

ПРОГНОЗ СОСТОЯНИЯ ЛЕСНЫХ ЭКОСИСТЕМ СРЕДНЕГО ПОВОЛЖЬЯ С ИСПОЛЬЗОВАНИЕМ САМООБУЧАЮЩИХСЯ МОДЕЛЕЙ

С.А. Лежнин, А.В. Губаев, О.Н. Воробьев, Э.А. Курбанов,
Д.М. Дергунов, Л.В. Тарасова
Поволжский государственный технологический университет

В статье представлены результаты исследования по прогнозированию состояния лесных экосистем Среднего Поволжья с использованием самообучающихся моделей, разработанных в среде Python. Были разработаны и протестированы несколько вариантов моделей для прогноза, в том числе с использованием нейронных сетей. Все используемые модели были самообучающимися на основе данных, собранных за период с 2000 по 2020 год. В качестве признака, характеризующего состояние лесных экосистем, использован нормализованный относительный индекс растительности (NDVI). Как показали результаты тестирования, наиболее точной оказалась модель экспоненциального сглаживания, которая содержала наименьшие ошибки по сравнению с другими моделями. На основе модели экспоненциального сглаживания был проведен прогноз состояния лесных экосистем до 2050 года, который показал устойчивый рост фитомассы на территории исследования. Результаты прогнозирования хорошо соотносятся с данными предыдущих десятилетий, так как с 2000 по 2020 год наблюдалось общее снижение вырубленных и повреждённых пожарами древостоев на территории исследования. Кроме того, восходящий тренд хорошо коррелирует с общим развитием древостоев и накоплением ими биомассы, если они не подвержены внезапным негативным воздействиям.

Ключевые слова: прогнозирование, лесные насаждения, фитомасса, Python, нейронная сеть, моделирование

FORECASTING THE STATE OF FOREST ECOSYSTEMS IN THE MIDDLE VOLGA REGION USING SELF-LEARNING MODELS

S.A. Lezhnin, A.V. Gubaev, O.N. Vorobev, E.A. Kurbanov,
D.M. Dergunov, L.V. Tarasova
Volga State University of Technology

The article presents the outcomes of research forecasting the state of forest ecosystems in the Middle Volga region using self-learning models programmed in Python. Several forecasting models have been developed and tested, including those that employ neural networks. All the models were self-learning based on data collected from 2000 to 2020. The condition of forest ecosystems was characterised using the Normalized Difference Vegetation Index (NDVI). Experiments revealed that the exponential smoothing model was the most accurate and had the fewest errors in comparison with other models. A forecast of the state of forest ecosystems up to 2050 was made using the exponential smoothing model, and the results revealed a steady

phytomass increase in the area under study. Since there was a significant decrease in fallen and damaged trees in the research region from 2000 to 2020, the forecasting data correlate well with past records. Provided the stands are not vulnerable to unexpected negative impacts, the upward trend is directly related to the overall development of the stands and their phytomass accumulation.

Keywords: *forecasting, forest stands, phytomass, Python, neural network, modelling*

Введение. Понимание динамики и самоорганизации экосистем является одной из самых сложных проблем современной экологии (Levin, 1999). Самоорганизация происходит одновременно на нескольких уровнях иерархической организации экосистемы и включает динамические процессы, действующие в разных временных и пространственных масштабах (Levin, 2003). Динамика лесного покрова относится к временным и пространственным изменениям, происходящим одновременно на разных уровнях организации экосистемы. Различные подходы к моделированию, используемые для понимания и прогнозирования этих изменений, включают ряд дискретных и непрерывных детерминированных моделей, таких как индивидуальные модели, дифференциальные уравнения и уравнения в частных производных (Strigul et al., 2012). За последние десятилетия было разработано большое количество моделей, прогнозирующих развитие леса (Botkin, 1993; Pastor, 2005; Moorcroft et al., 2001; Strigul et al., 2008). Тем не менее, есть фундаментальные вопросы, которые существующие количественные подходы не могут полностью решить.

Одной из основных проблем является понимание динамики лесных экосистем при нестационарных режимах возмущений, связанных с климатическими факторами и антропогенной деятельностью. Неполный перечень нарушений, существенно влияющих на приживаемость деревьев и приводящих к изменению площади лесов или их состояния, включает ветер, мороз, ураганы, лесозаготовки и лесные пожары (McCarthy, 2001; Hanson, Weltzin, 2000).

