

УДК 504.38; 51-73

# Нейросетевая модель для оценки потоков углерода в лесных экосистемах по данным дистанционного зондирования Земли

А.П. Розанов<sup>✉</sup>, К.Г. Грибанов\*

Институт естественных наук и математики, Уральский федеральный университет  
620000, г. Екатеринбург, пр. Ленина, 51

Поступила в редакцию 28.07.2022 г.;  
после доработки 15.12.2022 г.;  
принята к печати 27.12.2022 г.

Лесные экосистемы являются одним из главных мест накопления и хранения углерода на Земле. Однако количественная инструментальная оценка потоков углекислого газа возможна лишь для участков радиусом 100–2000 м вокруг измерительной станции. При решении задачи масштабирования используются методы машинного обучения, способные аппроксимировать наблюдения с помощью интенсивностей излучения земной поверхности в разных спектральных интервалах в наземные наблюдения *in situ*. Представлены результаты оценки потоков углерода регрессионной нейросетевой моделью типа многослойный персепtron, обученной на данных сети FLUXNET для станции, расположенной в boreальном хвойном лесу ( $56,4615^\circ$  с.ш.,  $32,9221^\circ$  в.д.). Используя в качестве входных данных вегетационные индексы NVDI и EVI, полученные спектрорадиометром MODIS на спутнике Aqua, температуру воздуха на высоте 2 м и суммарное количество осадков при помощи моделидается оценка первичной валовой продукции (GPP), чистому экосистемному обмену (NEE), экосистемному дыханию (TER) и ряду других величин, характеризующих потоки воды и энергии. Проведенные статистические оценки демонстрируют высокие коэффициенты корреляции ( $R$ ) и Нэша–Сатклиффа (NSE) на тестовом наборе данных: для GPP и TER –  $R \geq 0,9$ ; NSE  $\geq 0,87$ ; для NEE –  $R = 0,4$ , NSE = 0,15.

**Ключевые слова:** нейронные сети, машинное обучение, потоки углерода, FLUXNET, MODIS; neural networks, machine learning, carbon fluxes, FLUXNET MODIS.

## Введение

С увеличением содержания углекислого газа в атмосфере Земли и связанного с этим потепления климата значительно возросла актуальность анализа углеродного цикла экосистем с целью определения восходящих и нисходящих потоков CO<sub>2</sub>. Известно, что у лесных экосистем есть способность запасать углерод из атмосферы (секвестрировать) и при определенных условиях хранить его достаточно долгое время. Детальное изучение конкретной экосистемы с использованием различных методов оценки потоков углерода возможно *in situ*. На данный момент создана глобальная сеть микрометеорологических станций FLUXNET, предоставляющая ряды измерений потоков углекислого газа, воды и энергии между биосферой и атмосферой с разным временным разрешением [1].

Однако существует необходимость получения данных в масштабах области, страны, континента, т.е. когда прямое измерение потоков невозможно. Технологии же спутникового мониторинга предоставляют информацию с глобальным покрытием. На данный момент создано большое количество технологий обращения спутниковых данных с целью оценки атмосферных концентраций парниковых газов и их потоков с подстилающей поверхности в атмосферу (см., например, [2–4]). Методы отличаются уровнем сложности и вычислительными ресурсами, которые необходимо привлекать для их реализации. Выделяют два типа моделей: первый основан на моделировании процессов (process-based) [5], второй – на данных (data-driven) [6]. Первый тип подразумевает существование динамического ядра (системы дифференциальных уравнений), которое описывает физическую взаимосвязь между переменными. В моделях 2-го типа с помощью одного из видов машинного обучения и большого набора данных устанавливается зависимость между переменными. Помимо выигрыша во времени, модели машинного обучения могут извлекать

\* Алексей Павлович Розанов (alexey.rozanov@urfu.ru); Константин Геннадьевич Грибанов (kgribanov@remotesensing.ru).

многомерные функциональные связи между потоками, измеренными *in situ*, и данными дистанционного зондирования Земли (ДЗЗ). Существует целый класс методов усвоения спутниковых данных на основе машинного обучения (метод опорных векторов [7], нейросетевое моделирование [8], случайный лес [9] и др.). Их сопоставление [10] продемонстрировало высокую степень точности искусственных нейронных сетей.

