

НЕЙРОСЕТЕВАЯ МОДЕЛЬ ОЦЕНКИ УГЛЕРОДНОГО БАЛАНСА ЛЕСНОЙ ЗОНЫ МЕТОДОМ СЕМАНТИЧЕСКОЙ СЕГМЕНТАЦИИ

Тулохонова И.С.

*Восточно-Сибирский государственный университет технологий и управления,
Улан-Удэ, Россия
istulokhonova@mail.ru*

Михайлова С.С., Данилова С.Д.

*Финансовый университет при Правительстве Российской Федерации, Москва, Россия
ssmihajlova@fa.ru, dan-soelma@yandex.ru*

Аннотация. Статья посвящена разработке нейросетевой модели оценки углеродного баланса лесной зоны методом семантической сегментации с использованием модели сверточной нейронной сети. Экспериментальные данные, полученные разработанным прототипом ПО, позволили сделать вывод, что модель будет способствовать сбалансированному управлению лесовосстановлением и посадкой углерода.

Ключевые слова: углеродный баланс, нейронная сеть, семантическая сегментация, лесной массив, региональная лесная экосистема.

Введение

Проблема инвентаризации углеродного баланса в отношении лесов приобретает важный прикладной аспект. Леса, выполняющие функцию поглощения парниковых газов, признаны Рамочной конвенцией ООН по изменению климата.

Наиболее объективную информацию об углеродном балансе можно получить путем прямых измерений потоков и обмена углерода между атмосферой и экосистемой. Однако для этого требуется использование специального дорогостоящего оборудования. В настоящее время накопленные экспериментальные данные недостаточны для региональной оценки углеродного обмена, и поэтому невозможно измерить содержание углерода или уровень углеродного обмена между региональной лесной экосистемой и атмосферой, за исключением отдельных участков и ограниченных временных рамок [1], [2].

В этой связи особенно актуальна задача совершенствования методов учета поглощения парниковых газов, включая оценку запасов углерода в надземной и подземной биомассе различных экосистем. От решения этой задачи зависит возможность обеспечить объективную и полную оценку общего углеродного баланса страны и осуществление национальных политик в соответствии с Соглашением о климате.

1. Математическая модель оценки углеродного баланса

Для оценки углеродного баланса используется метод расчета изменения запасов углерода за определенный период времени [3]. Суть метода заключается в оценке общих запасов углерода в конкретном пуле для разных моментов времени с последующим распределением разницы в запасах по временному интервалу согласно следующему уравнению [2], [4]:

$$\Delta C_{FFLB} = \frac{C_{t2} - C_{t1}}{t_2 - t_1}, \quad (1)$$

$$C = [V \times D \times BEF] \times (1 + R) \times CF, \quad (2)$$

где:

ΔC_{FFLB} – годовой углеродный баланс в живой фитомассе (включая надземную и подземную) на лесных участках, тонн в год;

C_{t1} – запас углерода в фитомассе, рассчитанный в момент времени t_1 ;

C_{t2} – запас углерода в фитомассе, рассчитанный в момент времени t_2 ;

V – товарный запас древесины, м³/га;

D – плотность абсолютно сухой древесины, тонна сухого вещества / м³ запасов;

BEF – коэффициент прироста фитомассы для преобразования запаса древесного сырья в надземную фитомассу деревьев, безразмерная величина;

R – соотношение массы корней и побегов, безразмерная величина;

CF – доля углерода в сухом веществе (по умолчанию = 0,5), тонна углерода / тонна сухого вещества.

Данные о коэффициенте прироста фитомассы, плотности и товарном запасе древесины хвойных пород являются справочными [5]. Также учитываются климатические зоны, вид и возраст древостоя, состав почвы и т.д.

2. Семантическая сегментация объектов лесной экосистемы

Интеграционные тенденции в развитии систем дистанционного зондирования земной поверхности и возросший интерес к использованию методов машинного обучения в различных сферах деятельности определяют актуальность моделирования нейронных сетей в задаче семантической сегментации лесных экосистем.

Семантическая сегментация является высокоуровневым методом при обработке изображений и эффективно используется в задачах классификации с использованием алгоритмов машинного обучения [6], включая антропогенное воздействие на природную среду. Согласно преобладающим представлениям, одну из ведущих ролей в этом воздействии играет углеродный баланс наземных экосистем [7].

Вопросам построения углеродного баланса региональной лесной экосистемы посвящены исследования А.М. Алферова, Б.Г. Блинова, М.Л. Гитарского, В.А. Грабаря, Д.Г. Замолодчикова, А.Б. Зинченко, Х.П. Иванова, Б.М. Ивахова и др. [1], [8], [9].