Индивидуальные модели способны имитировать негативные эффекты во времени и пространстве (Liénard, Strigul, 2016), однако эти модели, как правило, производятся только с помощью компьютерного моделирования, и это ограничивает возможность предсказания развития экосистем с привязкой к натурным данным за прошедшие годы. Для решения данной проблемы некоторые ученые объединяют многомерный статистический анализ с марковской моделью вероятностей для разработки детального прогноза (Liénard et al., 2015). Однако одновременное использование нескольких независимых лесных характеристик существенно снижает способность понимать лесоводческий смысл модельных прогнозов (Caswell, 2001).

Еще одним современным подходом к прогнозированию является использование временных рядов (авторегрессионные модели и случайные выборки) для количественной оценки динамики лесных экосистем и построения прогностических моделей, включающих несколько параметров (Fox et al., 2008). Этот тип моделей может преодолеть основные недостатки предыдущих моделей. Авторегрессионные модели работают с непрерывным пространством, они поддаются анализу и могут работать с многомерными характеристиками сложных адаптивных систем (Davis et al., 2012).

В последние годы всё большее распространение при прогнозировании развития лесных экосистем получили искусственные нейронные сети (ИНС), поскольку они могут обеспечивать успешные прогнозы с учетом моделей развития древостоя и натурных данных. Нейронные сети являются очень полезным инструментом в моделировании данных

(Esteban et al., 2009; Ashraf et al., 2013; Buğday, 2018; Doğan, Buğday, 2018). Однако существует лишь ограниченное количество исследований по использованию нейронных сетей в моделировании лесных экосистем (Soares et al., 2011; Bhering et al., 2015).

Целью работы являлось прогнозирование развития лесных экосистем Среднего Поволжья до 2050 года с использованием натурных данных и нейронных сетей.

Для достижения цели были решены следующие **задачи**:

- подобраны натурные данные по состоянию лесных экосистем Среднего Поволжья за период с 2000 по 2020 год;
- подобраны прогнозные модели, основанные на нейронных сетях, позволяющие обучаться на прошлых данных;
- проведено прогнозирование развития лесных экосистем Среднего Поволжья на период до 2050 года.

Методика работ

Сбор полевых данных

В качестве признака, характеризующего состояние лесных экосистем, был использован нормализованный относительный индекс растительности (NDVI), простой показатель количества фотосинтетически активной биомассы. NDVI используется для оценки состояния лесного покрова в различных исследованиях и считается оптимальным для подобных работ (Zhao et al., 2022; Deng et al., 2022; Imanyfar, Hasanlou, 2019).

Для получения данных была создана регулярная векторная сеть 1x1 км, закрывающая все лесные насаждения площадью более 0,5 га на территории исследования (рис. 1) (Воробьев и др., 2022).




Рис.1. Этапы создания регулярной сети тестовых участков на базе тематической карты лесного покрова территории исследования

С помощью созданной сети была собрана база данных значений NDVI за период с 2000 по 2020 год, которая в дальнейшем была использована в обучении нейронной сети (табл. 1)

Таблица 1

Фрагмент базы данных NDVI

№ точки	Дата					
	01.05.2000	01.06.2000	01.07.2000	01.08.2000	01.09.2000	01.05.2001
0	0,781164	0,83864	0,850705	0,865301	0,789846	0,739768
1	0,781164	0,83864	0,850705	0,865301	0,789846	0,739768
2	0,796212	0,84424	0,8578	0,862646	0,791788	0,741775
3	0,780265	0,834326	0,83695	0,862244	0,794527	0,744477
4	0,780479	0,835051	0,837853	0,863418	0,795304	0,744394
5	0,780479	0,835051	0,837853	0,863418	0,795304	0,744394
6	0,779799	0,836451	0,847305	0,864056	0,789251	0,739355
7	0,781164	0,83864	0,850705	0,865301	0,789846	0,739768
8	0,781164	0,83864	0,850705	0,865301	0,789846	0,739768
9	0,784444	0,836271	0,853764	0,86561	0,79194	0,736975
10	0,783426	0,835894	0,852623	0,86494	0,791311	0,735778
11	0,785544	0,839876	0,857992	0,86843	0,792747	0,737208
12	0,785544	0,839876	0,857992	0,86843	0,792747	0,737208
13	0,787657	0,843027	0,862761	0,871242	0,795364	0,736673
14	0,790631	0,840439	0,857817	0,863302	0,789945	0,737636
15	0,790631	0,840439	0,857817	0,863302	0,789945	0,737636
16	0,793086	0,839834	0,854144	0,857626	0,787078	0,740755
17	0,79493	0,841128	0,85662	0,860803	0,789718	0,742382
18	0,79493	0,841128	0,85662	0,860803	0,789718	0,742382
19	0,777341	0,829881	0,834039	0,858667	0,791919	0,742695
20	0,777341	0,829881	0,834039	0,858667	0,791919	0,742695
21	0,780265	0,834326	0,83695	0,862244	0,794527	0,744477
22	0,780479	0,835051	0,837853	0,863418	0,795304	0,744394
23	0,780479	0,835051	0,837853	0,863418	0,795304	0,744394
24	0,779799	0,836451	0,847305	0,864056	0,789251	0,739355
25	0,781164	0,83864	0,850705	0,865301	0,789846	0,739768