Цель данной работы – создание модели для предсказания потоков углерода в boreальных лесных экосистемах, которая бы обучалась на данных ДЗЗ на входе и инструментальных измерениях, выполненных методом турбулентных пульсаций и предоставленных сетью FLUXNET, на выходе, а также могла бы быть верифицирована и использована для оценки потоков в экосистемах такого же типа на новых станциях. В качестве источника данных была выбрана станция RU-Fyo в хвойном boreальном лесу в Тверской обл. с координатами 56,4615° с.ш., 32,9221° в.д. [11] в Центрально-Лесном государственном природном биосферном заповеднике.

## Данные дистанционного зондирования

С помощью мультиспектральных данных многоканальных спектрорадиометров возможна оценка величин, которые характеризуют растительную биомассу на поверхности земли: NDVI и EVI [12]. NDVI представляет собой нормализованный относительный вегетационный индекс, который является показателем количества фотосинтетически-активной биомассы. Вычисляется он по формуле

$$NDVI = \frac{NIR - RED}{NIR + RED}, \quad (1)$$

где NIR и RED – интенсивности отраженного солнечного света в ближней инфракрасной (841–876 нм) и красной (620–670 нм) областях спектра.

EVI – улучшенный индекс для работы с растительностью с высоким индексом листовой поверхности:

$$EVI = 2,5 \cdot \frac{NIR - RED}{NIR + 6RED - 7,5BLUE + 1}. \quad (2)$$

При вычислении EVI дополнительно используется канал в синей области спектра, обозначенный как BLUE и представляющий интенсивность отраженного солнечного света в интервале 459–479 нм.

В настоящей работе были использованы данные со спутника NASA Aqua в рамках проекта EOS с установленным на борту спектрорадиометром MODIS (MODerate resolution Imaging Spectroradiometer) [13] с 36 спектральными каналами с пространственным разрешением 250, 500 м и 1 км. MODIS позволяет создавать глобальные карты нескольких характеристик поверхности земли, включая двунаправленный коэффициент отражения по-

верхности, альbedo, температуру поверхности земли и вегетационные индексы.

Сервис NASA Earth Data [14] предоставляет возможность получить готовые продукты: MYD13Q1 с вегетационными индексами NDVI и EVI с 16-дневным периодом осреднения с разрешением 250 м за 2002–2014 гг. в виде текстовых файлов.

## Ретроспективный климатический анализ ERA5

*Климатический ретроспективный анализ* – это метод создания численного описания климата в том виде, в каком он развивался в недавнем прошлом. Данный процесс основан на климатической модели, которая, моделируя глобальную циркуляцию атмосферы, одновременно ассимилирует разрозненные наблюдения физически согласованным образом, что позволяет создавать однородные (на регулярной пространственной и временной сетках) наборы данных для широкого списка переменных, включая те, которые наблюдаются редко или не наблюдаются напрямую (ветер в стратосфере, поток радиации, влажность почвы в корневой зоне и др.). Целью этого метода является извлечение максимального количества информации из всех доступных инструментальных измерений, используя различные типы наблюдений (метеостанции, ДЗЗ, радары и др.). Обработка информации из разных источников делает возможным уменьшение погрешностей, позволяет обнаружить промахи в измерениях и в некоторых случаях даже исправить их. Глобальный реанализ обычно охватывает период в несколько десятилетий с частотой от одного часа до одного месяца.

В рамках настоящей работы были использованы ежечасные метеорологические данные (температура воздуха на высоте 2 м, общее количество осадков) ретроспективного климатического анализа ERA5 для выбранной точки за период с 4.07.2002 г. по 31.12.2014 г., полученные с помощью сервиса ECMWF Copernicus [15] в формате NetCDF4.

## FLUXNET

*Метод турбулентных пульсаций* [16] позволяет осуществлять прямые измерения потоков углеродсодержащих газов ( $\text{CO}_2$ ,  $\text{CH}_4$ ) и воды между покрытой растительностью площадкой и атмосферой за малые и большие промежутки времени (часы, дни, сезоны, годы). Одно из его преимуществ – возможность оценки потоков с относительно больших территорий (обычно характерный радиус площадки варьируется в пределах 100–2000 м вокруг измерительной станции [17]). Однако этот метод применим только для равнин со стабильными атмосферными условиями.

С помощью сервиса FLUXNET, предоставляющего данные глобальной сети микрометеорологических станций, становится возможна

количественная оценка секвестрирования углерода в экосистеме. Одним из ключевых показателей является NPP (net primary production) – чистая первичная продукция, которая определяется как

$$\text{NPP} = \text{GPP} - R_a, \quad (3)$$

где GPP (gross primary production) – валовая первичная продукция,  $R_a$  – автотрофное дыхание экосистемы.

