DOI: 10.58168/Forestry2025_719-727
УДК 630.61

МОДЕЛИРОВАНИЕ ТАКСАЦИОННЫХ ПОКАЗАТЕЛЕЙ ЛЕСНЫХ ДРЕВОСТОЕВ

Д.В. Арапов
д.т.н., профессор кафедры информационных технологий,
Воронежский государственный лесотехнический университет имени Г.Ф. Морозова», г. Воронеж, Россия

Аннотация. Цель работы – исследовать возможность применения искусственных нейронных сетей для моделирования таксационных показателей древостоев сосны и лиственницы, которые способны объединить в единое целое опытные исследования и обеспечивающие достаточно высокую точность моделирования и обладающие надежной прогностической способностью. Недостатком известных информационно-моделирующих систем роста и динамики продуктивности лесов РФ является то, что в их основе лежат регрессионные модели, обладающие недостаточной точностью и прогностической способностью. Для нейросетевой обработки использовали опубликованные в открытой печати данные по таксационным характеристикам сосновых и лиственничных древостоев. Нейросетевое моделирование реализовали посредством открытой программной библиотеки TensorFlow на языке Python, версии 3.11.7.

Ключевые слова: таксационные характеристики, древостои сосновые и лиственничные, искусственные нейронные сети.

MODELING OF TAXATION INDICATORS OF FOREST STANDS

D.V. Arapov
Doctor of Technical Sciences,
Professor of the Department of Information Technology,
Voronezh State University of Forestry and Technologies named after G.F. Morozov, Voronezh, Russia

Abstract. The aim of this study was to explore the feasibility of using artificial neural networks to model forest inventory parameters for pine and larch stands. These networks are capable of integrating experimental research, providing a sufficiently high modeling accuracy, and possessing reliable predictive power. A drawback of existing information modeling systems for forest growth and productivity dynamics in the Russian Federation is that they are based on regression models, which have insufficient accuracy and predictive power. Published data on forest inventory parameters for pine and larch stands were used for neural network processing. Neural network modeling was implemented using the open-source TensorFlow library in Python, version 3.11.7.

Keywords: taxation characteristics, pine and larch stands, artificial neural networks.

В последние годы в агропромышленном комплексе страны активно реализуется цифровизация технологических процессов и объектов. Поиск унифицированных подходов для применения цифровых технологий в лесном хозяйстве РФ является актуальным. Бурный рост применения методов искусственного интеллекта – нейросетевого и генетических подходов обуславливается их высокой результативностью в различных областях IT-технологий [1,2,4,5,10-12,19]. Цель работы – исследовать посредством нейросетевовой реализации возможность использования многослойных персептронов для

© Арапов Д. В., 2025

моделирования таксационных характеристик древостоев сосны и лиственницы, которые способны объединить в единое целое опытные исследования и обеспечивающие достаточно высокую точность моделирования и обладающие надежной прогностической способностью.

В большинстве работ по исследованию и моделированию динамики естественного изреживания и роста лесных древостоев приведены результаты математической обработки обширных наблюдений за естественным ростом и отпадом лесных насаждений сосны и лиственницы с различной густотой посадки в разновозрастных лесных монокультурных и поликультурных массивах [2, 6–9, 13–15]. Установлено, что математическая модель динамики гибели элементов биосистемы должна быть аддитивной функцией временного тренда, волновой и случайной компонент. Независимо от первоначальной густоты лесных культур, отпад деревьев, вследствие инерционности механизма саморегуляции биологическим систем, носит колебательный характер [10]. В [24] исследовали влияние на динамику роста сосны в рядовых культурах при заданных вариантах густоты и разных ширине междурядий и шаге посадки.

Разработанные в конце XX и начале XXI века специализированными институтами информационно-моделирующие системы роста и динамики продуктивности лесов РФ основаны на регрессионных экспоненциальных функциях типа Ципфа-Парето-Мандельброта, Пюттера-Берталанфи, Г.Ф. Хильми, иногда аддитивно дополнены функцией *cos(at)*, где *t*-возраст деревьев [3, 6, 14, 15]. Для моделирования среднего диаметра древостоя используют экспоненциально-логарифмическую зависимость от возраста, а среднюю высоту и древесный запас рассчитывают с использованием экспоненциальных функций [3, 6–9, 13, 14]. В [15] установлена оптимальная густота посадки ели в лесокультурных и лесоводственных насаждениях, а в [18] исследована приживаемость саженцев сосны в условиях Карелии. Однако, общеизвестным недостатком регрессионного подхода к моделированию, в том числе таксационных характеристик лесных древостоев, являются недостаточная точность полученных регрессий и узкая прогностическая способность, ограниченная предельными значениями экспериментальных данных. Например, ошибка моделирования в [7, 8, 13, 14] зависимости от возраста и начальной густоты посадки числа, оставшихся после отпада живых деревьев составляет 14-35% отн.

