550 Moscow, st. Timiryazevskaya, 49, Russian Federation; e-mail: ebaranovich@rgau-msha.ru; +7(499)9763444;

4. **Kozak Yulia Aleksandrovna**, Candidate of Veterinary Sciences, Senior Lecturer of the Department of Morphology and Veterinary and Sanitary Expertise of the Institute of Zootechnics and Biology, RSAU-MAA named after K.A. Timiryazev; 127550 Moscow, st. Timiryazevskaya, 49, Russian Federation; e-mail: kozak@rgau-msha.ru, tel. +7(499)9763444.

УДК 619:637.12

DOI:

К ВЫБОРУ МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ДЕТЕКТИРОВАНИЯ ФОРМЕННЫХ ЭЛЕМЕНТОВ КРОВИ СЕЛЬСКОХОЗЯЙСТВЕННЫХ ЖИВОТНЫХ

**А. И. Димитриева, А. П. Попов, А. В. Коваленко, В. А. Андреев, Н. Н. Белова, О. Г. Васильева,
А. В. Степанов**

*Чувашский государственный аграрный университет
428003, Чебоксары, Российская Федерация*

Аннотация. Внедрение алгоритмов машинного обучения в ветеринарную лабораторную диагностику в сельском хозяйстве позволяет решить нехватку специалистов в отрасли, увеличивает уровень автоматизации объектов сельского хозяйства. В связи с этим, в отрасли возможна замена времязатратных методик ручной микроскопии мазка крови. В рамках настоящего исследования с использованием автоматизированной фотофиксации микроскопических изображений мазка крови собрана база данных. Изображения аннотированы с помощью ручной и полуавтоматической процедуры разметки в системе Supervise.ly. При аннотации использовано 9 классов объектов, представляющих собой форменные элементы крови крупного рогатого скота. Полученная база данных сохранена в системе управления базами данных CouchDB. Методом машинного зрения и машинного обучения с учителем проведено обучение искусственной нейронной сети в рамках 8 моделей, основанных на открытой архитектуре Yolov8, максимальная точность классификации форменных элементов крови крупного рогатого скота составила 96%. Обучение нейронной сети контролировалось по 9 основным показателям и нескольким производным зависимостям. К основным показателям относились: точность, специфичность, чувствительность, F1-мера, логарифмическая функция

потерь и др. В качестве аппаратной платформы, на которой происходило обучение, использовалась рабочая станция с центральным процессором Intel Core i7, видеокартой Tesla V100, объем задействованной оперативной памяти до 64 Гб. Среднее время детектирования на моделях с малым числом параметров (до 22 млн) составило 2-3 мс на одно изображение. Полученные результаты применимы при создании системы поддержки принятия решений на основе алгоритмов дерева решений.

Ключевые слова: машинное обучение, искусственная нейронная сеть, форменный элемент крови, база данных, машинное зрение, крупный рогатый скот.

Введение. В сельском хозяйстве на сегодняшний день активно внедряются современные методы лабораторной диагностики. Основное назначение лабораторной диагностики – подтверждение, уточнение диагноза, причин возникновения заболевания, выбора методов лечения, разработка плана лечения, а так же контроль результатов терапии.

Автоматизация трудоемких, времязатратных лабораторных методик диагностики заболеваний – актуальная задача, как медицины человека, так и ветеринарной медицины на текущем этапе ее развития, среди них микроскопия мазка крови, цитология, гистология, флуоресцентная микроскопия, в том числе и сверхвысокого разрешения.

Системы автоматизированной микроскопии с использованием алгоритмов машинного обучения и машинного зрения особенно широко применяются в медицине человека [6, 7], в ветеринарной лабораторной диагностике, но в особенности в сельском хозяйстве они распространены значительно меньше. На сегодняшний день задача разработки внедрения соответствующих цифровых методов в практику ветеринарной лабораторной диагностики особенно актуальна в связи с недостатком квалифицированных кадров, как в отрасли в целом по стране, так и зарубежом. Таким образом, разработка систем автоматизированной микроскопии для диагностики крови животных носит стратегический характер и необходима для развития отрасли и страны в целом.