Показатель углеродного баланса экосистемы NEE [18] (net ecosystem exchange) учитывает гетеротрофное дыхание животных и микробов:

$$\text{NEE} = \text{GPP} - R_a - R_h, \quad (4)$$

где  $R_h$  – гетеротрофное дыхание экосистемы.

## Многослойный персепtron

Среди множества видов моделей машинного обучения для решения задачи регрессии была выбрана искусственная нейронная сеть типа многослойный персептрон, где каждый нейрон осуществляет линейную регрессию с последующим применением нелинейной функции активации. При обучении моделей разной архитектуры нами было выявлено, что персептрон с двумя скрытыми слоями (рис. 1) обеспечивает наиболее высокую точность при приемлемых временных затратах на обучение.

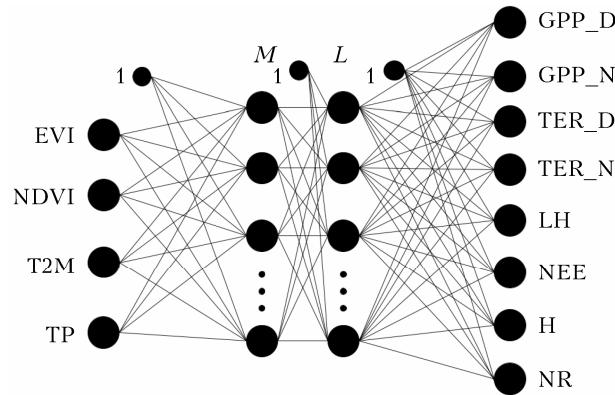


Рис. 1. Архитектура многослойного персептрона;  $M$ ,  $L$  — количество нейронов в скрытых слоях, остальные обозначения см. в тексте

Для работы с моделью были созданы два набора данных: тренировочный (100 входных и выходных векторов) и тестовый (185 пар векторов). Первый необходим для того, чтобы обнаружить зависимость между входными и выходными параметрами (обучить нейронную сеть), второй – для оценки качества обучения. Для тестового набора был рассчитаны коэффициенты корреляции ( $R$ ) между  $j$ -м выходным параметром сети  $y_j$  и соответствующим ему желаемым параметром  $d_j$ , а также коэффициенты эффективности модели Нэша–Сатклиффа (NSE) [19], определяемые по формуле

$$\text{NSE}_j = 1 - \frac{\sum_{i=1}^N (y_{ij} - d_{ij})^2}{\sum_{i=1}^N (d_{ij} - (\bar{d}_j))^2}, \quad (5)$$

где  $y_{ij}$  – значение, выдаваемое моделью на  $j$ -м выходе для  $i$ -го тестового входного вектора;  $d_{ij}$  – желаемое значение на  $j$ -м выходе для  $i$ -го тестового выходного вектора;  $(\bar{d}_j)$  – экспериментальное среднее значение на  $j$ -м выходе.

Для обучения сети была выбран алгоритм обратного распространения ошибки, основанный на расчете среднеквадратичной функции ошибки

$$E(w) = \sum_{j=1}^8 \sum_{i=1}^N (y_{ji}(w) - d_{ij})^2, \quad (6)$$

где  $w$  – все веса связей нейронной сети. В каждой эпохе (цикле обучения) после расчета ошибки происходит оптимизация весов методом градиентного спуска [20] по формуле

$$\omega = \omega - \eta \nabla E(\omega), \quad (7)$$

где  $\eta$  — скорость обучения.

На выход модели подавались ежедневные данные с сервиса FLUXNET, упомянутые выше: GPP (дневной и ночной), NEE, TER (terrestrial respiration – дыхание экосистемы) – дневной и ночной, LH (latent heat – скрытая теплота), H (heat – явная теплота) и NR (net radiation – чистая радиация, т.е. разница между поступающим и излучаемым длинноволновым и коротковолновым излучением). В качестве входных векторов были использованы вегетационные индексы EVI, NDVI, температура воздуха на высоте 2 м (T2M) и суммарное количество осадков (TP). Программное обеспечение создано на языке Python с помощью пакета PyTorch [21].

## Результаты

Созданное программное обеспечение позволяет менять множество параметров нейронной сети (количество нейронов в скрытых слоях, функции активации нейронов, функция ошибки, скорость обучения и т.д.). Таким образом было получено несколько десятков различных моделей, демонстрирующих разную точность. Наибольшие коэффициенты корреляции обеспечила модель с количеством нейронов в скрытых слоях, равным 300 и 400 соответственно. В качестве функции активации была использована сигмоидная функция, а невязка (рис. 2) определялась как среднеквадратическая. Наилучшие результаты с точки зрения скорости обучения получены при обновлении весов с помощью стохастического градиентного спуска, оценивающего градиент целевой функции для одного случайно выбранного выходного вектора на каждой итерации.