Объектами исследования послужили таксационные показатели древостоев сосны и лиственницы. Для нейросетевой обработки использовали опубликованные в открытой печати [12-14] таксационные исследования. Из [14] взяли обобщенные данные хода роста полных сосновых древостоев III класса бонитета, возраст сосен 10 – 200 лет и данные хода роста модальных древостоев лиственницы южной Якутии, тип леса – брусничниковый, класс бонитета IV, возраст лиственниц 40 – 220 лет. С помощью многослойных персептронов нами были обработаны данные по средней высоте деревьев (*м*), среднему диаметру (*см*), по числу живых деревьев (*шт./га*), древесному запасу ($м^3/га$), общей продуктивности ($м^3/га$), годовому отпаду ($м^3/га/год$).

Нейросетевое моделирование реализовали посредством открытой программной библиотеки для машинного обучения TensorFlow на языке Python версии 3.11.7. Использованные библиотеки – Numpy для поддержки многомерных массивов и Matplot для визуализации данных двумерной графикой. Подробный алгоритм глубокого обучения в используемых многослойных нейронных сетях описан в [1]. В программе реализовали: считывание и разделение данных на входные и выходные, нормировку данных. В обучении многослойного персептрона использовались все имеющиеся данные по каждой технической характеристике древостоя. Структура многослойного персептрона, число нейронов в каждом слое, вид функции активации нейронов (выбрали SiLU), количество эпох (т.е. число прогонов алгоритма оптимизации), коэффициент валидации и другие параметры задаются и реализуются в модуле Net.py. Ответ нейронной сети реализуется после минимизации целевой функции, которая заканчивается при выполнении задания по

числу эпох – 5000 или 25000 срабатываний оптимизатора: $\min E = 0,5\sum_{j=1}^{N}\left(Y_j\left(\mathbf{W}\right)-d_j\right)^2$, где **Y** – искомый вектор значений характеристики; **d** – вектор опытных величин характеристики; N – число опытов. Поиск min E реализуется по вектору синоптических весов связей нейронов $\mathbf{W}$.

При построении результирующих графиков по оси абсцисс выводится возраст деревьев, по оси ординат – опытные и расчетные нейросетевые значения технических характеристик древостоев.

Для глубокого обучения многослойных персептронов на основе опубликованных технических характеристик древостоев взяли оптимизационный алгоритм RMSProp [17] с автоматически изменяющейся скоростью обучения (1):

$$Er\left[grad^2\right]_n = 0,9Er\left[grad^2\right]_{n-1} + 0,1grad_n^2 \quad (1)$$

Искомые синоптические веса связей нейронов вычисляются в оптимизаторе RMSProp с высокой скоростью по формуле (2):

$$w^{n+1} = w^n - \frac{a}{\sqrt{Er\left[grad^2\right]_n + \varepsilon}} grad_n, \quad (2)$$

где $grad_n = \nabla_{w_n} E\left(w_n\right)$ – производная ошибки нейросети; η – шаг обучения алгоритма; $a = 1E-3$ – константа шага обучения; $\varepsilon = 1E-6$.

В отличие от [1], где использовали сигмоидальную функцию активации нейронов, в качестве функции активации нейронов применили функцию Свиша «SiLU» [18]: $swish\left(x\right) = x \cdot sigmoid\left(x\right)$.

Нейромоделирование обобщенных данных хода роста сосновых древостоев. Для пяти искомых параметров (средняя высота, средний диаметр, древесный запас, общая производительность и отпад деревьев) выбрали в процессе цифрового моделирования многослойный персептрон, состоящий из входного слоя, одного скрытого слоя в 20 нейронов и однонейронного выходного слоя, с которого снимается значение технической характеристики.

Для характеристики «число живых деревьев» применили многослойный персептрон с двумя скрытыми слоями по 20 нейронов. На входы персептронов поступает нормированные значения возраста сосен от 10 до 200 лет. Зависимость усредненной высоты сосен от их возраста показана на рис. 1.