Материалы и методы исследования. Для отработки алгоритмов собиралась база данных микрофотографий клеток крови крупнорогатого скота (КРС) [5], она представлена в виде изображений, полученных с микроскопа и масок объектов, полученных с помощью средств разметки. Разметка изображений происходила с помощью открытых инструментов на основе API платформ Supervise.ly [12] и Nasty.AI [13]. Основной метод разметки основан на экспертном мнении команды разметки и сравнении с атласами клеток крови [4]. База данных собиралась на NoSQL системе управления базами данных (СУБД) CouchDB, ее объем составил 214,95 Мб. Для разметки объектов – форменных элементов крови на изображении, применялись 9 классов. Статистика по базе данных размеченных классов объектов за время выполнения данной части НИОКР представлена в таблице 1.

Таблица 1 – Название классов объектов на микрофотографиях мазка крови

Тип объекта	Количество
WBC_LYM	15238
WBC_NEU	776
WBC_EOS	246
artifact	4541
RBC_normal	5515
PLT	8204
WBC_MON	24
RBC_piroplasm	5227
WBC_BAS	23

Скриншоты процесса разметки базы изображений приведены на рис. 1. Каждая из клеток выделяется в прямоугольник или многоугольник и снабжается меткой класса, соответствующей типу клетки.




Рис. 1. Разметка объектов на микрофотографии толстого мазка крови КРС.

В качестве архитектуры нейронной сети были исследованы 8 моделей [3, 8, 9], построенные на архитектуре Yolo v5. Их основные данные сведены в таблице 2. Обучение нейронной сети происходило на рабочей станции с центральным процессором Intel Core i7, видеокартой Tesla V100, объем задействованной оперативной памяти до 64 Гб.

Таблица 2 – Модели, исследованные в данной работе

Модель	Размер изображения (пикселей)	Скорость на Tesla V100 (мс)	Параметры (млн)	FLOPS 640 (млрд)
Model 1	640	2	7.3	17
Model 2	640	2.7	21.4	51.3
Model 3	640	3.8	47	115.4
Model 4	640	6.1	87.7	218.8
Model 5	1280	4.3	12.7	17.4
Model 6	1280	8.4	35.9	52.4
Model 7	1280	12.3	77.2	117.7
Model 8	1280	22.4	141.8	222.9

Результаты исследований и их обсуждение. Результаты обучения нейронной сети не сильно отличаются от модели к модели, так, в самой первой модели с минимальным числом параметров из представленных точность предсказаний оказалась примерно на том же уровне, что и на последней модели с максимальным числом параметров из представленных (рисунок 2).



Рис. 2. Результаты обучения модели 1 в течение 15 эпох

Результат обучения показал и следующие характеристики, на основе которых вычисляются метрики машинного обучения, количество: True Positive (TP) – истинно-положительно определенных объектов; False Positive (FP) – ложно-положительно определенных объектов; False Negative (FN) – ложно-отрицательно определенных объектов; True Negative (TN) – истинно-отрицательно определенных объектов.

Основные метрики машинного обучения, использованные при обучении нейронной сети:

Точность - доля правильных ответов алгоритма

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Точность - доля объектов, обозначенных классификатором верными и при этом действительно являющимися верными

$$precision = \frac{TP}{TP + FP} \quad (2)$$

Чувствительность (recall) определяет, какую долю объектов класса алгоритм нашел как верные из всех верных объектов класса

$$recall = \frac{TP}{TP + FN} \quad (3)$$

Специфичность - указывает долю ложных результатов, которые правильно указаны алгоритмом

$$specifity = \frac{TN}{TN + FP} \quad (4)$$

Negative Predictive Value -

$$NPV = \frac{TN}{TN + FN} \quad (5)$$

F-мера (в общем случае β) – среднее гармоническое от значений точности (precision) и чувствительности (recall)

$$F_{\beta} = (1 + \beta^2) \cdot \frac{precision \cdot recall}{\beta^2 \cdot precision + recall} \quad (6)$$