После анализа полученных результатов (рис. 3 и 4) можно сделать вывод, что модель демонстрирует высокую точность оценки дневных иочных

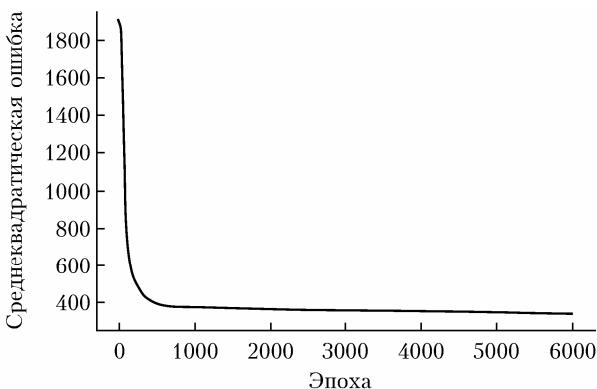


Рис. 2. График зависимости невязки от количества эпох

значений GPP и TER ( $R > 0,9$ ;  $NSE \geq 0,87$ ) и с меньшей точностью прогнозирует LH ( $R = 0,88$ ;  $NSE = 0,78$ ).

Однако результаты работы модели свидетельствуют об отсутствии явной зависимости ( $R = 0,4$ ;  $NSE = 0,15$ ) между входными параметрами (NDVI, EVI, среднесуточная температура на высоте 2 м и суммарное количество осадков) и NEE. Согласно работе [22] NEE зависит от других параметров, отличных от входных данных построенной модели, таких как функциональный тип растений, влажность, эвапотранспирация, разница между дневной и ночной температурами воздуха, что подтверждают полученные данные.