Количество эпох равно 5000, средняя относительная ошибка нейромоделирования средней высоты составила $\pm$ 1,47%.

На рис. 2 показано нейросетевое моделирование зависимости усредненного диаметра сосен от их возраста.

Количество эпох – 5000, средняя относительная ошибка нейромоделирования среднего диаметра равна $\pm$ 2,27%.

На рис. 3 показана зависимость числа живых деревьев от возраста сосен.

Число эпох – 25000, средняя относительная ошибка нейромоделирования числа живых сосен равна $\pm$ 6,54%.

На рис.4 приведена графическая зависимость древесного запаса сосен от их возраста.

Число эпох – 5000, средняя относительная ошибка нейромоделирования древесного запаса составила $\pm$ 1,81%.

На рис. 5 представлена зависимость от возраста сосен общей продуктивности лесного массива.

Число эпох – 5000, средняя относительная ошибка нейромоделирования общей продуктивности равна $\pm$ 2,52%.

На рис.6 показана зависимость гибели деревьев от возраста сосен.

Число эпох – 5000, средняя относительная ошибка нейромоделирования отпада деревьев равна ± 3,49%.

Нейромоделирование хода роста древостоев лиственницы южной Якутии.

Для пяти искомых параметров (число деревьев, средняя высота, средний диаметр, древесный запас, общая производительность) применили многослойный персептрон, состоящий из входного слоя, одного скрытого слоя в 19 нейронов и однонейронного выходного слоя, с выхода которого снимается значение таксационной характеристики. Для характеристики «отпад деревьев» применили многослойный персептрон с двумя скрытыми слоями по 19 нейронов. На вход персептрона поступает нормированное значение возраста лиственниц от 40 до 220 лет. С выхода выходного слоя снимается значение характеристики «отпад деревьев». Принятое число эпох равно 5000 для всех 6 характеристик.

На рис. 7 представлены результаты нейромоделирования числа деревьев в зависимости от возраста лиственниц.

Средняя относительная ошибка нейромоделирования числа живых деревьев составила ± 1,97%. На рис. 8 представлены результаты нейромоделирования среднего диаметра деревьев в зависимости от возраста лиственниц. Средняя относительная ошибка нейромоделирования среднего диаметра равна ± 0,85%.

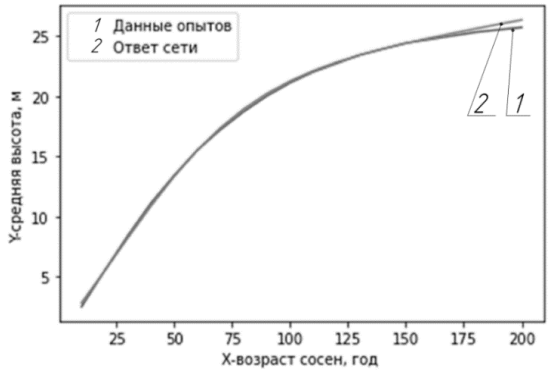
На рис. 9 показана зависимость средней высоты лиственниц от их возраста. Средняя относительная ошибка нейромоделирования средней высоты равна ± 0,94%.

На рис. 10 приведены результаты нейромоделирования древесного запаса от возраста лиственниц. Средняя относительная ошибка нейромоделирования древесного запаса равна 1,09%.

На рис. 11 приведены результаты нейромоделирования общей продуктивности от возраста лиственниц. Средняя относительная ошибка нейромоделирования общей продуктивности равна ± 1,21%.

На рис. 12 приведены результаты нейромоделирования отпада деревьев от возраста лиственниц. Средняя относительная ошибка нейромоделирования отпада равна ± 6,7%.

Проведенное нейромоделирование показало перспективность его использования для исследования закономерностей роста лесных древостоев, как в культурных, так и в естественных насаждениях. По сравнению с [7, 8, 13, 14, 15] относительная ошибка моделирования таксационных показателей древостоев при использовании многослойных персепторнов находится в пределах 1,0-7,0%. Это позволяет сделать вывод о более высокой точности нейросетевых моделей по сравнению с моделями, основанными на регрессионном подходе. Следует отметить незначительное время обучения нейросетевых моделей. Так на персональном компьютере с процессором Intel Core i3-3110M и 16 Гб ОЗУ время расчета при количестве эпох 5000 составляло в среднем 8-10 минут, а при 25 000 эпох – около 1 часа.