Подбор прогнозных моделей

Для разработки моделей прогнозирования лесных экосистем была использована библиотека Darts для языка программирования Python (Time Series Made...). Разработчики библиотеки Darts стремятся упростить анализ временных рядов и прогнозирование. Darts поддерживает различные подходы к прогнозированию, начиная от классических статистических моделей, таких как ARIMA и экспоненциальное сглаживание, и заканчивая новыми методами, основанными на машинном и глубоком обучении. Кроме того, Darts включает в себя различные функции, которые позволяют понять статистические свойства временных рядов, а также оценить точность моделей прогнозирования (Rolnick et al., 2022).

Первым шагом в подборе моделей прогнозирования была обработка исходных данных и их статистических свойств. Это было достигнуто методом анализа временных рядов и графическим отображением полученных результатов. После загрузки набора данных в

рабочий алгоритм к нему применяются некоторые методы предварительной обработки данных, такие как удаление ненужных столбцов, установка ежемесячного индекса даты и времени и удаление нулевых значений. После очистки набора данных создается простой линейный график временного ряда (рис. 2).




Рис. 2. Распределение средних значений индекса NDVI за временной период сбора данных

На рисунке 2 видно, что существует явная тенденция к увеличению запаса древесных насаждений. Кроме того, прослеживаются сезонные колебания фитомассы, что является естественным процессом во время вегетационного периода. В целом тренд на увеличение довольно постоянный, за исключением отдельных периодов: спад общего запаса фитомассы в начале 2000-х связан с обширной засухой на территории Среднего Поволжья; резкое снижение индекса NDVI в 2010 году связано с прошедшими пожарами; спад 2013-2014 годов также коррелирует с данными о засухах на территории исследования в это время.

Следующим шагом была декомпозиция временного ряда для извлечения компонентов тренда, сезонности и остатков (рис. 3). В этом конкретном случае уже можно было идентифицировать компоненты, визуально рассматривая линейный график, но сезонная декомпозиция значительно помогает в более сложных случаях.




Рис.3. Тренд, сезонность и остатки индекса NDVI за прошедший период

Построение автокорреляционной функции временного ряда, т. е. линейной зависимости между ее значениями с запаздыванием, показывает, что автокорреляция также выделяет сезонную составляющую временного ряда (рис. 4).




Рис.4. Автокорреляция временного ряда

Модели прогнозирования временных рядов

Следующим этапом исследования было обучение различных моделей прогнозирования на наборе данных NDVI. Необходимо было подобрать модель с наивысшей точностью и адекватностью. Наиболее эффективная модель будет использована в дальнейшем для прогнозирования состояния лесных экосистем Среднего Поволжья до 2050 года. Загрузка

данных NDVI прошлых лет в объект TimeSeries библиотеки Darts позволит строить прогнозы и отображать различные показатели модели, включая среднюю абсолютную ошибку (Mean absolute error, MAE), среднеквадратическое отклонение (Root mean square error, RMSE), среднюю абсолютную ошибку в процентах (Mean absolute percentage error, MAPE), симметричную абсолютную процентную ошибку (Symmetric mean absolute percentage error, SMAPE) и R^2 .