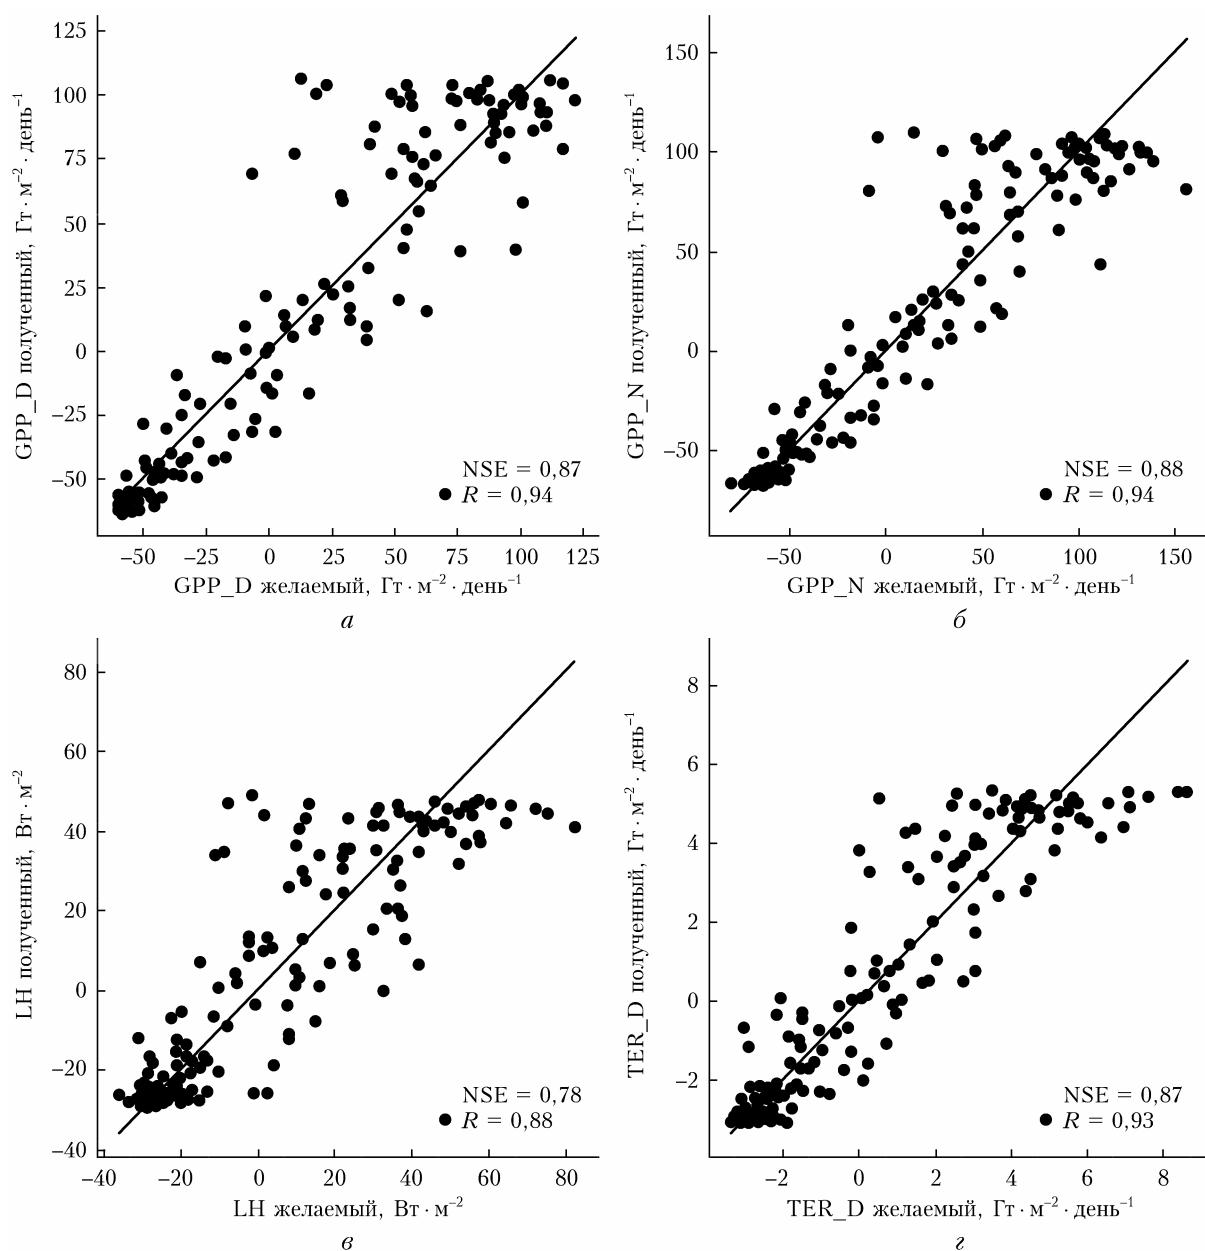


Рис. 3. Результат работы нейронной сети на тестовом наборе данных с коэффициентами корреляции для параметров GPP\_D (a), GPP\_N (б), LH (в), TER\_D (г); желаемый параметр — это известное значение (целевая переменная), полученный — оценка модели

