

Разработка новой автоматической методики восстановления интенсивности тропических циклонов по данным многоспектральных спутниковых наблюдений Земли с помощью искусственных нейросетей

А. Н. Якушева¹, Д. М. Ермаков^{1,2}

¹ *Институт космических исследований РАН, Москва, 117997, Россия
E-mails: annayakusheva99@mail.ru, pldime@gmail.com*

² *Фрязинский филиал Института радиотехники и электроники
им. В. А. Котельникова РАН, Фрязино, 141190, Московская обл., Россия*

Представлена автоматическая методика восстановления интенсивности тропических циклонов (ТЦ) по их спутниковым изображениям на основе свёрточной нейронной сети. Для формирования выборки исходных данных использованы 43 688 записей о ТЦ из баз данных основных региональных национальных центров слежения за тропическими циклонами (для краткости — национальных ураганных центров, БД НУЦ) и соответствующие им спутниковые изображения в нескольких спектральных диапазонах (видимом, инфракрасном, микроволновом). Собранные данные охватывают наблюдения с 1981 по 2022 г. во всех акваториях Мирового океана, кроме Индийского океана, участвующих в генезисе тропических циклонов. Выполнено исследование по реализации нейросети с наилучшими показателями, восстанавливающей интенсивность ТЦ на собранном объёме данных. По итогам исследования спроектирована, реализована и обучена нейросеть, обеспечившая (при сравнении восстановленного значения интенсивности ТЦ с указанными в БД НУЦ) среднеквадратичную ошибку около 11,3 (11,4) уз; коэффициент детерминации — около 0,80 (0,82) в зависимости от сочетания типов входной информации. Отмечено, что достигнутые показатели качества превосходят известные из литературы или сопоставимы с ними. При этом анализ работ по развитию подходов к автоматизированной оценке интенсивности ТЦ показал, что все они выполнены на существенно меньших (на порядки) объёмах входной информации (отдельные акватории, единичные годы, определённые фазы развития ТЦ и т.д.). Заявленные в литературе оценки среднеквадратичной погрешности составляют от 8 до 14 уз, но минимальный уровень погрешности достигается путём специального отбора «подходящих» данных.

Ключевые слова: тропические циклоны, восстановление интенсивности, искусственные нейронные сети, многоспектральные спутниковые наблюдения

Одобрена к печати: 29.03.2024

DOI: 10.21046/2070-7401-2024-21-2-336-349

Введение

Климатологии тропических циклонов (ТЦ) — исследованию многолетней глобальной и/или региональной статистики совокупности их характеристик — посвящено значительное число работ (см., например, (Sharkov, 2000, 2012)). Хорошо известно, что наиболее важные процессы эволюции ТЦ (переход к зрелой фазе, быстрая интенсификация) происходят, как правило, вдали от суши, где пролегает основная часть его траектории. Поэтому наиболее надёжным средством мониторинга эволюции ТЦ является дистанционное зондирование Земли (ДЗЗ). Значительную роль в дистанционной диагностике ТЦ отводят оптическим изображениям (в видимом и инфракрасном (ИК) диапазонах спектра) с геостационарных спутников.

Классическим методом идентификации и определения интенсивности ТЦ по спутниковым снимкам является метод Дворака (Dvorak, 1973). Согласно этому методу фазы развития каждого ТЦ могут быть соотнесены с одним из нескольких шаблонов. Метод присваивает каждому ТЦ «Т-числа» (Т1–Т8), основываясь на образах ТЦ по данным спутниковых наблюдений. Исходный вариант метода Дворака, опирающийся на экспертную оценку, имел среднеквадратичную погрешность оценки интенсивности ТЦ около 6 м/с (Yang, Gossuth, 2016).

Основное предположение метода Дворака состоит в том, что ТЦ с близкими значениями интенсивности имеют схожие образы при дистанционных наблюдениях. Другими словами, предполагается, что между изображениями ТЦ существуют «скрытые корреляции», которые можно использовать для оценки их интенсивности (Wimmers et al., 2019).

Помимо метода Дворака существует несколько других дистанционных методов диагностики структуры и интенсивности ТЦ. В частности, применяют наблюдения в микроволновом (МВ) диапазоне спектра. Спутниковые наблюдения на частотах 37 и 85–92 ГГц считаются наиболее перспективными для определения интенсивности ТЦ (Wimmers et al., 2019). Методы, использующие микроволновые наблюдения, в настоящее время обеспечивают среднеквадратическую ошибку (СКО) восстановления интенсивности ТЦ от 10 до 15 уз (1 уз $\approx 0,5144$ м/с).

Формирование многолетних архивов данных ДЗЗ и прогресс в области вычислительной техники закономерно приводят к росту числа работ по развитию методик автоматического восстановления интенсивности ТЦ на основе анализа многолетней статистики наблюдений. А с учётом доступности статистической информации о самих ТЦ в национальных ураганных центрах разных стран (т. е. фактически наличия «размеченных данных») на первое место выходят алгоритмы машинного обучения (*табл. 1*). В подавляющем большинстве работ, указанных в *табл. 1*, применены регрессионные нейросетевые модели. Среднеквадратичная погрешность восстановления интенсивности ТЦ (*англ.* Root Mean Square Error — RMSE) в этих работах при оценке на тестовых выборках данных составила от 8 до 14 уз.