Общая оценка модели возможна при использовании метрики AUC-ROC (или ROC AUC) – площадь (Area Under Curve) под кривой ошибок (Receiver Operating Characteristic curve). Данная кривая представляет из себя линию от (0,0) до (1,1) в координатах True Positive Rate (TPR) – (7) и False Positive Rate (FPR) – (8):

$$TPR = \frac{TP}{TP + FN} \quad (7)$$

$$FPR = \frac{FP}{FP + TN} \quad (8)$$

Логистическая функция потерь задается как:

$$\log loss = -\frac{1}{l} \cdot \sum_{i=1}^l (y_i \cdot \lg(\hat{y}_i) + (1 - y_i) \cdot \lg(1 - \hat{y}_i)), \quad (9)$$

где \hat{y}_i – это ответ алгоритма на i -ом объекте, y – истинная метка класса на i -ом объекте, а l – размер выборки.

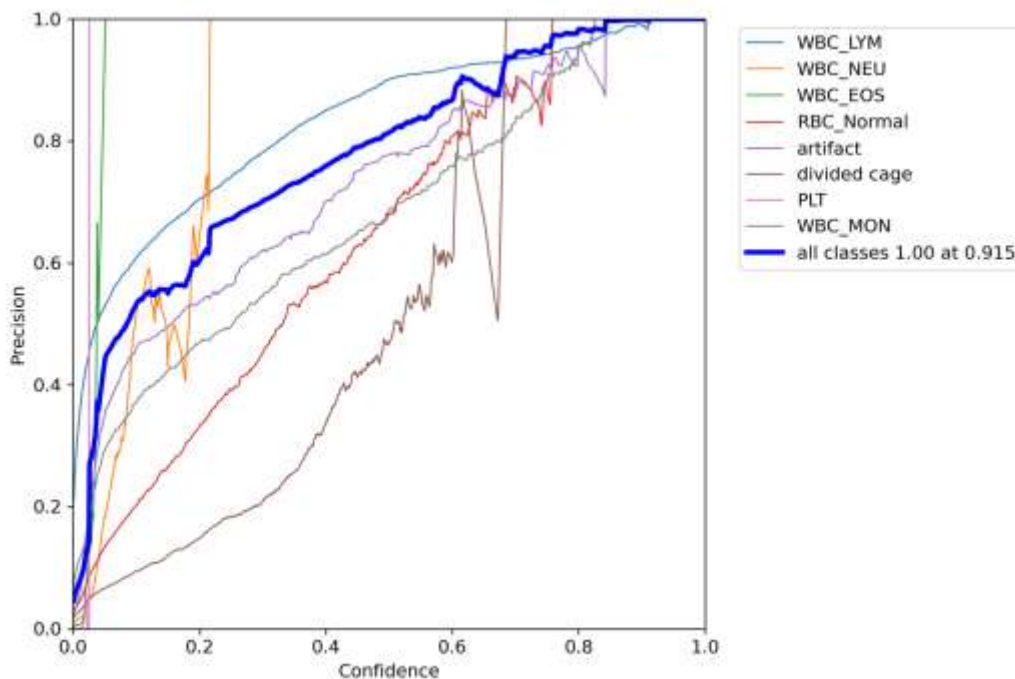


Рис. 3. Р-кривая, кривая точности для каждого из классов, детектируемых объектов




Рис. 4. Кривая чувствительности для каждого из классов, детектируемых объектов

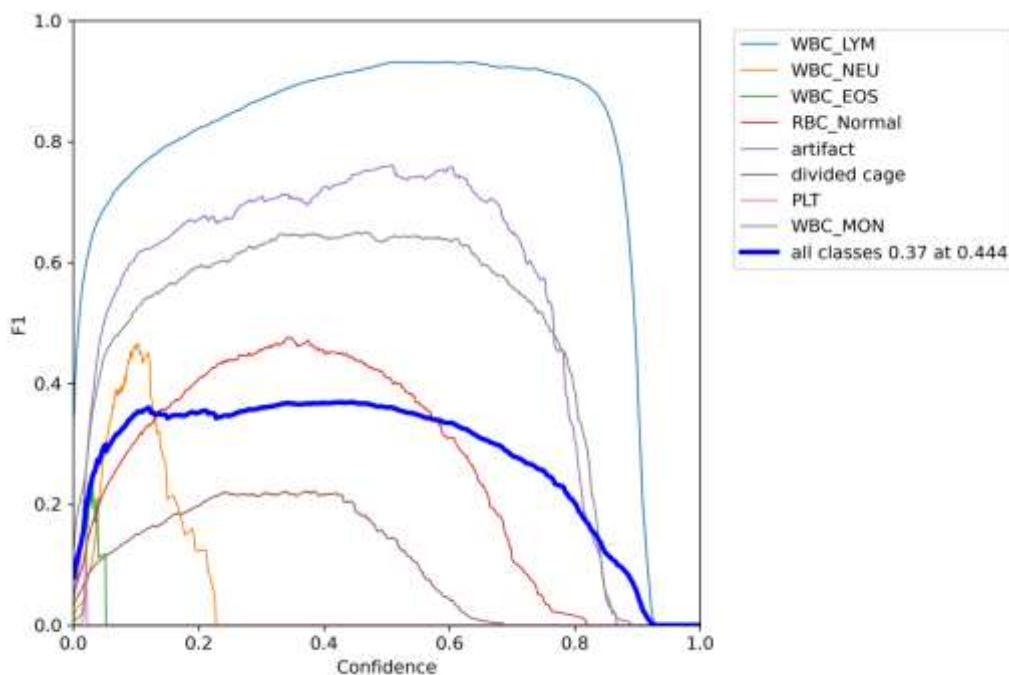


Рис. 5. F1-кривая для каждого из классов, детектируемых объектов

Наилучшие значения, полученные по результатам обучения нейронной сети: точность: $accuracy=96\%$, $precision=96\%$, $recall=88\%$, $F1\text{-мера}=95\%$.

Полученные модели могут быть использованы в лабораторной диагностике [10, 11] с применением системы поддержки принятия решений [1, 2] на основе деревьев решений.

Выводы. В результате исследования 8 моделей глубоких нейронных сетей установили, что лучшие показатели по 8 классам объектов при классификации изображений находятся на уровне 96% точности и 88% чувствительности.

Полученные данные позволяют использовать указанные модели машинного обучения для построения системы поддержки принятия решений на основе деревьев решений.

Литература

- ГОСТ 34.603-92 Информационная технология. Виды испытаний автоматизированных систем: утвержден и введен в действие Постановлением Комитета стандартизации и метрологии СССР от 17.02.92 N 161: дата введения 1993-01-01. – Москва : Стандартинформ, 2009.