В работе для решения задачи семантической сегментации изображений предложен и протестирован метод дистанционного зондирования, который сочетает объектно-ориентированный подход в анализе спутниковых изображений с алгоритмом классификации, основанным на методе обработки индексов. Тематическая обработка композитного изображения выполнена с использованием спутников Sentinel-2 с диффузным отражением, которые показали эффективность измерения плотности и площади лесных участков, а также фиксации различных изменений в них.

Для апробации метода дистанционного зондирования выбрана лесная территория в Кабанском районе Республики Бурятия, и исследованы ее спутниковые снимки Sentinel-2 с наилучшим пространственным разрешением и рядом спектральных каналов от 32 до 39. В качестве исходных данных использовались безоблачные сцены Sentinel-2 с пространственным разрешением 10 метров на протяжении летних сезонов пяти лет. Применяемая технология спутникового мониторинга позволяет наблюдать изменения в вегетационном индексе, полученном спектральным анализом спутниковых изображений высокого разрешения.

Спектральная обработка изображений возможна на основе нормализованного относительного индекса вегетации $NDVI$, поскольку, по нашему мнению, этот подход эффективен для выражения состояния растительности и их количественных характеристик:

$$NDVI = \frac{N_b - R_0}{N_b + R_0}, \quad (3)$$

где:

N_b – отражение в ближней инфракрасной области спектра;

R_0 – отражение в инфракрасной области спектра.

Наблюдая, что датчики Sentinel-2 имеют необходимые полосы с отражением в ближней инфракрасной области спектра N_b и в красной области спектра R_0 , приходим к выводу, что изображение, обработанное с помощью $NDVI$, легче сегментировать, поскольку, основываясь на индексах, растительность довольно четко разделена от других природных объектов. Присвоение индекса и цветового градиента каждому пикселю соответствует изображению обработанного изображения.

Значение и соответствующие классы индекса $NDVI$ приведены в таблице 1.

Таблица 1. Значения и классы индексов $NDVI$

Значение индекса	Класс индекса
Близкое к -1	Водоемы
От -0.1 до 0.1	Бесплодные участки (камни, песок или снег)
От 0.2 до 0.4	Кустарники и пастбища
Близкое к 1	Лесные массивы

Для оценки углеродного баланса используется метод расчета изменения запасов углерода за определенный период времени. Основная концепция метода заключается в оценке общих запасов углерода для различных моментов времени с дальнейшей корреляцией разницы в запасах с интервалом времени в соответствии с методологической основой расчетов углеродного бюджета, описанной в [10].

3. Сверточная нейросетевая модель архитектуры U-net

Семантическая сегментация изображения выполняется с использованием сверточной нейронной сети CNN модели U-net, на вход которой подается изображение, а на выходе мы получаем одноканальную карту вероятной площади определенных классов лесных объектов.

В то же время, при построении карты объектов, все изображение сканируется устройством, состояния которого хранятся в зарезервированных местах на карте объектов. Эта конструкция эквивалентна операции свертки, за которой следует аддитивный член смещения и сигмовидная функция:

$$y^{(d)} = \sigma \cdot (W \cdot y^{(d-1)} + b), \quad (4)$$

где d – глубина сверточного слоя, W – весовая матрица, а b – смещение. Использование разреженной весовой матрицы уменьшает количество настраиваемых параметров сети и, таким образом, увеличивает ее способность к обобщению. Умножение W на входные данные слоя формирует свертку входных данных с использованием w , которую можно рассматривать как обучаемый фильтр. Если входные данные для сверточного слоя $d-1$ имеют размерность $N \times N$, а воспринимающее поле единиц измерения в определенной плоскости сверточного слоя d имеет размерность $m \times m$, то построенная карта объектов будет представлять собой матрицу размеров $(N-m+1) \times (N-m+1)$. В частности, элемент карты объектов в позиции (i, j) может быть определен как:

$$y_{ij}^{(d)} = \sigma \cdot (x_{ij}^{(d)} + b), \quad (5)$$

тогда, как:

$$x_{ij}^{(d)} = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} \omega_{ab} \cdot y_{(i+a)(j+b)}^{(d-1)}, \quad (6)$$

где b – скалярная величина.

Используя формулы (5) и (6) последовательно для входных позиций (i, j) , строится карта объектов для соответствующей плоскости.