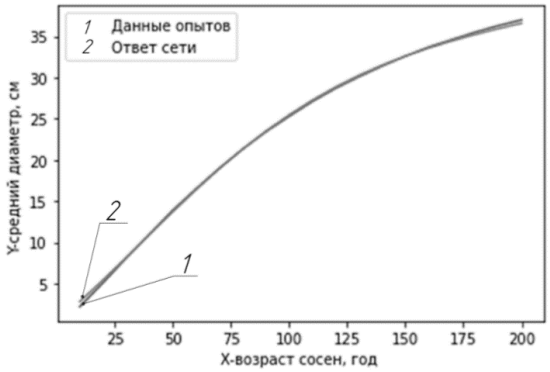


Рисунок 1. Зависимость средней высоты сосен от их возраста

Рисунок 2. Зависимость среднего диаметра от возраста сосен

Таким образом, сследовали возможность и эффективность применения искусственных многослойных нейронных сетей для моделирования таксационных характеристик сосновых и лиственничных древостоев искусственного и естественного происхождения. Система с использованием нейросетевых технологий может быть использована в составе специализированного программного обеспечения для мониторинга таксационных характеристик сосновых и лиственничных древостоев.

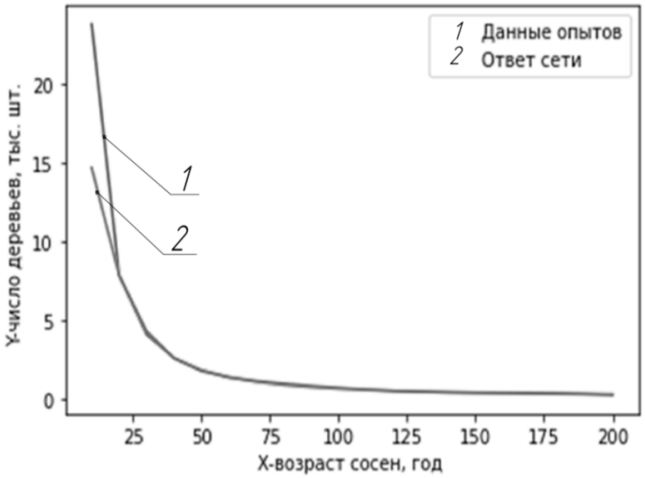