- ГОСТ Р 56920-2016/ISO/IEC/IEEE 29119-1:2013 Системная и программная инженерия. Тестирование программного обеспечения. Часть 1. Понятия и определения: утвержден и введен в действие Приказом Федерального агентства по техническому регулированию и метрологии от 18 мая 2016 г. N 331-ст : дата введения 2017-06-01. – Москва : Стандартинформ, 2016. – 22 с.
- ГОСТ Р ИСО/МЭК 20546-2019 Большие данные: утвержден и введен в действие Приказом Федерального агентства по техническому регулированию и метрологии. – Москва : Стандартинформ, 2020. – 30 с.
- Атлас ветеринарной гематологии / В. Д. Риган, Т. Г. Сандерс, Д. Б. Деникола: Аквариум-Принт, 2014.
- Свидетельство о государственной регистрации базы данных № 2022623713 Российская Федерация. База данных для машинного обучения системы поддержки принятия врачебных решений и постановки диагноза «лейкоз» на основе анализа крови сельскохозяйственных животных : № 2022623796: заявл. 16.12.2022: опубл. 27.12.2022 / А. П. Попов, А. В. Коваленко, Ю. А. Кислицина [и др.] ; заявитель Федеральное государственное бюджетное образовательное учреждение высшего образования «Чувашский государственный аграрный университет», Федеральное государственное бюджетное образовательное учреждение высшего образования «Саратовский государственный университет генетики, биотехнологии и инженерии имени Н.И. Вавилова», 2022.
- Структура комплекса автоматической микроскопии МЕКОС-Ц2 и методики его испытаний / В. С. Медовый, А. А. Парпара, А. М. Пятницкий [и др.] // Медицинская техника. – 2006. – № 4. – С. 36-41.
- Swolin B, Simonsson P, Backman S, Löfqvist I, Bredin I, Johnsson M. Differential counting of blood leukocytes using automated microscopy and a decision support system based on artificial neural networks--evaluation of DiffMaster Octavia // Clin Lab Haematol. – Vol. 25. – 3 -, 2003. – P. 139-47. doi: 10.1046/j.1365-2257.2003.00516.x.