Модель нейронной сети состоит из четырех блоков уровней, содержащих два сверточных слоя с пакетной нормализацией и функцией активации ReLU:

$$A(x) = \max(0, x). \quad (7)$$

При обучении нейронной сети для семантической сегментации используются несколько гиперпараметров, включая:

- размер пакета (batch size): количество изображений, используемых одновременно для обновления весов сети во время обучения, равно 300;
- скрытая размерность (hidden dimension): количество сверточных фильтров в каждом слое модели составляет 10, 20, 40 и 80. Узкое место модели имеет 160 сверточных фильтров. В кодирующих слоях используются связи проходимости с соответствующими слоями в декодирующей части;
- количество слоев сверточной нейронной сети, используемых для извлечения характеристик изображения, составляет 9;
- размер ядра (kernel size): размер ядра, используемого для свертки изображения на каждом слое сверточной нейронной сети, составляет 3×3 ;
- шаг свертки (stride): количество пикселей, на которое ядро свертки перемещается при применении свертки на каждом слое сверточной нейронной сети, равно двум;
- размер входного изображения: размер входного изображения, используемого для обучения и тестирования сверточной нейронной сети, составляет 256×256 .

20% от общего размера набора данных выделяется для тестирования. Входные данные представляют собой трехканальное изображение лесной области, а на выходе получаем одноканальную карту вероятной области определенной характеристики того же размера лесной области, которая преобразуется в двоичную маску сегментации с использованием порога. На рисунке 1 показана архитектура построенной нейронной сети на основе модели U-net [7].

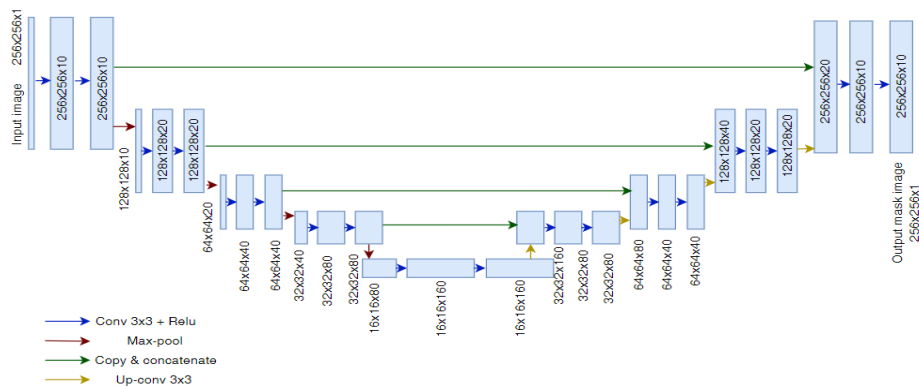


Рис. 1. Архитектура нейронной сети

На выходе нейронной сети имеем нелинейную функцию активации, которая принимает ту же линейную комбинацию, что и на входе. Наиболее исторически популярной и до сих пор часто используемой функцией активации является логистическая сигмовидная функция:

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (8)$$

Для оценки производительности и функциональности модели нейронной сети используется функция потери перекрестной энтропии, на выходе которой получается значение вероятности в диапазоне от 0 до 1:

$$H(P, Q) = -\sum_x P(x), \quad (9)$$

где P представляет распределение вероятностей фактического изображения, тогда как Q определяет распределение вероятностей, предсказанное моделью.

Следуя формуле (9), перекрестная энтропия вычисляется путем сравнения фактических меток с вероятностными предсказаниями модели. Чем больше разница между фактическим распределением меток и прогнозируемым распределением, тем выше значение перекрестной энтропии. В нашем случае это чувствительный показатель, равный 0,012.

Для обучения нейронной сети первоначально инициализируется набор данных с изображениями и масками. Затем набор данных делится на обучающие и эволюционные выборки для обучения нейронной сети и прогнозирования данных.

Основные этапы обучения нейронной сети включают в себя:

- инициализация набора данных спутниковых снимков;
- нормализация данных;
- инициализация архитектуры CNN модели U-net;
- составление NS;
- тренировочный цикл;
- вывод результатов;
- оценка результатов.

Обобщенная модель нейронной сети представлена на рисунке 2.