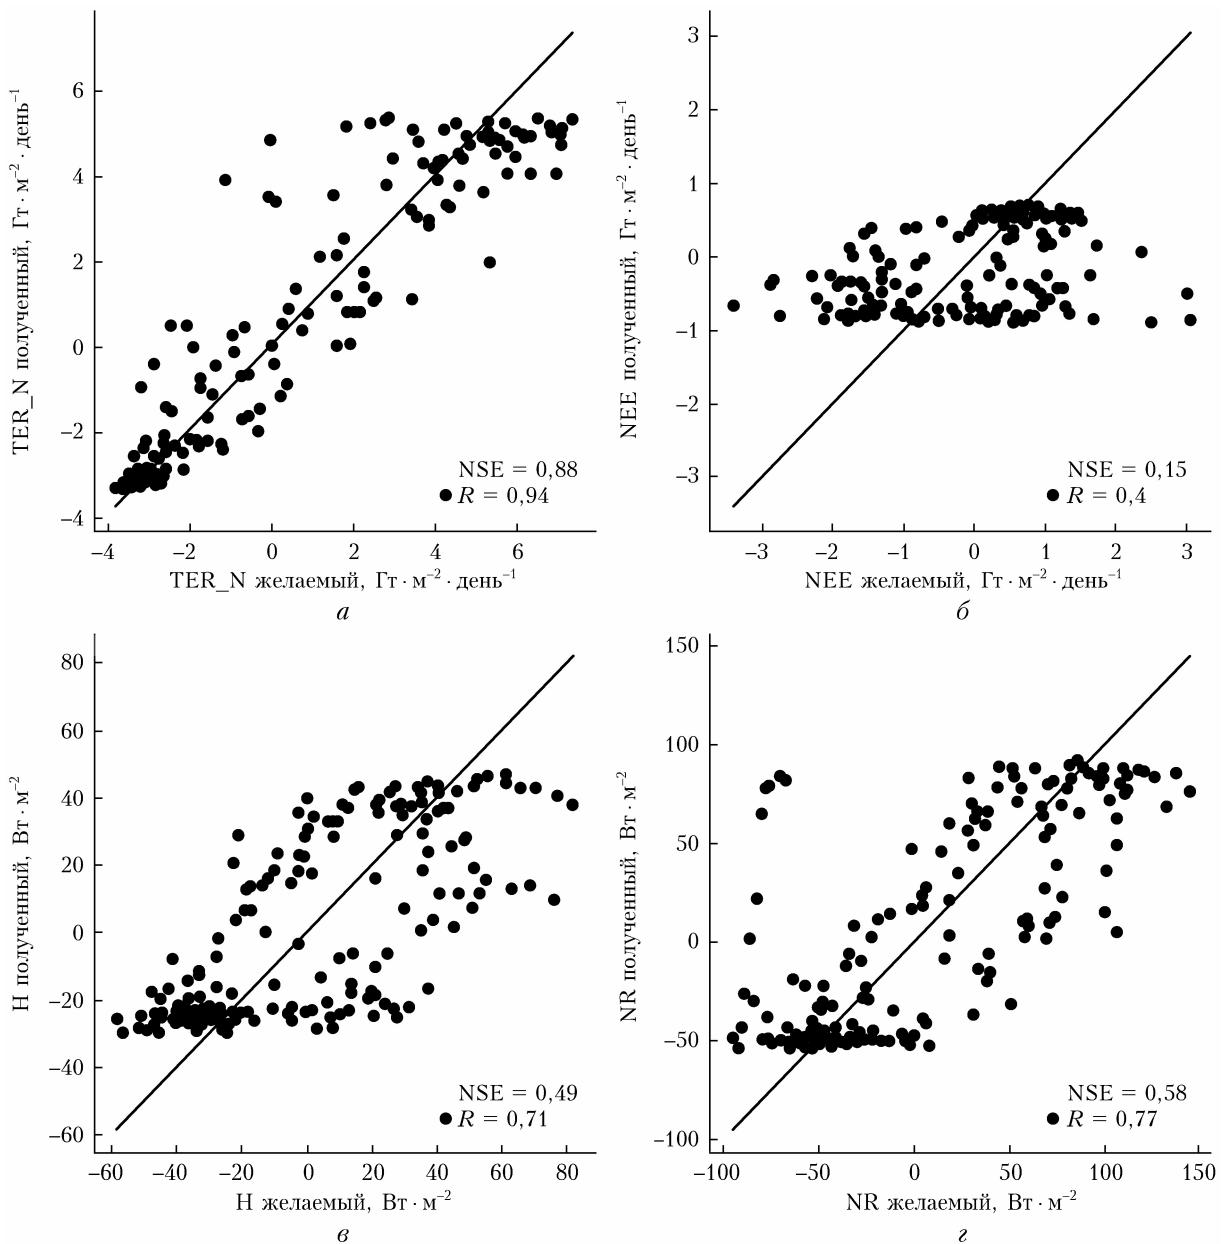


Рис. 4. Результат работы нейронной сети на тестовом наборе данных с коэффициентами корреляции для параметров TER\_N (а), NEE (б), H (в), NR (г)

Для явной теплоты H и чистой радиации NR  $R = 0,71$  и  $0,77$ , а NSE =  $0,49$  и  $0,58$ , что может говорить о том, что обнаружена функциональная зависимость между  $H$  и  $R$  и входными параметрами модели, однако есть другие метрики, определяющие потоки чистой радиации и явной теплоты, которые не были нами использованы при создании набора данных.

### Заключение

Таким образом, обученная модель типа многослойный персептрон пригодна для оценки потоков углерода, воды и лучистой энергии по данным дис-

танционного зондирования (EVI и NDVI) и метеорологическим параметрам (температура воздуха на высоте 2 м и суммарное количество осадков). Коэффициенты корреляции и Нэша–Сатклиффа на тестовом наборе данных: для валового первичного продукта (GPP)  $R \geq 0,94$ , NSE =  $0,87$ ; для экосистемного дыхания (TER)  $R \geq 0,93$ , NSE  $\geq 0,87$ ; для чистого экосистемного обмена (NEE)  $R = 0,4$ , NSE =  $0,15$ ; для скрытой теплоты (LH)  $R = 0,88$ , NSE =  $0,78$ ; для явной теплоты (H)  $R = 0,71$ , NSE =  $0,49$ ; для чистой радиации (NR)  $R = 0,77$ , NSE =  $0,58$ .