8. Paszke A., Gross S., Massa F., Lerer A., Bradbury J., Chanan G., Chintala S. PyTorch: An Imperative Style, High-Performance Deep Learning Library // Advances in Neural Information Processing Systems. – 2019. – Vol. 32. – P. 8024–8035.
9. Deep Learning. / Goodfellow I., Bengio Y., Courville A.: MIT Press, 2016. – 800 p.
10. OIE Terrestrial Manual 2018. - URL: <https://www.oie.int/en/what-we-do/standards/codes-and-manuals/terrestrial-manual-online-access/> (дата обращения 10.08.2021).
11. Gardner IA, Colling A, Caraguel C, Crowther JR, Jones G, Firestone SM, Heuer C. Introduction - Validation of tests for OIE-listed diseases as fit-for-purpose in a world of evolving diagnostic technologies // Rev Sci Tech. – Vol. 40 – 1 –, 2021. – P. 19-28. doi: 10.20506/rst.40.1.3207.
12. Supervisely. - URL: <https://supervisely.ly/> (дата обращения 10.02.2023).
13. Hasty. - URL: <https://hasty.ai/> (дата обращения 10.02.2023).

Сведения об авторах

1. **Димитриева Анастасия Ивановна**, кандидат ветеринарных наук, доцент, доцент кафедры эпизоотологии, паразитологии и ветеринарно-санитарной экспертизы, Чувашский государственный аграрный университет; 428003, г. Чебоксары, ул. К. Маркса, 29, Чувашская Республика, Россия; e-mail: nastena_dim@mail.ru;
2. **Попов Александр Петрович**, ассистент кафедры эпизоотологии, паразитологии и ветеринарно-санитарной экспертизы, Чувашский государственный аграрный университет; 428003, г. Чебоксары, ул. К. Маркса, 29, Чувашская Республика, Россия; e-mail: popovaleksandr.petrovich@yandex.ru;
3. **Коваленко Алёна Витальевна**, аспирант кафедры морфологии, акушерства и терапии, Чувашский государственный аграрный университет; 428003, г. Чебоксары, ул. К. Маркса, 29, Чувашская Республика, Россия; e-mail: kovalenkoa15051998@gmail.com;
4. **Андреев Владимир Александрович**, старший преподаватель кафедры математики, физики и информационных технологий; Чувашский государственный аграрный университет; 428003, г. Чебоксары, ул. К. Маркса, 29, Чувашская Республика, Россия; e-mail: aiwoland7@rambler.ru;
5. **Белова Надежда Николаевна**, кандидат технических наук, доцент, доцент кафедры математики, физики и информационных технологий, Чувашский государственный аграрный университет; 428003, г. Чебоксары, ул. К. Маркса, 29, Чувашская Республика, Россия; e-mail: bnn.belova@yandex.ru;
6. **Васильева Ольга Геннадьевна**, кандидат экономических наук, доцент, доцент кафедры математики, физики и информационных технологий, Чувашский государственный аграрный университет; 428003, г. Чебоксары, ул. К. Маркса, 29, Чувашская Республика, Россия; e-mail: olech.vasiljeva@yandex.ru;
7. **Степанов Антон Викторович**, кандидат физико-математических наук, доцент, доцент кафедры математики, физики и информационных технологий, Чувашский государственный аграрный университет; 428003, г. Чебоксары, ул. К. Маркса, 29, Чувашская Республика, Россия; e-mail: for.anton_step@mail.ru, тел. 8(352)62-23-34 доп. 155.