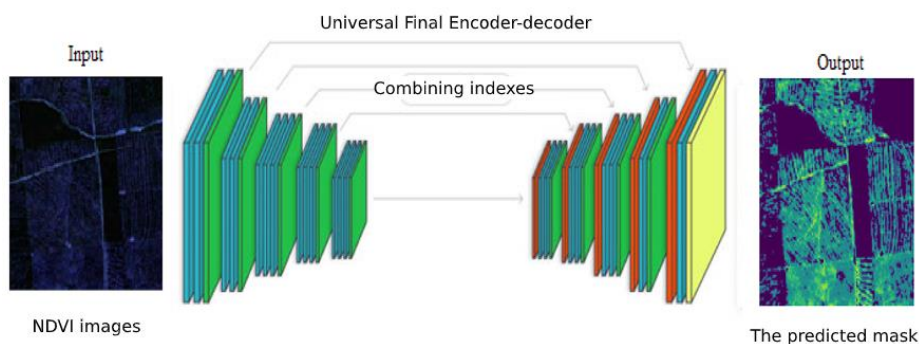


Рис. 2. Обобщенная модель нейронной сети

Как было сказано выше, для выполнения сегментации спутниковых снимков была выбрана лесистая местность в Кабанском районе Республики Бурятия. Участок занимает площадь около 180 км² и расположен на относительно ровной местности, где преобладают хвойные деревья разного возраста. Лес классифицируется как управляемый, и в течение нескольких лет в нем проводилась плановая рубка ухода. На рисунке 3 показан моментальный снимок фрагмента леса для обработки нейронной сетью.



Рис. 3. Фрагмент лесного массива перед обработкой нейронной сетью

На рисунке 4 показан моментальный снимок фрагмента лесной зоны после применения метода сегментации. По результатам сегментации можно заметить, что вырубки являются наиболее точно распознанными лесными участками. На бинарных масках участки сплошного леса выделены светлым цветом, в то время как другие области представлены темным оттенком.




Рис. 4. Сегментированный фрагмент лесного массива

Таким образом, семантическая сегментация позволяет автоматически обнаруживать объекты и выделять их на изображениях путем разделения изображения на несколько сегментов, каждый из которых соответствует объекту или части объекта на изображении.

Для реализации нейросетевой модели вычисления углеродного баланса была использована среда разработки IDE и язык программирования Python, а также несколько библиотек, включая NumPy, Matplotlib, OpenCV, Pandas, TensorFlow и Keras [7].

Эксперименты по обучению нейронной сети проводились с использованием входных данных из наземной экосистемы лесничества Кабанского района в период с 2018 по 2022 год, что представлено таблице 2.

Таблица 2. Результаты обучения нейронной сети

Входные данные/год	Точность обучения сети	Ошибка обучения
2018	0,75867	0,21374
2019	0,83724	0,11328
2020	0,68924	0,10248
2021	0,87184	0,098923
2022	0,91108	0,097915

Результаты расчета запасов углерода в Кабанском районе в связи с вырубкой лесов представлены в таблице 3.

Таблица 3. Углеродный баланс в результате сетевого обучения

Год	Доля лесозаготовок, %	Запас углерода в фитомассе, т С	Годовой углеродный баланс
2018	19	0,429903302	0,003771082
2019	17	0,384650323	-0,041481898
2020	39	0,882433094	0,02451203
2021	26	0,58828873	0,009427704
2022	21	0,475156282	0,039596357

Углеродный баланс по отношению к годовому углеродному балансу в фитомассе в лесных районах наземной экосистемы (т С/год) показан на рисунке 5.

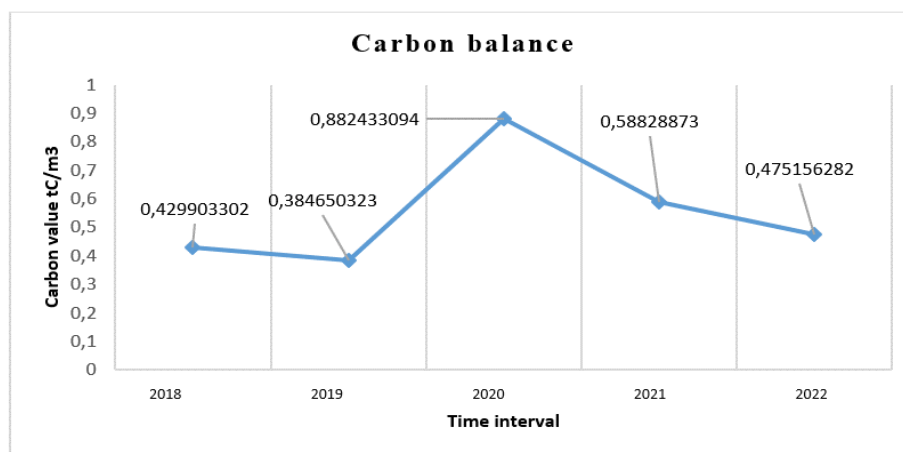


Рис. 5. График запаса углерода в фитомассе

Баланс углерода по отношению к годовым запасам в лесных районах наземной экосистемы (тонн в год) представлен на рисунке 6.