Рисунок 3. Нейромоделирование хода роста насаждений сосны по числу деревьев

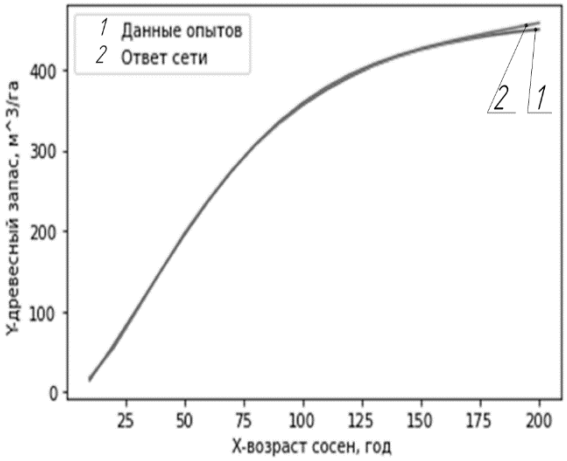


Рисунок 4. Зависимость древесного запаса от возраста сосен

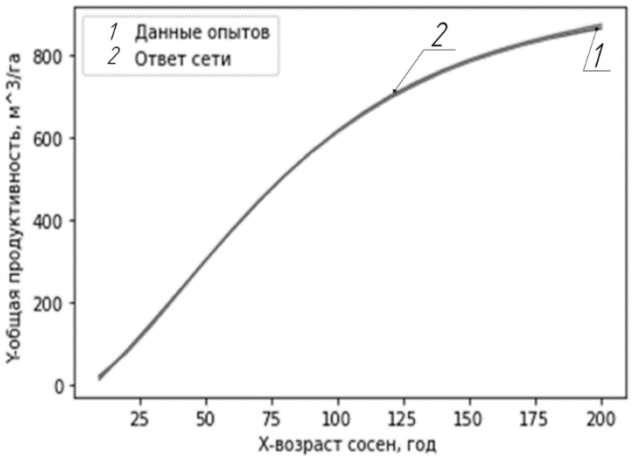


Рисунок 5. Зависимость общей продуктивности массива от возраста сосен

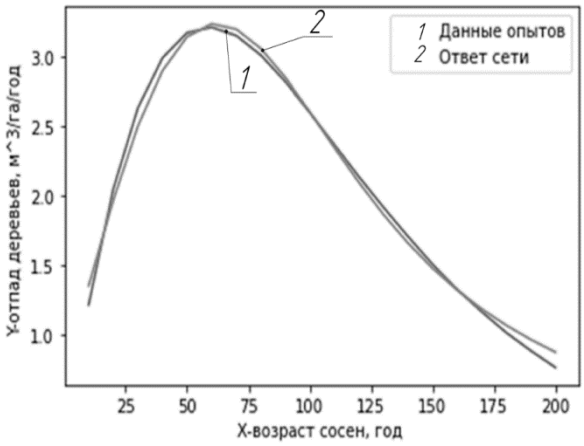


Рисунок 6. Зависимость отпада деревьев от возраста сосен

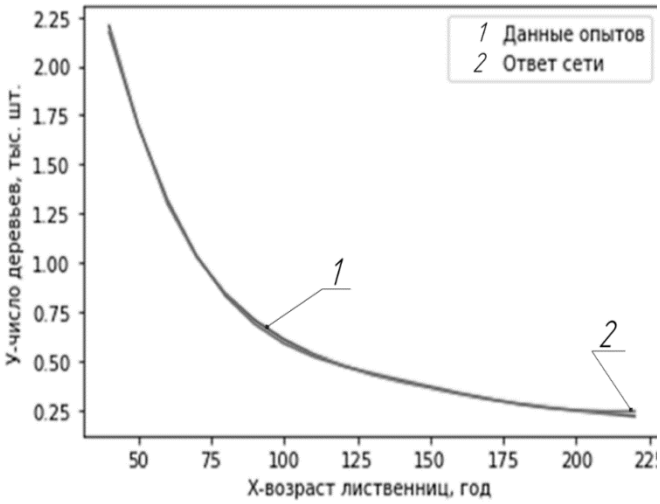


Рисунок 7. Зависимость числа живых лиственниц от их возраста

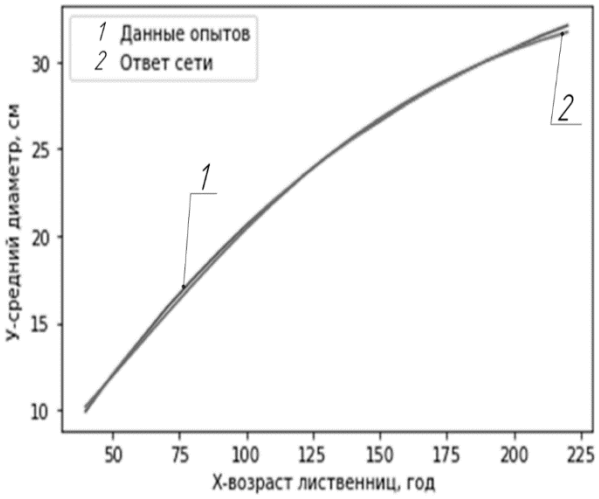


Рисунок 8. Зависимость среднего диаметра лиственниц от их возраста

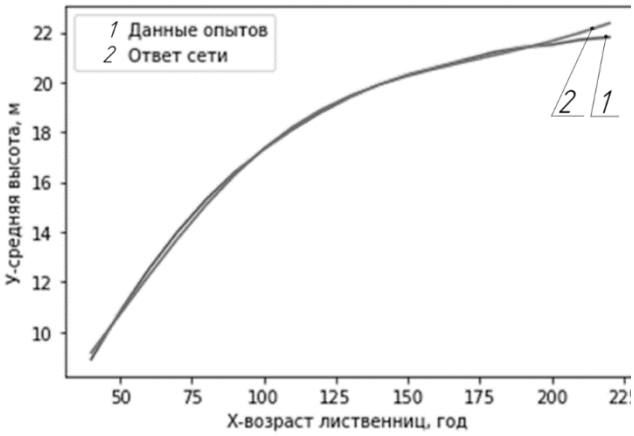


Рисунок 9. Зависимость средней высоты лиственниц от их возраста