Таблица 1. Алгоритмы восстановления интенсивности тропических циклонов

Исследование	Спектральные диапазоны		Выборка данных	СКО, уз
(Zhao et al., 2016)	ИК	10,3–11,3 мкм	52 случая за 2008–2009 гг.	12,69
(Combinido et al., 2018)	ИК	10,2–11,5 мкм	ТЦ Тихого океана за 2015–2016 гг.	13,23
(Velden, Herndon, 2014)	ИК, МВ	10,2–11,5 мкм, 85–89 ГГц	Отсутствует точное указание	8,30
(Lee et al., 2020)	ИК	10,7–12,0; 6,7; 3,9 мкм	Северо-западная часть Тихого океана за 2017 г.	8,32
(Xiang et al., 2019)	МВ	85–89 ГГц	Северо-западная часть Тихого океана за 2017 г.	11,55
(Chen et al., 2019)	ИК, МВ	10,7; 6,7 мкм, 85–92 ГГц	96 ТЦ за 2017 г.	8,39
(Wimmers et al., 2019)	МВ	37,85–92 ГГц	ТЦ за 2007, 2017 гг.	14,30

Перечисленные исследования констатируют преимущество машинного обучения над другими методами восстановления параметров ТЦ, когда недоступны наземные измерения. Однако при оценке точности моделей в этих исследованиях используют фильтрацию данных по категориям ТЦ, временным промежуткам и/или акваториям Мирового океана, обосновывая это наибольшим количеством синхронно выполненных авиаразведывательных наблюдений. Как следует из самих указанных работ, такая фильтрация может существенно влиять на адекватность оценки погрешности метода восстановления интенсивности ТЦ в общем случае.

Основной целью работы было создание и обучение нейросетевой модели, показывающей сопоставимое (или лучшее) качество восстановления интенсивности ТЦ по данным наблюдений в ИК-диапазоне без их предварительного отбора. Такая универсальная модель, в частности, может быть непосредственно внедрена в систему оперативной потоковой обработки спутниковых данных. Кроме того, кратко затронут вопрос реализации совместной обработки данных наблюдений в инфракрасном и микроволновом диапазонах, что в перспективе должно дополнительно повысить точность развиваемой модели. Следует отметить, что в настоящей

статье использована наибольшая по объёму и самая представительная выборка данных (по числу ТЦ, их изображениям и интервалам наблюдений) для разработки и тестирования нейросетевой модели по сравнению с вышеупомянутыми исследованиями.

Использованные данные

Как правило, модели машинного обучения работают лучше всего с десятками тысяч обучающих примеров, а производительность модели логарифмически зависит от размера обучающей выборки. Это важно и при решении задачи автоматического определения интенсивности ТЦ.

Для того чтобы создать обучающий набор, были собраны записи о ТЦ из трёх разных баз данных (БД). В этих БД используются как результаты авиаразведки, так и экспертная оценка параметров ТЦ. Каждому ТЦ соответствуют записи параметров с 6-часовыми интервалами, которые включают в себя время, дату, категорию ТЦ, максимальную скорость устойчивого ветра, широту, долготу, давление в центре глаза и радиус максимального ветра.

Первая используемая БД была составлена Национальным ураганным центром США (*англ.* National Hurricane Center — NHC) (<https://www.nhc.noaa.gov/data/>). В этой БД зафиксированы метеорологические данные о ТЦ, проходивших над Атлантическим океаном и северо-восточной частью Тихого океана. Эта БД имеет официальное название HURDAT2. Вторая БД включает в себя ТЦ северо-западной части Тихого океана и принадлежит Китайскому метеорологическому управлению (*англ.* China Meteorological Administration — CMA) (https://tcdata.typhoon.org.cn/en/zjljsjj_sm.html). И третья БД была сформирована по записям ТЦ Японского метеорологического агентства (*англ.* Meteorological Services of Japan — JMA) по западной части Тихого океана (<http://agora.ex.nii.ac.jp/digital-typhoon/year/>).

В настоящей работе для сбора спутниковых снимков по полученным БД был использован архив Института метеорологических спутниковых исследований (*англ.* Cooperative Institute for Meteorological Satellite Studies (CIMSS) of University of Wisconsin-Madison) (<http://tropic.ssec.wisc.edu/archive/>) и архив Японского национального института информатики (*англ.* National Institute of Informatics — NII) (<http://agora.ex.nii.ac.jp/digital-typhoon/year/>). Архивы содержат изображения ТЦ с геостационарных спутников GOES (*англ.* Geostationary Operational Environmental Satellite) и Himawari в инфракрасном диапазоне 10,3–11,2 и 6,2–6,9 мкм.

Также из данных архивов были получены нелинейно преобразованные инфракрасные изображения, на которых с помощью специальных кривых контрастирования выделяют «паттерны ураганов» (характерные структурные элементы), описанные в методе Дворака. Такие изображения широко используются при оценке интенсивности ТЦ.

Эти изображения были дополнены синхронными фрагментами полей восстановленного по микроволновым данным интегрального влагосодержания атмосферы и водозапаса облаков из геопортала спутникового радиотепловидения на платформе сервера Фрязинского филиала Института радиотехники и электроники им. В. А. Котельникова (ИРЭ) РАН (<https://fireras.su/tpw/Fields.aspx>).




Рис. 1. Пример набора образов ТЦ по данным спутниковых наблюдений: *a* — тепловой ИК-канал, 10,3–11,2 мкм; *b* — контрастированное ИК-изображение (КИК), 11 мкм; *в* — ИК-изображение в линии поглощения водяного пара (ВП), 6,2–6,9 мкм; *г* — поле интегрального влагосодержания (ИВС) по микроволновым данным; *д* — поле водозапаса облаков (ВЗО) по микроволновым данным

В обучающей выборке были представлены ТЦ с интенсивностью от 10 до 160 уз (по сведениям ураганных центров). При этом не всегда имелась информация, в каких случаях проводились непосредственные измерения скорости ветра, поэтому в работе был применён единый подход к использованию всех случаев наблюдений ТЦ.