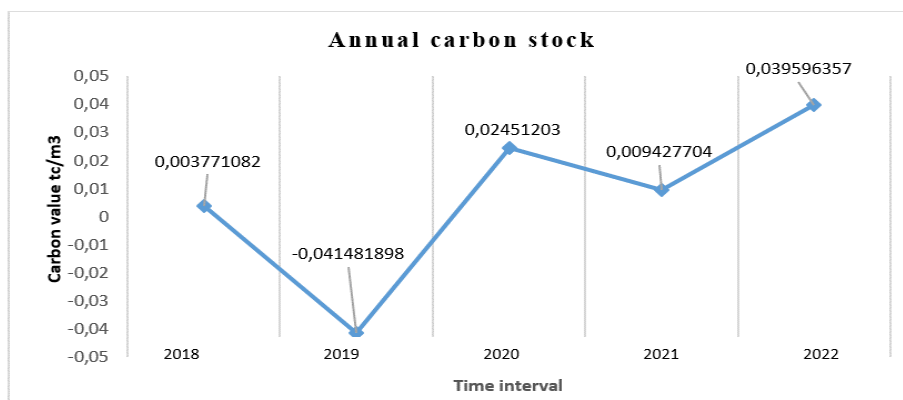


Рис. 6. График годового запаса углерода

Экспериментальные данные, полученные в результате обучения нейронной сети семантической сегментации лесов и расчета углеродного баланса, демонстрируют эффективность модели для оценки углеродного баланса в лесном массиве Кабанского района Республики Бурятия. Достоверность результатов проверяется с помощью обучающих и тестовых наборов данных.

4. Заключение

Использование текущих данных лесного реестра, полученных с помощью методов дистанционного зондирования, обеспечивает беспристрастную оценку лесов в наземной экосистеме, потенциально предлагая решение проблемы семантической сегментации с использованием сверточных нейронных сетей. Это представляет собой один из нескольких потенциальных подходов к решению экологических проблем, связанных с оценкой углеродного баланса.

Разработанный прототип программного обеспечения для сверточной нейронной сети, наряду с обучающими экспериментами и расчетами динамики запасов углерода в конкретном регионе, способствуют пониманию процесса лесовосстановления и осаждения углеродного баланса.

Литература

1. *Малик Л. К. М.* Киотский протокол – проблемы и возможные решения для России // Проблемы безопасности и чрезвычайных ситуаций. – 2009. – Vol. С–18, N 4. – P. 3–21.
2. *Филипчук А.Н., Малышева Н.В., Моисеев Б.Н., Страхов В.В.* Аналитический обзор методов учета выбросов и поглощения парниковых газов из атмосферы лесами. // Лесхоз. информ. – 2016. – Vol. С–50. – P. 36–85.
3. *Грабовский В. И., Зукерт Н. В., Корзухин М. Д.* Оценка индекса листовой поверхности (LAI) для территории РФ по данным государственного лесного реестра. // Лесоведение. – 2015. Vol. С–5, N 4. – P. 255–259.
4. *Корзухин М. Д., Коротков В. Н.* Модификация модели РОБУЛ для расчета углеродного баланса лесов России //Фундаментальная и прикладная климатология. – 2018. – Vol. С–23, N 3. – С. 30-53.
5. *Матусевич Г.В., Стоноженко Л.В., Иванов Н.Г.* Таксация лесов: теоретические основы вычислений. – М.: МГТУ им. Н.Э. Баумана, 2012, – 182 с.
6. *Дли М.И., Пучков А.Ю., Рысина Е.И.* Интеллектуальные алгоритмы анализа разнородной информации. – Смоленск: Универсум, 2022 – 204 с.
7. *Тулохонова И.С., Титов В.А.* Нейросетевая модель углеродного баланса земной экосистемы // Проблемы механики современных машин: материалы VIII междуна. конф. – Улан-Удэ, ВСГУТУ, 2022 – С.633–640.
8. *Замолодчиков Д.Г., Грабовский В.И., Курц В.А.* Влияние объемов лесопользования на углеродный баланс лесов России: прогнозный анализ по модели СВМ-CFS3 // Труды Санкт-Петербургского научно-исследовательского института лесного хозяйства. – 2014. – Т. 1. – С. 5–18.
9. *Paul E.A., Kravchenko A., Grandy A.S., Morris S.* Soil organic matter dynamics: Controls and management for sustainable ecosystem functioning. // The Ecology of Agricultural Landscapes: Long-Term Research on the Path to Sustainability. – 2015. Vol. С–30. – P. 104–134.
10. *Федоров Б.Г.* Углеродный баланс России. – М.: Научный консультант, 2017. – 82 с.