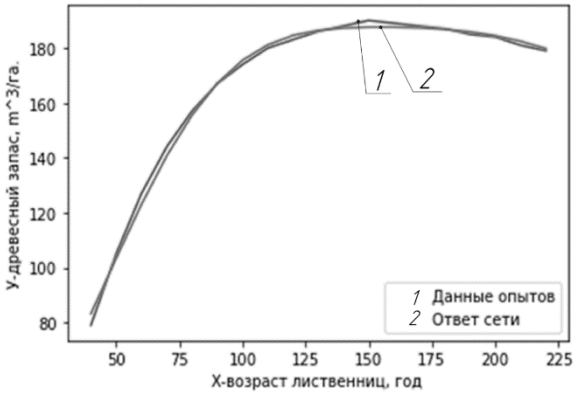


Рисунок 10. Зависимость древесного запаса от возраста лиственниц

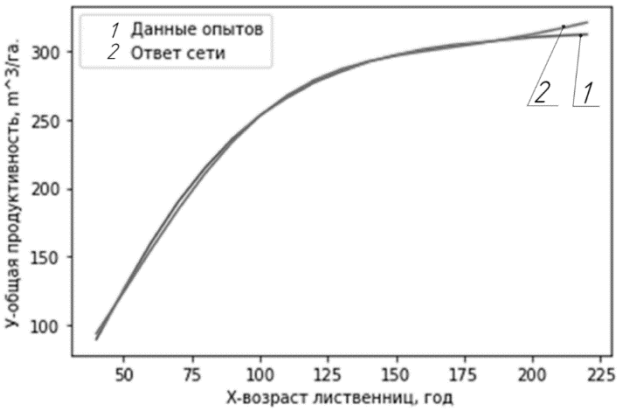


Рисунок 11. Зависимость общей продуктивности от возраста лиственниц

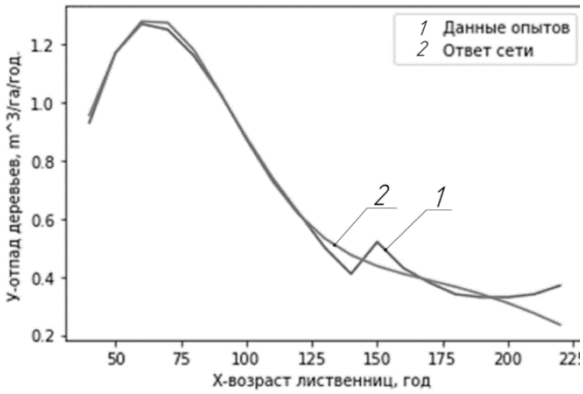


Рисунок 12. Зависимость отпада деревьев от возраста лиственниц

Результаты проведенного исследования показали перспективность использования методов искусственного интеллекта для моделирования таксационных показателей лесных древостоев РФ и имеют методическое и нормативно-справочное значение, а также могут быть использованы при проведении научных, лесоучетных, лесохозяйственных и лесоэксплуатационных работ.