На их основе был сформирован единый набор спутниковых снимков (рис. 1, см. с. 338) по разным акваториям и в разных спектральных диапазонах, дополненный соответствующими метеорологическими данными. Результирующая БД имеет 43 688 записей о ТЦ с 1981 по 2022 г.

Предобработка данных

Так как БД спутниковых изображений имеют снимки с разным пространственным разрешением, на первом этапе обработки осуществляется приведение изображений к общему масштабу. На основе записей о координатах центра ТЦ в БД HURDAT2, JMA и CMA из каждого спутникового изображения был выделен фрагмент размерами около 9° в географических координатах (1018 км) по широте и долготе, центрированный (приблизённо) относительно ТЦ.

Распределение количества ТЦ по интенсивности имеет неоднородный характер, и в итоге результирующая выборка включает в себя ТЦ с интенсивностью от 10 до 160 уз, причём с увеличением интенсивности ТЦ их число уменьшается (рис. 2). То есть чаще всего ТЦ относятся к стадии тропической депрессии и тропического шторма, затем их количество уменьшается с увеличением максимальной скорости ветра.

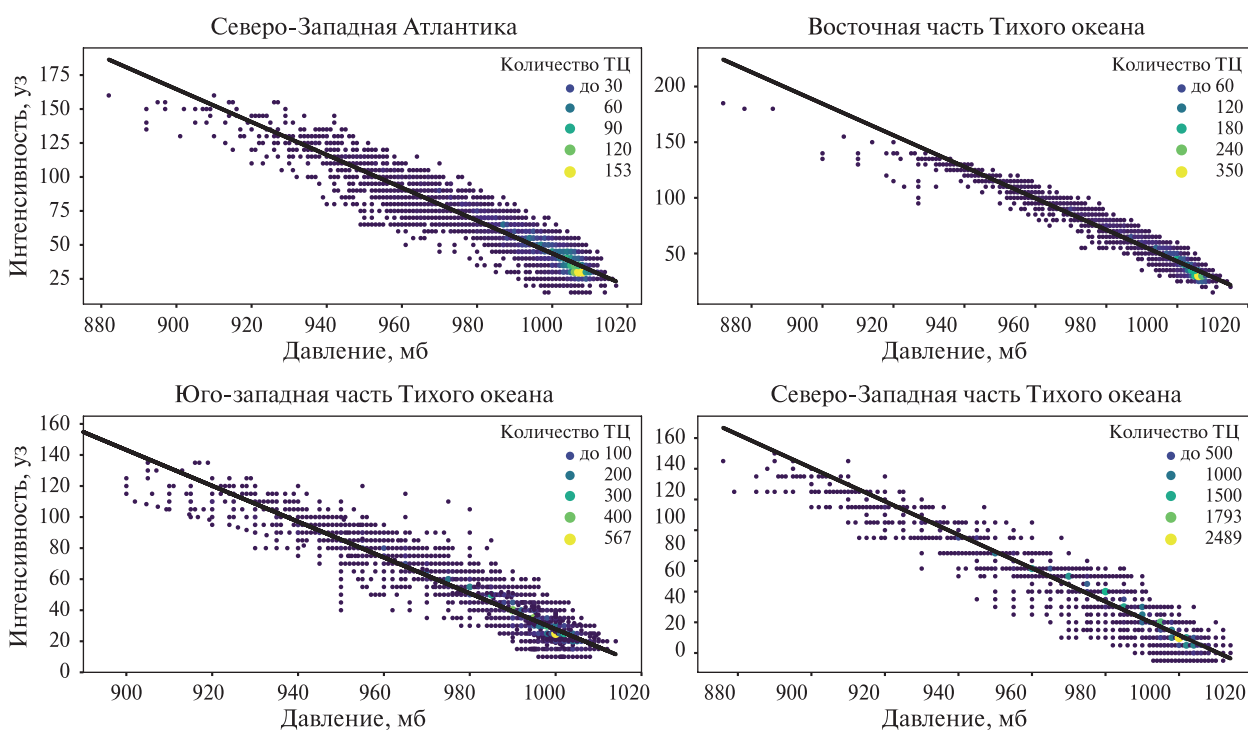


Рис. 2. Связь числа зарегистрированных ТЦ с атмосферным давлением в центре глаза ТЦ и его интенсивностью для разных акваторий Мирового океана

В машинном обучении такое неоднородное распределение набора данных может привести к некорректному обучению, выражающемуся в большой систематической погрешности в результатах восстановления параметров. Поэтому следующим этапом обработки данных становится создание сбалансированного обучающего набора. Стандартная технология решения этой проблемы называется «аугментацией» (расширением обучающего набора). Некоторые изображения ТЦ отражаются по вертикали, горизонтали и поворачиваются на

угол, задаваемый случайным выбором. Таким образом достигается равномерное распределение изображений ТЦ по интенсивностям.

Следующий этап заключается в нормализации данных. Нормализация — процедура обработки входной информации, при которой значения признаков во входном векторе приводятся к определённому диапазону. Нормализация включала в себя:

- 1) центрирование данных (вычитание из исходного значения в каждой точке изображения среднего по всему изображению);
- 2) масштабирование путём нормировки данных на их стандартное отклонение, рассчитанное по изображению.