Результаты оценки свидетельствуют о том, что не была установлена связь между входными па-

метрами модели и коэффициентом чистого экосистемного обмена ( $NEE, R = 0,4$ ,  $NSE = 0,15$ ).

Модель типа многослойный персепtron продемонстрировала пригодность для оценки первичной валовой продукции и экосистемного дыхания по спутниковым и метеорологическим данным на сравнительно небольшом обучающем наборе для boreальной лесной экосистемы на территории РФ.

Перспективным направлением дальнейших исследований, согласно результатам работы, является применение нескольких видов моделей машинного обучения (с помощью ансамблевых методов) и расширение обучающего набора данных с помощью дискретных величин, определяющих типы растительности, почвы и др., а также параметров, характеризующих долю поглощенной фотосинтетической радиации, почвенное дыхание и др.

**Финансирование.** Исследования выполнены при финансовой поддержке Министерства высшего образования и науки РФ (проект № FEUZ-2023-0023).

## Список литературы

1. Baldocchi D., Falge E., Gu L., Olson R., Hollinger D., Running S., Anthoni P., Bernhofer Ch., Davis K., Evans R., Fuentes J., Goldstein A., Katul G., Law B., Lee X., Malhi Y., Meyers T., Munger W., Oechel W., Paw U.K.T., Pilegaard K., Schmid H.P., Valentini R., Verma S., Vesala T., Wilson K., Wofsy S. FLUXNET: A new tool to study the temporal and spatial variability of ecosystem-scale carbon dioxide, water vapor, and energy flux densities // Bull. Am. Meteorol. Soc. 2001. V. 82, N 11. P. 2415–2434.
2. Грибанов К.Г., Имасу Р., Захаров В.И. Нейронные сети для определения высотных профилей  $\text{CO}_2$  по данным GOSAT/TANSO-FTS // Оптика атмосф. и океана. 2009. Т. 22, № 9. С. 890–895; Gribanov K.G., Imasu R., Zakharov V.I. Neural networks for  $\text{CO}_2$  profile retrieval from the data of GOSAT/TANSO-FTS // Atmos. Ocean. Opt. 2010. V. 23, N 1. P. 42–47.
3. Rolnick D., Donti P.L., Kaack L.H., Kochanski K., Lacoste A., Sankaran K., Slavin Ross A., Milojevic-Dupont N., Jaques N., Waldman-Brown A., Lucchini A., Maharaj T., Sherwin E.D., Karthik Mukkavilli S., Kording K.P., Gomes C., Ng A.Y., Hassabis D., Platt J.C., Creutzig F., Chayes J., Bengio Y. Tackling climate change with machine learning // ACM Computing Surveys (CSUR). 2022. V. 55, N 2. P. 1–96.
4. Heermann P.D., Khazenie N. Classification of multispectral remote sensing data using a back-propagation neural network // IEEE Trans. Geosci. Remote Sens. 1992. V. 30, N 1. P. 81–88.
5. Cao M., Marshall S., Gregson K. Global carbon exchange and methane emissions from natural wetlands: Application of a process-based model // J. Geophys. Res.: Atmos. 1996. V. 101, N D9. P. 14399–14414.
6. Dou X., Yang Y., Luo J. Estimating forest carbon fluxes using machine learning techniques based on eddy covariance measurements // Sustainability. 2018. V. 10, N 1. P. 203.
7. Yu T., Zhang Q., Sun R. Comparison of machine learning methods to up-scale gross primary production // Remote Sensing. 2021. Т. 13, № 13. С. 2448.
8. Поляков А.В. Использование метода искусственных нейронных сетей при восстановлении вертикальных профилей атмосферных параметров // Оптика атмосф. и океана. 2014. Т. 27, № 1. С. 34–39; Polyakov A.V. The method of artificial neural networks in retrieving vertical profiles of atmospheric parameters // Atmos. Ocean. Opt. 2014. V. 27, N 3. P. 247–252.
9. Zeng J., Matsunaga T., Tan Z.-H., Saigusa N., Shirai T., Tang Y., Peng S., Fukuda Y. Global terrestrial carbon fluxes of 1999–2019 estimated by upscaling eddy covariance data with a random forest // Scientific Data. 2020. V. 7, N 1. P. 1–11.
10. Tramontana G., Jung M., Schwalm C.R., Ichii K., Camps-Valls G., Ráduly B., Reichstein M., Arain M.A., Cescatti A., Kiely G., Merbold L., Serrano-Ortiz P., Sickert S., Wolf S., Papale D. Predicting carbon dioxide and energy fluxes across global FLUXNET sites with regression algorithms // Biogeosciences. 2016. N 13. P. 4291–4313. DOI: 10.5194/bg-13-4291-2016.
11. Kurbatova J., Li C., Varlagin A., Xiao X., Vygodskaya N. Modeling carbon dynamics in two adjacent spruce forests with different soil conditions in Russia // Biogeosciences. 2008. V. 5, N 4. P. 969–980.
12. Zhengxing W., Chuang L., Alfredo H. From AVHRR-NDVI to MODIS-EVI: Advances in vegetation index research // Acta Ecologica Sinica. 2003. V. 23, N 5. P. 979–987.
13. ORNL DAAC 2018. MODIS and VIIRS Land Products Global Subsetting and Visualization Tool. ORNL DAAC, Oak Ridge, Tennessee, USA. Accessed February, 2022. Subset obtained for MYD13Q1 product at 56,46,32,92, time period: [04.07.2002] to [31.12.2014], and subset size: 0.250 × 0.250 km. DOI: 10.3334/ORNLDaac/1379.
14. NASA Earth Data Portal; Mission and Measurements; MODIS Terra&Aqua. URL: <https://ladsweb.modaps.eosdis.nasa.gov/missions-and-measurements/modis/>.
15. ECMWF Copernicus Climate Change Data Service; ERA5 hourly land products. URL: <https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-land?tab=form>.
16. Baldocchi D., Hicks B., Meyers T. Measuring biosphere-atmosphere exchanges of biologically related gases with micrometeorological methods // Ecology. 1988. V. 69. P. 1331–1340. DOI: 10.2307/1941631.
17. Schmid H.P. Source areas for scalars and scalar fluxes // Bound.-Layer Meteorol. 1994. V. 67. P. 293–318. DOI: 10.1007/BF00713146.
18. Reichle D.E. The Global Carbon Cycle and Climate Change: Scaling Ecological Energetics from Organism to the Biosphere. Elsevier, 2020. P. 150–152. DOI: 10.1016/C2019-0-01382-9.
19. Nash J.E., Sutcliffe J.V. River flow forecasting through conceptual models part I – A discussion of principles // J. Hydrol. 1970. V. 10, N 3. P. 282–290.
20. Bottou L. Large-scale machine learning with stochastic gradient descent // Proc. COMPSTAT'2010, 2010. P. 177–186.
21. Paszke A., Gross S., Massa F., Lerer A., Bradbury J., Chanan G., Killeen T., Lin Z., Gimelshein N., Antiga L., Desmaison A., Kopf A., Yang E., DeVito Z., Raison M., Tejani A., Chilamkurthy S., Steiner B., Fang L., Bai J., Chintala S. PyTorch: An imperative style, high-performance deep learning library // Adv. Neural Inform. Proces. Syst. 2019. V. 32. P. 8024–8035.