Наивная модель прогнозирования

Стандартной практикой при прогнозировании с помощью нейронных сетей является установка базовой точности, что задаётся с помощью создания наивной модели. Это поможет оценить производительность более сложных моделей, которые теоретически должны иметь более высокую точность по сравнению с базовой линией. В исследовании создается наивная сезонная модель, которая всегда предсказывает значение на K шагов назад, где K равно сезонному периоду. Для тестирования наивной сезонной модели используется функция `history_forecasts` с горизонтом прогноза на 12 месяцев. Эта функция последовательно обучает модель в расширяющемся окне и по умолчанию сохраняет последнее значение каждого прогноза. Этот метод известен как ретроспективное тестирование или перекрестная проверка временных рядов, и он является более сложным по сравнению с типичным методом обучения. После создания прогноза отображается график и статистические показатели (рис. 5, табл. 2).




Рис. 5. Наивная модель после самообучения на полевых данных

Таблица 2

Статистические показатели наивной модели прогноза

Модель	MAE	RMSE	MAPE	SMAPE	R^2
Наивная модель	0,05	0,07	23,65	21,52	0,94

Как видно из графика 5 и таблицы 2, наивная модель после самообучения с довольно высокой точностью строит прогноз, в сравнении с данными за последние 3 года исследования.

Модель экспоненциального сглаживания

После установки базовой точности можно построить модели, основанные на других методах расчета. Следующая модель была построена на основе экспоненциального сглаживания Холта-Винтера, классического подхода, который успешно используется с 1960-х годов (Winters, 1960). Аналогично наивной модели, после расчёта получается графическое отображение модели экспоненциального сглаживания и её статистические показатели (рис. 6, табл. 3).




Рис. 6. Модель экспоненциального сглаживания после самообучения на полевых данных

Таблица 3

Статистические показатели модели экспоненциального сглаживания

Модель	MAE	RMSE	MAPE	SMAPE	R ²
Экспоненциальная модель	0,04	0,06	24,99	17,91	0,94

Очевидно, что модель экспоненциального сглаживания значительно превосходит наивную модель со значением SMAPE, равным 17 %. Визуально это подтверждается тем, что прогнозируемые значения почти идентичны значениям набора данных, нанесенных на график.

Модель линейной регрессии

Аналогично вышепостроенным моделям, используя `history_forecasts()` и служебные функции, создаем модель линейной регрессии с отображением графических и статистических результатов (рис. 7, табл. 4).




Рис. 7. Модель линейной регрессии после самообучения на полевых данных

Таблица 4

Статистические показатели модели линейной регрессии

Модель	MAE	RMSE	MAPE	SMAPE	R ²
Регрессионная модель	0,05	0,06	23,59	21,76	0,95

Как видим, модель имеет производительность на уровне наивной модели с близким значением SMAPE, но с чуть более высоким уровнем $R^2=0,95$.

Модель прогнозирования временной сверточной сети (BCC)

В последние годы глубокое обучение стало популярным в прогнозировании временных рядов, при этом рекуррентные нейронные сети стали стандартным выбором в исследованиях, а также в практических приложениях. Несмотря на это, временная сверточная сеть — это альтернативная архитектура, дающая многообещающие результаты (Bai et al., 2018), поэтому в работе была проверена ее производительность (рис. 8, табл. 5).




Рис. 8. Модель временной сверточной сети после самообучения на полевых данных

Таблица 5

Статистические показатели модели временной сверточной сети

Модель	MAE	RMSE	MAPE	SMAPE	R ²
Временная сверточная сеть	0,04	0,06	20,45	17,95	0,95

Очевидно, что модель ВСС имеет значительно лучшую производительность по сравнению с базовой линией и практически равна по точности модели экспоненциального сглаживания.

Прогнозирование динамики лесных экосистем

Как и ожидалось, все модели превзошли наивную сезонную модель, обеспечив хорошую точность. Несмотря на это, видно, что экспоненциальное сглаживание обеспечивает наилучшие результаты, поэтому прогноз состояния лесных экосистем до 2050 года будет основан на нем. Для создания модели используется функция fit, чтобы подогнать модель экспоненциального сглаживания ко всему набору данных, а затем отобразить результаты (рис. 9).




Рис. 9. Прогнозные значения индекса NDVI до 2050 года

Как видно из графика 9, компоненты временного ряда были успешно идентифицированы моделью. Общий тренд показывает постоянный рост фитомассы древесного покрова, что говорит об устойчивом развитии лесных экосистем Среднего Поволжья. Результаты прогнозирования хорошо соотносятся с данными предыдущих десятилетий, так как с 2000 по 2020 год наблюдалось общее снижение вырубленных и повреждённых пожарами древостоев на территории исследования. Кроме того, восходящий тренд хорошо коррелирует с общим развитием древостоев и накоплением ими биомассы, если они не подвержены внезапным негативным воздействиям.