Список литературы

1. Арапов Д.В., Курицын В.А., Скоробогатов С.А. Автоматизированная мобильная система принятия решений для использования в специальной медицине // Моделирование систем и процессов. 2024. Т.17. № 3. С. 7-16.
2. Богачев А.В. Лесотаксационные исследования. М.: ВНИИЛМ, 2007. 344 с.
3. Грачев А.В. Применение нейросетевых технологий для прогнозирования состояния работы объектов предприятий АПК // Техника и технология пищевых производств. 2023. Т.53. №4. С. 816-823.
4. Дубенок Н.Н., Лебедев А.В., Кузьмичев В.В. Динамическая модель изреживания культур сосны // Известия Санкт-Петербургской лесотехнической академии. 2022. Вып. 239. С. 6–21.
5. Дубенок Н.Н., Кузьмичев В.В., Лебедев А.В. Нелинейная модель смешанных эффектов зависимости высоты от диаметра деревьев в древостоях лиственницы // Труды Санкт-Петербургского научно-исследовательского института лесного хозяйства. 2021. № 4. С. 42-56.
6. Дубенок Н. Н., Лебедев А.В., Кузьмичев В.В. Оценка статистических моделей распределения деревьев по диаметру в культурах сосны // Лесохозяйственная информация. 2022. № 1. С. 50-61
7. Киреева К.А., Коробова Л.А., Арапов Д.В. Разработка искусственной нейронной сети для классификации ЭКГ // Моделирование систем и процессов. 2023. Т.16. №3. С. 42 – 54.
8. Лебедев А.В., Кузьмичев В.В. Таксационные показатели сосновых древостоев по данным долговременных наблюдений // Сибирский лесной журнал. 2023. № 2. С. 3–16.
9. Мельник П.Г., Воронин Ф.Н., Мерзленко М.Д. Лесокультурно-лесоводственное значение параметров размещения ели при посадке в национальном парке «Лосиный остров» // Вестник Алтайского государственного аграрного университета. 2014. №1. С. 52–58.
10. Мерзленко М.Д. Обоснование теории волнообразного роста хвойных лесных культур // Лесной вестник. 2021. Т. 25, №2. С. 3–9.
11. Соколов, А.И., Харитонов В.А., Пеккоев А.Н., Кривенко Т.И. Сохранность и рост культур сосны, созданных посадочным материалом с закрытой корневой системой в условиях Карелии // Известия вузов. Лесной журнал. 2015. №6. С. 46–56.
12. Швиденко А.З., Щепащенко Д.Г., Нильссон С, Булуй Ю.И. Таблицы и модели хода роста и продуктивности насаждений основных лесообразующих пород Северной Евразии: нормативные справочные материалы: 2-е изд. перераб. и дополн. М.: Рослесхоз. 2008. 886 с.
13. Швиденко А.З., Щепащенко Д.Г., Нильссон С, Булуй Ю.И. Система моделей роста и динамики продуктивности лесов России (таблицы и модели биопродуктивности) // Лесное хозяйство. 2004. № 2. С. 40–44.
14. Швиденко А.З., Щепащенко Д.Г., Нильссон С, Булуй Ю.И. Система моделей роста и динамики продуктивности лесов России (таблицы хода роста) // Лесное хозяйство. 2003. № 6. С. 34–38.
15. Шутов И.В., Иванов А.М., Антонов О.И., Власов Р.В., Сергиенко В.Г., Беленец Ю.Е., Смирнов Е.Г., Выродова С.А., Степаненко С.М. Рост сосны в рядовых культурах при заданных вариантах густоты и разных ширине междурядий и шаге посадки // Труды Санкт-Петербургского НИИ лесного хозяйства. 2014. № 1. С. 19–29.
16. Arapov D.V., Kuritsyn V.A., Petrov S.M., Podgornova N.M. Simulation of the rate of dissolution of sucrose crystals. Journal of Food Engineering. 2022. 318: 110887. – URL: https://doi.org/10.1016/j.jfoodeng.2021.110887.

17. Elfwing S., Uchibe E., Doya K. Sigmoid-weighted linear units for neural network function approximation in reinforcement learning. Neural Networks. 2018. – URL: https://doi.org/10.1016/j.neunet.2017.12.012

18. Hinton G.E., Srivastava N., Krizhevsky A., Sutskever I., Salakhutdinov R.R. Improving neural networks by preventing co-adaptation of feature detectors. arXiv:1207.0580v1[cs.NE] 3 Jul 2012. – URL: https://doi.org/10.48550/arXiv.1207.0580.

19. Kuritsyn V.A., Arapov D.V., Goril'chenko R.L. Optimization of circulation water cooling process in forced-draft towers. Chemistry and Technology of Fuels and Oils, 2012, vol. 48, no. 2, pp. 97–108. – URL: https://doi.org/10.1007/s10553-012-0344-1.

References

1. Arapov D.V., Kuritsyn V.A., Skorobogatov S.A. Automated mobile decision-making system for use in special medicine. Modelirovanie system i processov = Modeling of systems and processes, 2024, vol. 17, no. 3, pp. 7-16 (In Russ.). – URL: https://doi.org/10.12737/2219-0767-2024-5-13

2. Bogachev, A.V. Forest taxation studies. Moscow, VNIILM Publ. 2007. 344 p.

3. Grachev AV. Application of neural network technologies for forecasting the operating status of agricultural enterprises. Tekhnika i tekhnologiya pishchevyh pro-izvodstv = Food Processing: Techniques and Technology, 2023, vol. 53, no. 4, pp. 816–823. (In Russ.). – URL: https://doi.org/10.21603/2074-9414-2023-4-2481

4. Demakov Yu.L. Diagnostics of forest ecosystem stability. Yoshkar-Ola Publ. 2000. 416 p.

5. Dubenok N.N., Lebedev A.V., Kuzmichev V.V. Dynamic model of thinning of pine crops. Izvestiya Sankt-Peterburgskoj lesotekhnicheskoj akademii = Bulletin of the St. Petersburg Forest Engineering Academy, 2022, no. 239, pp. 6–21. (In Russ.). – URL: https://doi.org/10.21266/2079-4304.2022.239.6-21

6. Dubenok N.N., Kuzmichev V.V., Lebedev A.V. Nonlinear mixed effects model of the dependence of height on tree diameter in larch stands. Trudy Sankt-Peterburgskogo nauchno-issledovatel'skogo instituta lesnogo hozyajstva = Proceed-ings of the St. Petersburg Research Institute of Forestry, 2021, no. 4, pp. 42–56. (In Russ.). – URL: https://doi.org/10.21178/2079–6080.2021.4.42.