22. Huang N., Wang L., Zhang Y., Gao S., Niu Z. Estimating the Net Ecosystem Exchange at global FLUXNET sites using a random forest model // IEEE J. Sel. Top. Appl. Earth Observ. Remote Sens. 2021. V. 14. P. 9826–9836. DOI: 10.1109/JSTARS.2021.3114190.

**A.P. Rozanov, K.G. Gribanov. Neural network model for estimation of the carbon fluxes in forest ecosystems from remote sensing data.**

Forests are among the main places on Earth where carbon is collected and accumulated. However, quantitative instrumental assessment of carbon fluxes is possible only for small-scale areas. When solving the scaling problem, we use machine learning methods, which can transform the values of the intensity of the Earth's surface reflectance in different spectral intervals into ground-based *in situ* observations. The assessments of carbon fluxes by a regression neural network model of the multilayer perceptron type trained on FLUXNET network data for a station located in a boreal coniferous forest (56.4615°N, 32.9221°E) are presented. Using vegetation indices NDVI and EVI measured by MODIS Aqua, air temperature at an altitude of 2 m, and total precipitation as input data, the model estimates of gross primary production (GPP), net ecosystem exchange (NEE), ecosystem respiration (TER), and some other parameters describing water and energy fluxes are calculated. Statistical estimation provides high values of the correlation coefficient and Nash–Sutcliffe coefficient on test dataset:  $R > 0.9$  and  $\text{NSE} \geq 0.87$  for GPP and TER;  $R = 0.4$  and  $\text{NSE} = 0.15$  for NEE.