Заключение

Сравнение моделей прогнозирования динамики древесного покрова позволяет констатировать, что модели экспоненциального сглаживания показывают чуть лучший результат, чем линейные модели и модели глубокого обучения. Вместе с тем следует иметь в виду, что новые модели не обязательно лучше в каждом случае по сравнению с классическими методами. Но повсеместное распространение вычислительной техники предполагает возможную оптимизацию разрабатываемых моделей, применяя большое количество параметров, что в настоящее время занимает большое количество времени и требует высоких вычислительных мощностей, однако способна предложить значительные улучшения прогнозирования.

Построенный прогноз до 2050 года показывает восходящий тренд фитомассы лесных насаждений Среднего Поволжья, что говорит об устойчивом развитии лесных экосистем. Вместе с тем следует уточнить, что построенная модель в незначительной степени учитывает непостоянные негативные факторы, такие как пожары и засухи, которые отрицательно влияют на состояние древостоев. Кроме того, для улучшения прогнозирования необходимо увеличивать обучающий период модели. Возможно, что обучающая выборка за 30- или 40-летний период дала более точные результаты, чем используемая обучающая выборка за 20 лет.



*Исследование выполнено за счет гранта Российского научного фонда
№ 22-16-00094, <https://rscf.ru/project/22-16-00094/>*

Библиографический список

1. Курбанов Э.А., Воробьев О.Н., Лежнин С.А., Дергунов Д.М. Анализ трендов временных рядов вегетационных индексов по данным MODIS для оценки влияния засух на лесные насаждения Среднего Поволжья с 2000 по 2020 год // Современные проблемы дистанционного зондирования Земли из космоса. 2022. №4. С.181-194.
2. Ashraf M.I., Zhao Z., Bourque A., MacLean D.A., Meng F. Integrating biophysical controls in forest growth and yield predictions generated with artificial intelligence technology // Canadian Journal of Forest Research. 2013. 43. P. 1162–1171.
3. Bai S., Kolter J.Z., Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling // arXiv. 2018. 803.01271.
4. Bhering L.L., Junqueira V.S., Peixoto L.A., Cruz C.D., Laviola B.G. Comparison of methods used to identify superior individuals in genomic selection in plant breeding // Genet Mol Res. 2015. 14(3):10888-10896.
5. Botkin D.B. Forest Dynamics: An Ecological Model // Oxford University Press: Oxford, UK. 1993.
6. Pastor J.; Sharp A.; Wolter P. An application of Markov models to the dynamics of Minnesota's forests // Can. J. For. Res. 2005. 35. P. 3011–3019.