ON THE CHOICE OF A MACHINE LEARNING MODEL FOR DETECTING FORMED BLOOD CELLS IN FARM ANIMALS

A. I. Dimitrieva, A. P. Popov, A. V. Kovalenko, V. A. Andreev, N. N. Belova, O. G. Vasilieva, A. V. Stepanov
Chuvash State Agrarian University
 428003, Cheboksary, Russian Federation

Abstract. *The introduction of machine learning algorithms in veterinary laboratory diagnostics in agriculture allows to solve the shortage of specialists in the industry, increases the level of automation of agricultural facilities. In this regard, the industry can replace the time-consuming methods of manual blood smear microscopy. In the framework of this study, a database was collected using automated photofixation of microscopic images of a blood smear. The images are annotated using manual and semi-automatic tagging procedures in the Supervise.ly system. When annotating, 9 classes of objects were used, which are blood cells of cattle. The resulting database is stored in the CouchDB database management system. Using the method of machine vision and machine learning with a teacher, an artificial neural network was trained within 8 models based on the open architecture Yolov8, the maximum accuracy of classifying blood cells in cattle was 96%. The training of the neural network was controlled by 9 main indicators and several derived dependencies. The main indicators included: accuracy, specificity, sensitivity, F1-measure, logarithmic loss function, etc. As the hardware platform on which the training took place, we used a workstation with an Intel Core i7 central processor, a Tesla V100 video card, the amount of RAM used was up to 64 GB. The average detection time on models with a small number of parameters (up to 22 million) was 2–3 mc per image. The results obtained are applicable in creating a decision support system based on decision tree algorithms.*

Key words: *machine learning, artificial neural network, blood cell, database, machine vision, cattle.*

References

1. GOST 34.603-92 Informacionnaya tekhnologiya. Vidy ispytaniy avtomatizirovannyh sistem : utverzhen i vveden v dejstvie Postanovleniem Komiteta standartizacii i metrologii SSSR ot 17.02.92 N 161: data vvedeniya 1993-01-01. – Moskva : Standartinform, 2009.
2. GOST R 56920-2016/ISO/IEC/IEEE 29119-1:2013 Sistemnaya i programmaya inzheneriya. Testirovanie programmogo obespecheniya. CHast' 1. Ponyatiya i opredeleniya: utverzhen i vveden v dejstvie Prikazom Federal'nogo agentstva po tekhnicheskomu regulirovaniyu i metrologii ot 18 maya 2016 g. N 331-st : data vvedeniya 2017-06-01. – Moskva : Standartinform, 2016. – 22 s.
3. GOST R ISO/MEK 20546-2019 Bol'shie dannye : utverzhen i vveden v dejstvie Prikazom Federal'nogo agentstva po tekhnicheskomu regulirovaniyu i metrologii. – Moskva : Standartinform, 2020. – 30 s.
4. Atlas veterinarnoj gematologii / V. D. Rigan, T. G. Sanders, D. B. Denikola: Akvarium-Print, 2014.
5. Svidetel'stvo o gosudarstvennoj registracii bazy dannyh № 2022623713 Rossijskaya Federaciya. Baza dannyh dlya mashinnogo obucheniya sistemy podderzhki prinyatiya vrachebnyh reshenij i postanovki diagnoza «lejkoz» na osnove analiza krovi sel'skokozyajstvennyh zhivotnyh : № 2022623796 : zayavl. 16.12.2022 : opubl. 27.12.2022 / A. P. Popov, A. V. Kovalenko, YU. A. Kislicina [i dr.] ; zayavitel' Federal'noe gosudarstvennoe byudzhethoe obrazovatel'noe uchrezhdenie vysshego obrazovaniya «CHuvashskij gosudarstvennyj agrarnyj universitet», Federal'noe gosudarstvennoe byudzhethoe obrazovatel'noe uchrezhdenie vysshego obrazovaniya «Saratovskij gosudarstvennyj universitet genetiki, biotekhnologii i inzhenerii imeni N.I. Vavilova», 2022.
6. Struktura kompleksa avtomaticheskoy mikroskopii MEKOS-C2 i metodiki ego ispytaniy / V. S. Medovyy, A. A. Parpara, A. M. Pyatnickij [i dr.] // Medicinskaya tekhnika. – 2006. – № 4. – S. 36-41.
7. Swolin B, Simonsson P, Backman S, Löfqvist I, Bredin I, Johnsson M. Differential counting of blood leukocytes using automated microscopy and a decision support system based on artificial neural networks--evaluation of DiffMaster Octavia // Clin Lab Haematol. – Vol. 25. – 3 -, 2003. – P. 139-47. doi: 10.1046/j.1365-2257.2003.00516.x.
8. Paszke A., Gross S., Massa F., Lerer A., Bradbury J., Chanan G., Chintala S. PyTorch: An Imperative Style, High-Performance Deep Learning Library // Advances in Neural Information Processing Systems. – 2019. – Vol. 32. – P. 8024–8035.
9. Deep Learning. / Goodfellow I., Bengio Y., Courville A.: MIT Press, 2016. – 800 p.
10. OIE Terrestrial Manual 2018. - URL: <https://www.oie.int/en/what-we-do/standards/codes-and-manuals/terrestrial-manual-online-access/> (data obrashcheniya 10.08.2021).
11. Gardner IA, Colling A, Caraguel C, Crowther JR, Jones G, Firestone SM, Heuer C. Introduction - Validation of tests for OIE-listed diseases as fit-for-purpose in a world of evolving diagnostic technologies // Rev Sci Tech. – Vol. 40 – 1 –, 2021. – P. 19-28. doi: 10.20506/rst.40.1.3207.
12. Supervisely. - URL: <https://supervisely/> (data obrashcheniya 10.02.2023).
13. Hasty. - URL: <https://hasty.ai/> (data obrashcheniya 10.02.2023).