7. Dubenok N.N., Lebedev A.V., Kuzmichev V.V. Evaluation of statistical models of tree distribution by diameter in pine crops. Lesohozyajstvennaya informaciya = Forestry information, 2022, no. 1, pp. 50-61. (In Russ.). – URL: https://doi.org/10.24419/LHI.2304-3083.2022.1.03.

8. Kireeva K.A., Korobova L.A., Arapov D.V. Development of an artificial neural network for ECG classification. Modelirovanie system i processov = Modeling of systems and processes, 2023, vol. 16, no. 3, pp. 42-54. (In Russ.). – URL: https://doi.org/10.12737/2219-0767-2023-16-3-42-54.

9. Lebedev A.V., Kuzmichev V.V. Taxation indicators of pine stands based on long-term observations. Sibirskij lesnoj zhurnal = Siberian Forest Journal, 2023, no. 2, pp. 3-16. (In Russ.). https://doi.org/10.15372/SJFS20230201

10. Merzlenko MD. Justification of the theory of wave-like growth of coniferous forest crops. Lesnoj vestnik = Forest Bulletin, 2021, vol. 25, no. 2, pp. 3–9. (In Russ.). https://doi.org/10.18698/2542-1468-2021-2-5-9

11. Sokolov A.I., Kharitonov V.A., Pekkoev A.N., Krivenko T.I. Preservation and growth of pine crops created from planting material with a closed root system in the conditions of Karelia. Lesnoy Zhurnal = Russian Forestry Journal, 2015, no. 6, pp. 46–56. https://doi.org/10.17238/issn0536-1036.2015.6.46

12. Shvidenko A.Z., Shchepashchenko D.G., Nilsson S., Buluy Yu.I. Tables and models of the growth and productivity of plantations of the main forest-forming species of Northern Eurasia: normative reference materials. Moscow, Rosleschoz Publ. 2008. 886 p.

13. Shvidenko A.Z., Shchepashchenko D.G., Nilsson S., Buluy Yu.I. System of models of growth and productivity dynamics of Russian forests (tables and models of bioproductivity. Lesnoe hozyajstvo = Forestry, 2004, no. 2, pp. 40–44. (In Russ.).

14. Shvidenko A.Z., Shchepashchenko D.G., Nilsson S., Buluy YuI. System of models of growth and productivity dynamics of Russian forests (tables of growth progress). Lesnoe hozyajstvo = Forestry, 2003, no. 6, pp. 34–38. (In Russ.).

15. Shutov I.V., Ivanov A.M., Antonov O.I., Vlasov R.V., Sergienko V.G., Belenets Yu.E., Smirnov E.G., Vyrodova S.A., Stepanenko S.M. Pine growth in row crops at given density options and different row spacings and planting pitch. Trudy Sankt-Peterburgskogo NII lesnogo hozyajstva = Works of the St. Petersburg Research Institute of Forestry, 2014, no. 1, pp. 19–29. (In Russ.).

16. Arapov D.V., Kuritsyn V.A., Petrov S.M., Podgornova N.M. Simulation of the rate of dissolution of sucrose crystals. Journal of Food Engineering. 2022. 318: 110887. https://doi.org/10.1016/j.jfoodeng.2021.110887

17. Elfwing S., Uchibe E., Doya K. Sigmoid-weighted linear units for neural net-work function approximation in reinforcement learning. Neural Networks. 2018. https://doi.org/10.1016/j.neunet.2017.12.012

18. Hinton G.E., Srivastava N., Krizhevsky A., Sutskever I., Salakhutdinov R.R. Improving neural networks by preventing co-adaptation of feature detectors. arXiv:1207.0580v1[cs.NE] 3 Jul 2012. https://doi.org/10.48550/arXiv.1207.0580

19. Kuritsyn V.A., Arapov D.V., Goril'chenko R.L. Optimization of circulation water cooling process in forced-draft towers. Chemistry and Technology of Fuels and Oils, 2012, vol. 48, no. 2, pp. 97–108. https://doi.org/10.1007/s10553-012-0344-1.