7. Buğday E. Application of Artificial Neural Network System Based on ANFIS Using GIS for Predicting Forest Road Network Suitability Mapping // *Fresenius Environmental Bulletin*. 2018. Vol.27, №3. P. 1656-1668.
8. Caswell H. *Matrix Population Models: Construction, Analysis, and Interpretation* // Sinauer Associates: Sunderland, MA, USA. 2001.
9. Davis J., Aliaga-Díaz R., Thomas C.J. *Forecasting Stock Returns: What Signals Matter, and What do They Say Now* // The Vanguard Group: Valley Forge, PA, USA. 2012.
10. Deng Y., Pan J., Wang J. Mapping of Forest Biomass in Shangri-La City Based on LiDAR Technology and Other Remote Sensing Data // *Remote Sensing*. 2022. Vol. 14, Iss. 22. 5816.
11. Doğan S., Buğday E. Modeling of Temporal and Spatial Changes of Land Cover and Land Use by Artificial Neural Networks: Kastamonu Sample // *Journal of Bartın Faculty of Forestry*. 2018. 20 (3): 653-663. doi: 10.24011/barofd.467974.
12. Esteban L.G., Fernandez F.G., De Palacios P. MOE Prediction in *Abies pinsapo* boiss. Timber: application of an artificial neural network using non-destructive testing // *Computers and Structures*. 2009. №87. P. 1360-1365.
13. Fox J.C., Bi H., Ades P.K. Modelling spatial dependence in an irregular natural forest // *Silva Fenn*. 2008. №42. P. 35.
14. Hanson P.J., Weltzin J.F. Drought disturbance from climate change: Response of United States forests // *Sci. Total Environ*. 2000. №262. P. 205-220.
15. Imanyfar S., Hasanlou M., Zadeh M.M. Mapping oak decline through long-term analysis of time series of satellite images in the forests of Malekshahi, Iran // *International Journal of Remote Sensing*. 2019. Vol. 40, Iss. 23. P. 8705-87262.
16. Levin S.A. *Complex adaptive systems: Exploring the known, the unknown and the unknowable* // Am. Math. Soc. 2003. Vol. 40. P. 3-19.
17. Levin S.A. *Fragile Dominion: Complexity and the Commons* // Perseus Publishing: Cambridge, MA, USA. 1999.
18. Liénard J.F., Gravel D., Strigul N.S. Data-intensive modeling of forest dynamics // *Environ. Model. Softw*. 2015. 67. P. 138-148.
19. Liénard J., Strigul N. An individual-based forest model links canopy dynamics and shade tolerances along a soil moisture gradient // *R. Soc. Open Sci*. 2016. 3. 150589.
20. McCarthy J. Gap dynamics of forest trees: A review with particular attention to boreal forests // *Environ. Rev*. 2001. 9. P. 1-59.
21. Moorcroft P., Hurtt G., Pacala S.W. A method for scaling vegetation dynamics: The ecosystem demography model (ED) // *Ecol. Monogr*. 2001. 71. P. 557-586.
22. Rolnick D. et al. Tackling climate change with machine learning // *ACM Computing Surveys (CSUR)*. 2022. 55.2. P. 1-96.
23. Strigul N. Individual-based models and scaling methods for ecological forestry: Implications of tree phenotypic plasticity // *Sustainable Forest Management*. 2012. P. 359-384.
24. Strigul N., Pristinski D., Purves D., Dushoff J., Pacala. S. Scaling from trees to forests: Tractable macroscopic equations for forest dynamics // *Ecol. Monogr*. 2008. Vol. 78. P. 523-545.
25. Soares F., Flôres E.L., Cabacinha C.D., Carrjo G.A., Veiga A.C. Recursive diameter prediction and volume calculation of eucalyptus trees using Multilayer Perceptron // *Networks, Computers and Electronics in Agriculture*. 2011. Vol. 78, Iss 1. P. 19-27.
26. Time Series Made Easy in Python. URL: <https://unit8co.github.io/darts/>
27. Winters, P.R. Forecasting sales by exponentially weighted moving averages // *Management science*. 1960. P. 324-342.
28. Zhao J., Wang L. Yang H., Wu P., Wang B., Pan C. A Land Cover Classification Method for High-Resolution Remote Sensing Images Based on NDVI Deep Learning Fusion Network // *Remote Sensing*. 2022. Vol. 14, Iss. 21. 5455.

References

1. Kurbanov E.A., Vorob'ev O.N., Lezhnin S.A., Dergunov D.M. Analiz trendov vremennykh ryadov vegetatsionnykh indeksov po dannym MODIS dlya otsenki vliyaniya zasukh na lesnye nasazhdeniya Srednego Povolzh'ya s 2000 po 2020 god (Analysis of trends in time series of vegetation indices according to MODIS data to assess the impact of droughts on forest stands in the Middle Volga region from 2000 to 2020). *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*. 2022. №4. P.181-194.
2. Ashraf M.I., Zhao Z., Bourque A., MacLean D.A., Meng F. Integrating biophysical controls in forest growth and yield predictions generated with artificial intelligence technology. *Canadian Journal of Forest Research*. 2013. 43. P. 1162-1171.