Information about authors

1. **Dimitrieva Anastasia Ivanovna**, Candidate of Veterinary Sciences, Associate Professor, Associate Professor of the Department of Epizootology, Parasitology and Veterinary and Sanitary Expertise, Chuvash State Agrarian University, 428003, Cheboksary, st. K. Marx, 29, Chuvash Republic, Russia; e-mail: nastena_dim@mail.ru;
2. **Popov Alexander Petrovich**, Assistant of the Department of Epizootology, Parasitology and Veterinary and Sanitary Expertise, Chuvash State Agrarian University, 428003, Cheboksary, st. K. Marx, 29, Chuvash Republic, Russia; e-mail: popovaleksandr.petrovich@yandex.ru;
3. **Kovalenko Alena Vitalievna**, Postgraduate student of the the Department of Morphology, Obstetrics and Therapy, Chuvash State Agrarian University, 428003, Cheboksary, st. K. Marx, 29, Chuvash Republic, Russia; e-mail: kovalenkoa15051998@gmail.com;
4. **Andreev Vladimir Alexandrovich**, Senior Lecturer of the Department of Mathematics, Physics and Information Technology, Chuvash State Agrarian University, 428003, Cheboksary, st. K. Marx, 29, Chuvash Republic, Russia; e-mail: aiwoland7@rambler.ru;
5. **Belova Nadezhda Nikolaevna**, Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Mathematics, Physics and Information Technology, Chuvash State Agrarian University, 428003, Cheboksary, st. K. Marx, 29, Chuvash Republic, Russia; e-mail: bnn.belova@yandex.ru;
6. **Vasilyeva Olga Gennadijevna**, Candidate of Economical Sciences, Associate Professor, Associate Professor of the Department of Mathematics, Physics and Information Technology, Chuvash State Agrarian University, 428003, Cheboksary, st. K. Marx, 29, Chuvash Republic, Russia; e-mail: olech.vasiljeva@yandex.ru;
7. **Stepanov Anton Viktorovich**, Candidate of Physical and Mathematical Sciences, Associate Professor, Associate Professor of the Department of Mathematics, Physics and Information Technologies, Chuvash State Agrarian University, 428003, Cheboksary, st. K. Marx, 29, Chuvash Republic, Russia; e-mail: for.anton_step@mail.ru, tel. 8(352)62-23-34 additionally 155.