Следует отметить, что все указанные процедуры предобработки выполнялись после разделения набора данных на обучающую и проверочную (в соотношении 8:2) выборки — для каждой из них в отдельности, чтобы обеспечить пропорциональное включение в них оригинальных изображений. Тестовый набор данных был сформирован так, чтобы в нём были представлены изображения ТЦ всех значений интенсивности. Для этого в него были включены изображения за 2007, 2009, 2012 и 2017 гг.

Свёрточная нейросеть

Таблица 2. Архитектура свёрточной нейросети

Слой	Выходной размер	Параметры	Функция активации
Свёрточный слой № 1	(100, 100, 8)	208	LeakyReLU
Слой максимального пуллинга № 1	(50, 50, 8)		—
Свёрточный слой № 2	(50, 50, 16)	1168	LeakyReLU
Свёрточный слой № 3	(50, 50, 16)	2320	LeakyReLU
Слой максимального пуллинга № 2	(25, 25, 16)		—
Слой исключения № 1			
Свёрточный слой № 4	(25, 25, 32)	4640	LeakyReLU
Свёрточный слой № 5	(25, 25, 32)	9248	LeakyReLU
Слой максимального пуллинга № 3	(12, 12, 32)		—
Свёрточный слой № 6	(12, 12, 64)	18496	LeakyReLU
Свёрточный слой № 7	(12, 12, 64)	36928	LeakyReLU
Слой максимального пуллинга № 4	(6, 6, 64)		—
Слой исключения № 2			
Свёрточный слой № 8	(6, 6, 128)	73856	LeakyReLU
Слой максимального пуллинга № 5	(3, 3, 128)		—
Свёрточный слой № 9	(3, 3, 256)	295168	LeakyReLU
Слой максимального пуллинга № 6	(1, 1, 256)		—
Выравнивание (<i>англ.</i> Flatten)			—
Полносвязный слой № 1	(32)	8224	LeakyReLU
Слой исключения № 3			
Полносвязный слой № 2	(1)	33	—
Всего параметров:		450 289	

Архитектура реализованной свёрточной нейросети (СНС) отображена в *табл. 2*. Модель СНС включает в себя свёрточные слои (*англ.* Convolutional layer) (Arohan et al., 2020), которые формируют карту признаков, слои максимального пуллинга (*англ.* Maximum Pooling layer) (Arohan et al., 2020), которые уменьшают пространство признаков, слои исключения (*англ.*

Dropout) для предотвращения переобучения и полносвязные слои (*англ.* Fully-connected layer), которые содержат векторы весов и смещений. Выходным слоем является один нейрон (выдающий значение интенсивности ТЦ), к которому не применяется функция активации.

При построении модели, восстанавливающей интенсивность ТЦ, была использована функция активации LeakyReLU. Формула для функции активации LeakyReLU:

$$f(z) = \begin{cases} \alpha z, & z < 0, \\ z, & z \geq 0, \end{cases}$$

где $\alpha = 0,01$.

В качестве функции потерь в работе была использована средняя абсолютная ошибка (*англ.* Mean Absolute Error — MAE). При обучении СНС был применён стандартный алгоритм оптимизации Adam (Kingma, Ba, 2015), а также алгоритм ранней остановки, препятствующий переобучению модели при сохранении оптимальных достигнутых значений весов.

Критерии оценки качества

В настоящей работе были использованы четыре метрики оценки качества работы нейросети. Все они характеризуют интегральное по тестовой выборке отклонение оценок восстанавливаемой величины (интенсивности), \hat{y}_i , от её «истинного» значения, y_i , известного априори. Дисперсия ошибки — одна из основных метрик в задаче регрессии. С помощью MSE большие расхождения в оценках нейросети становятся более заметны, так как невязки возводятся в квадрат. Метрика вычисляется следующим образом:

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2, \quad (1)$$

где N — количество данных.

Среднеквадратичная ошибка применяется для того, чтобы привести метрику (1) к размерности исходных данных.

$$\text{RMSE} = \sqrt{\text{MSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}. \quad (2)$$

Коэффициент детерминации — безразмерная мера качества восстановления, в которой метрика MSE фактически сравнивается с дисперсией самих данных. По этому критерию высокому качеству модели соответствуют значения коэффициента детерминации, близкие к 1.

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}, \quad (3)$$

где $\bar{y} = \frac{1}{N} \sum_{i=1}^N y_i$.

Также для оценки качества работы модели используют средний модуль невязки оценок:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|. \quad (4)$$

Результаты

Для исследования связи качества обучения СНС с количеством и типами использованной для обучения информации были рассмотрены различные варианты формирования обучающих и проверочных выборок. Выборки изменялись методом последовательного дополнения дан-

ных в них. Качество обучения характеризовалось метриками RMSE (2), R^2 (3) и MAE (4), вычисляемыми на независимой тестовой выборке.

Сначала нейросеть обучалась только на изображениях в тепловом ИК-канале 10,3–11,2 мкм отдельных бассейнов Мирового океана и некоторых их объединений. Как видно из *табл. 3*, показатели СНС в целом улучшаются с увеличением объема использованных данных. Кроме того, установлена чувствительность результата обучения к использованию обучающей информации из различных баз данных основных региональных национальных центров слежения за тропическими циклонами (для краткости — национальных ураганных центров, БД НУЦ) (что косвенно свидетельствует о различном качестве этой информации). Так, для бассейна северо-запада Тихого океана имеется в открытом доступе информация по ТЦ из НУЦ СМА и JMA (см. разд. «Использованные данные»). Установлено, что СНС устойчиво сходится к лучшим метрическим показателям при разметке данных по информации СМА. Следует также отметить, что статистика данных СМА охватывает больший диапазон интенсивности ТЦ.