3. Bai S., Kolter J.Z., Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *arXiv*. 2018. 803.01271.
4. Bhering L.L., Junqueira V.S., Peixoto L.A., Cruz C.D., Laviola B.G. Comparison of methods used to identify superior individuals in genomic selection in plant breeding. *Genet Mol Res*. 2015. 14(3):10888-10896.
5. Botkin D.B. *Forest Dynamics: An Ecological Model*. Oxford University Press: Oxford, UK. 1993.
6. Pastor J.; Sharp A.; Wolter P. An application of Markov models to the dynamics of Minnesota's forests. *Can. J. For. Res*. 2005. 35. P. 3011–3019.
7. Buğday E. Application of Artificial Neural Network System Based on ANFIS Using GIS for Predicting Forest Road Network Suitability Mapping. *Fresenius Environmental Bulletin*. 2018. Vol.27, №3. P. 1656-1668.
8. Caswell H. *Matrix Population Models: Construction, Analysis, and Interpretation*. Sinauer Associates: Sunderland, MA, USA. 2001.
9. Davis J., Aliaga-Díaz R., Thomas C.J. *Forecasting Stock Returns: What Signals Matter, and What do They Say Now*. The Vanguard Group: Valley Forge, PA, USA. 2012.
10. Deng Y., Pan J., Wang J. Mapping of Forest Biomass in Shangri-La City Based on LiDAR Technology and Other Remote Sensing Data. *Remote Sensing*. 2022. Vol. 14, Iss. 22. 5816.
11. Doğan S., Buğday E. Modeling of Temporal and Spatial Changes of Land Cover and Land Use by Artificial Neural Networks: Kastamonu Sample. *Journal of Bartın Faculty of Forestry*. 2018. 20 (3): 653-663. doi: 10.24011/barofd.467974.
12. Esteban L.G., Fernandez F.G., De Palacios P. MOE Prediction in *Abies pinsapo* boiss. Timber: application of an artificial neural network using non-destructive testing. *Computers and Structures*. 2009. №87. P. 1360-1365.
13. Fox J.C., Bi H., Ades P.K. Modelling spatial dependence in an irregular natural forest. *Silva Fenn*. 2008. №42. P. 35.
14. Hanson P.J., Weltzin J.F. Drought disturbance from climate change: Response of United States forests. *Sci. Total Environ*. 2000. №262. P. 205-220.
15. Imanyfar S., Hasanlou M., Zadeh M.M. Mapping oak decline through long-term analysis of time series of satellite images in the forests of Malekshahi, Iran. *International Journal of Remote Sensing*. 2019. Vol. 40, Iss. 23. P. 8705-87262.
16. Levin S.A. Complex adaptive systems: Exploring the known, the unknown and the unknowable. *Am. Math. Soc*. 2003. Vol. 40. P. 3-19.
17. Levin S.A. *Fragile Dominion: Complexity and the Commons*. Perseus Publishing: Cambridge, MA, USA. 1999.
18. Liénard J.F., Gravel D., Strigul N.S. Data-intensive modeling of forest dynamics. *Environ. Model. Softw*. 2015. 67. P. 138-148.
19. Liénard J., Strigul N. An individual-based forest model links canopy dynamics and shade tolerances along a soil moisture gradient. *R. Soc. Open Sci*. 2016. 3. 150589.
20. McCarthy J. Gap dynamics of forest trees: A review with particular attention to boreal forests. *Environ. Rev*. 2001. 9. P. 1-59.
21. Moorcroft P., Hurtt G., Pacala S.W. A method for scaling vegetation dynamics: The ecosystem demography model (ED). *Ecol. Monogr*. 2001. 71. P. 557–586.
22. Rolnick D. et al. Tackling climate change with machine learning. *ACM Computing Surveys (CSUR)*. 2022. 55.2. P. 1-96.
23. Strigul N. Individual-based models and scaling methods for ecological forestry: Implications of tree phenotypic plasticity. *Sustainable Forest Management*. 2012. P. 359-384.
24. Strigul N., Pristinski D., Purves D., Dushoff J., Pacala. S. Scaling from trees to forests: Tractable macroscopic equations for forest dynamics. *Ecol. Monogr*. 2008. Vol. 78. P. 523-545.
25. Soares F., Flôres E.L., Cabacinha C.D., Carrijo G.A., Veiga A.C. Recursive diameter prediction and volume calculation of eucalyptus trees using Multilayer Perceptron. *Networks, Computers and Electronics in Agriculture*. 2011. Vol. 78, Iss 1. P. 19-27.
26. Time Series Made Easy in Python. URL: <https://unit8co.github.io/darts/>
27. Winters, P.R. Forecasting sales by exponentially weighted moving averages. *Management science*. 1960. P. 324–342.
28. Zhao J., Wang L. Yang H., Wu P., Wang B., Pan C. A Land Cover Classification Method for High-Resolution Remote Sensing Images Based on NDVI Deep Learning Fusion Network. *Remote Sensing*. 2022. Vol. 14, Iss. 21. 5455.