Далее в обучающую и проверочную выборку были включены изображения в тепловом ИК-канале всех бассейнов Мирового океана. После обучения СНС и оценки его качества обучающую и проверочную выборку дополнили изображениями в канале поглощения водяным паром 6,2–6,9 мкм и повторили процедуру обучения и тестирования СНС. Наконец, обучающую и проверочную выборки дополнили контрастированными ИК-изображениями (КИК) и снова повторили процедуру обучения и тестирования СНС. Следует отметить, что тестовая выборка при проверке качества обучения СНС не менялась и была составлена только из изображений теплового ИК-канала по всем бассейнам Мирового океана.

Таблица 3. Качество обучения свёрточной нейросети для разных бассейнов Мирового океана

Бассейн	MAE, уз	RMSE, уз	R^2
С-3 Тихий (СМА) (20–150 уз)	8,75	10,91	0,75
С-3 Тихий (JMA) (35–125 уз)	8,95	11,45	0,67
Ю-3 Тихий (JMA) (10–135 уз)	8,90	12,06	0,64
С-3 Атлантика (HURDAT2) (15–160 уз)	9,16	11,76	0,83
С-В Тихий (HURDAT2) (25–155 уз)	9,18	11,91	0,78
С-3 и Ю-3 Тихий (10–150 уз)	8,78	11,46	0,77
Атлантика и С-В Тихий (15–160 уз)	9,87	12,91	0,78

Примечание: С-3 Тихий — северо-запад Тихого океана; Ю-3 Тихий — юго-запад Тихого океана; С-3 Атлантика — северо-запад Атлантического океана; С-В Тихий — северо-восток Тихого океана.

Таблица 4. Качество обучения свёрточной нейросети на типологически расширяемых наборах данных

Тип данных	MAE, уз	RMSE, уз	R^2
ИК (10–160 уз)	9,47	12,19	0,77
ИК и ВП	8,81	11,39	0,82
ИК, ВП и КИК	8,68	11,33	0,80

В *табл. 4* приведены результаты тестирования СНС, обученной на указанных выше выборках данных. Эти результаты показывают, что в целом СНС демонстрирует лучшие показатели обучения при использовании изображений нескольких типов даже при итоговом тестировании только по одному из них. Это косвенно свидетельствует о наличии «скрытых кор-

реляций» (пространственных связей в структуре дистанционных образов ТЦ) и способности СНС выявлять и использовать эту информацию.

Дополнение обучающей и проверочной выборок изображениями полей интегрального влагосодержания и водозапаса облаков по микроволновым данным не привело к росту качества обучения СНС. Вероятно, это свидетельствует, что наблюдаемые в этих данных закономерности пространственной структуры ТЦ (в силу других физических механизмов формирования сигнала и худшего пространственного разрешения) радикально отличаются от усвоенных СНС в ИК-диапазоне. Проблема совместного использования данных ИК и микроволновых наблюдений для улучшения качества восстановления интенсивности ТЦ кратко обсуждена в заключении.

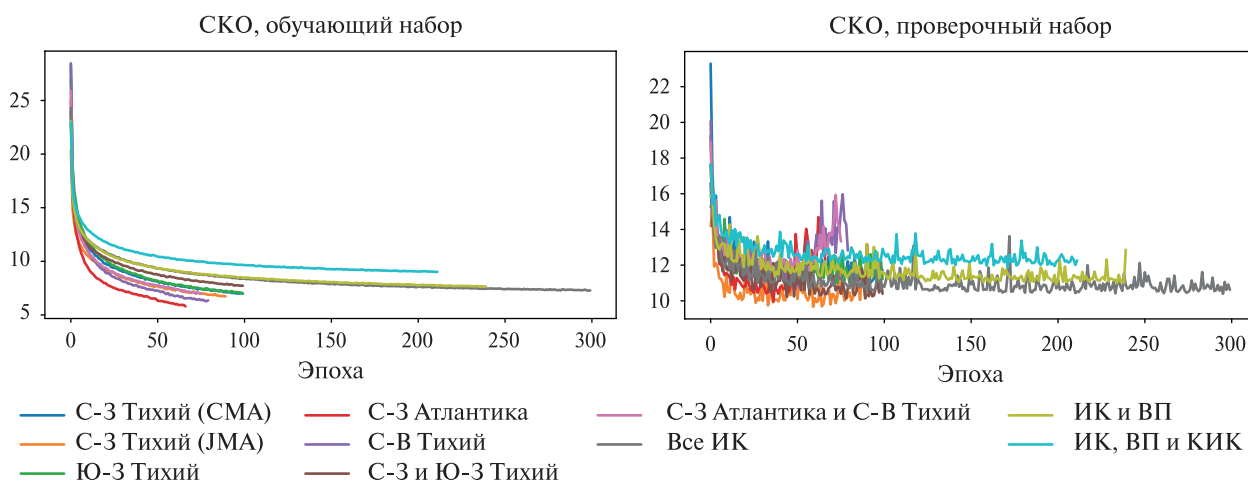


Рис. 3. Эволюционные кривые SKO на обучающем (слева) и проверочном (справа) наборах




Рис. 4. Распределение невязок (в узлах) нейросетевой оценки интенсивности ТЦ со значениями в БД НУЦ по всем изображениям. Вертикальный пунктир соответствует значениям μ и $\mu \pm \sigma$. Зелёная кривая — аппроксимирующая гауссова функция




Рис. 5. Гистограмма рассеяния нейросетевых значений (по вертикали) восстановленной интенсивности ТЦ и данных БД НУЦ (по горизонтали). Цвет кодирует общее число соответствующих пар значений (цветовая шкала — справа)

Анализ эволюционных кривых обучения на проверочном наборе данных показывает хорошую сходимость решения СНС и отсутствие переобучения. Некоторое ухудшение показателей обучения на проверочном наборе возникает при использовании данных по северо-

востоку Тихого океана, в том числе в сочетании их с данными по северо-западу Атлантики (рис. 3, см. с. 343). Приведены графики по метрике качества (2) (среднеквадратичного отклонения, СКО). Графики по метрике качества (4) демонстрируют очень близкий характер поведения, поэтому для краткости опущены.

График распределения невязок оценки интенсивности ТЦ на каждом изображении с соответствующими значениями интенсивности, указанными в БД НУЦ, приведён на рис. 4 (см. с. 343). Как видно, распределение невязок подчиняется нормальному закону, систематическая ошибка отсутствует. Аппроксимирующая полученное выборочное распределение гауссова кривая имеет параметры $\mu = 0,06$ уз (среднее значение) и $\sigma = 11,39$ уз. В области между 22,25 и 25,26 уз (± 13 м/с) лежат 95,44 % значений невязки.

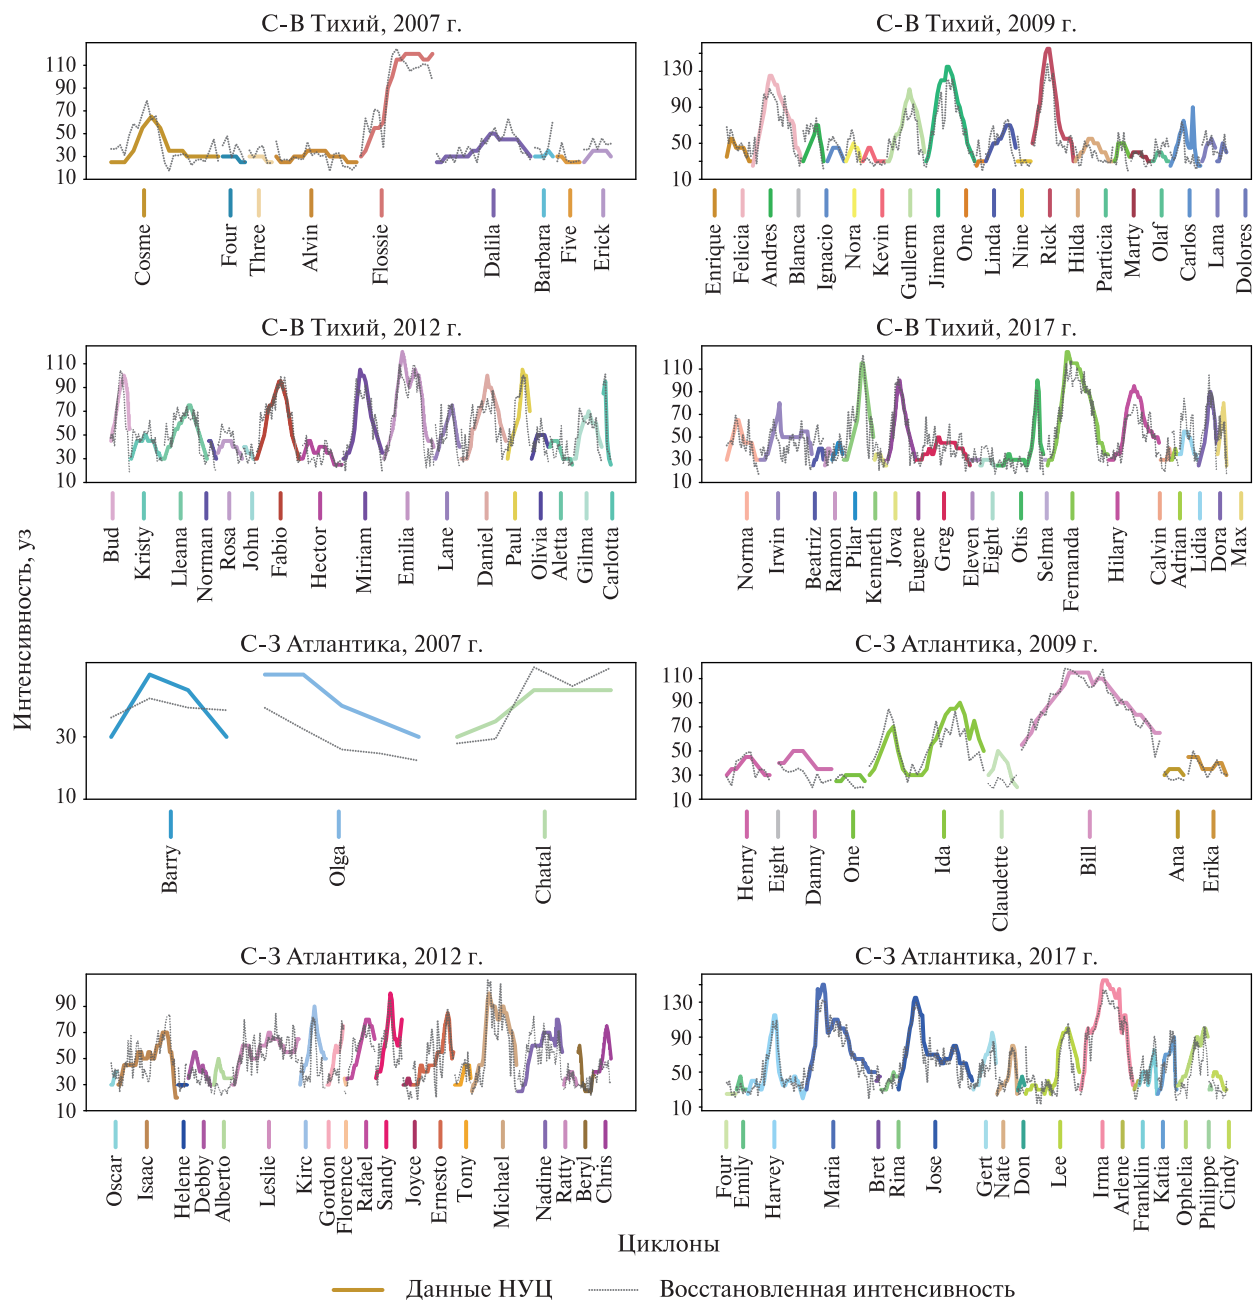


Рис. 6. Графики восстановленной интенсивности для ТЦ из тестовой выборки в сопоставлении с информацией из БД НУЦ (США) для северо-востока Тихого океана и северо-запада Атлантического океана

Для анализа точности восстановления в зависимости от интенсивности ТЦ были построены диаграммы рассеяния (скаттерограммы) нейросетевых оценок интенсивности и соответствующих значений из БД НУЦ.

На рис. 5 (см. с. 343) приведена диаграмма, построенная для варианта нейросети, обеспечившей коэффициент детерминации оценок $R^2 = 0,82$ (см. табл. 4). Из анализа следует, что нейросетевая модель обеспечивает несмещённую оценку с примерно одинаковым СКО для интенсивности ТЦ во всех фазах развития. Некоторое исключение представляют ТЦ с интенсивностями выше 140 уз, что отчасти объяснимо сравнительно малым количеством примеров таких ТЦ.

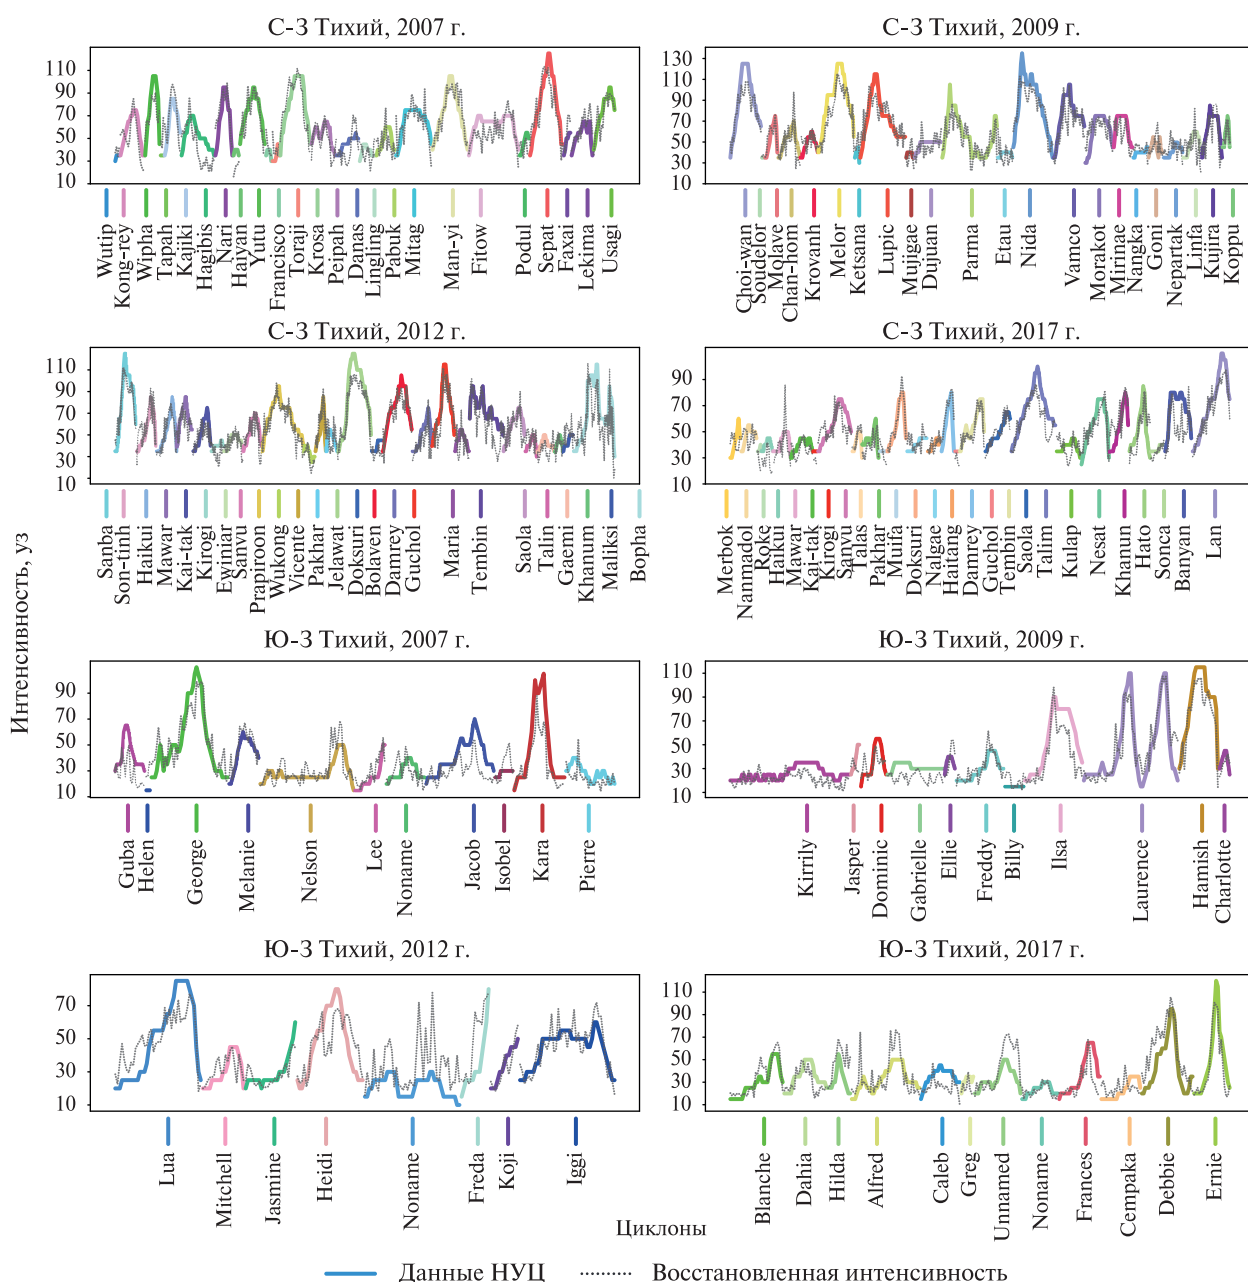


Рис. 7. Графики восстановленных интенсивностей для ТЦ из тестовой выборки в сопоставлении с информацией из БД НУЦ для северо-запада (по СМА) и юго-запада (по ЖМА) Тихого океана

Так как тестовый набор данных за четыре года содержал в совокупности около 5000 ИК-изображений, имелась возможность продемонстрировать временной ход эволюции большинства

ТЦ в различных акваториях в эти годы, восстановленный по нейросетевой модели, в сопоставлении с данными НУЦ. На *рис. 6* (см. с. 344) проиллюстрирован временной ход эволюции тропического циклогенеза за 2007, 2009, 2012 и 2017 гг. над северо-востоком Тихого океана и северо-западом Атлантического океана. Пунктиром показаны нейросетевые оценки. Сплошные линии построены по данным Национального ураганного центра США. Видно, что в целом нейросетевая модель хорошо воспроизводит эволюционные кривые тропического циклогенеза как на качественном, так и на количественном уровне.

На *рис. 7* (см. с. 345) представлено аналогичное сравнение восстановленной интенсивности ТЦ за 2007, 2009, 2012 и 2017 гг. с данными СМА по северо-западу Тихого океана и ЖМА по юго-западу Тихого океана. Наибольшее зафиксированное отклонение от данных НУЦ модель имеет на юго-западной части Тихого океана в сопоставлении с данными ЖМА. Предположительно, это связано со сравнительно низким качеством данных, представленных в НУЦ ЖМА. В частности, некоторые исследования (например, (Sun et al., 2017; Yu et al., 2007)), отмечают, что набор данных ЖМА имеет наибольшее число ошибок по сравнению с другими БД. Авторы планируют в дальнейшем проверить это предположение массовым независимым сопоставлением результатов автоматического восстановления интенсивности ТЦ с информацией СМА и ЖМА.

Возможными причинами расхождений могут быть различия в методиках расчёта скорости максимального устойчивого ветра: усреднения за разные интервалы времени (Vai et al., 2022), использование разных технологий измерений (наблюдения с наземных станций, авиа-разведка), а также человеческий фактор.

Заключение

В работе построена, обучена и протестирована свёрточная нейронная сеть для восстановления интенсивности тропических циклонов во всех фазах развития. Построенная сеть продемонстрировала высокие показатели качества в сравнении с другими известными из литературы методами автоматического восстановления интенсивности ТЦ по дистанционным данным. Среднеквадратичная погрешность восстановления составила около 11,3 уз (менее 6 м/с). В целом точность восстановления оказалась примерно постоянной для всех фаз развития ТЦ (за исключением ТЦ с интенсивностью более 140 уз, число которых в имеющемся наборе данных было мало). Минимальные значения погрешности достигнуты для ТЦ в ранних фазах развития. Следует отметить, что в работе была использована наиболее представительная выборка спутниковых изображений, подобранных для 43 688 записей о ТЦ с 1981 по 2022 г.

Показано, что расширение пространства входных признаков за счёт использования спутниковых изображений в разных спектральных диапазонах и их нелинейных преобразований приводит к улучшению качества восстановления интенсивности ТЦ (по критерию среднеквадратичного отклонения от экспертных оценок в БД НУЦ). Однако реализованная топология нейросети ограничивает возможности такого расширения. В частности, не сказывается на качестве восстановления дополнение оптических данных микроволновыми, хотя известны методы автоматического восстановления интенсивности ТЦ по этим данным, демонстрирующие сравнимые по точности результаты (на небольшой выборке). Одним из перспективных подходов к дальнейшему улучшению качества восстановления интенсивности ТЦ представляется синтез на уровне решений двух нейросетей. Вариант первой из них, обученной по оптическим данным, представлен в настоящей работе. Вторая — для применения к совмещённым микроволновым данным — должна быть построена и обучена независимо. На заключительном шаге должна быть реализована автоматическая процедура принятия итогового решения на основе результатов работы двух этих нейросетей (с учётом оценки достоверности индивидуальных решений в каждом конкретном случае). В дальнейшие планы авторов входит апробация такого подхода.

Работа выполнена по государственным заданиям Института космических исследований РАН (тема «Мониторинг», госрегистрация № 122042500031-8) в части разработки автоматической методики восстановления интенсивности тропических циклонов и ИРЭ РАН (тема «Космос-2», госрегистрация № 0030-2019-0008) в части информационного обеспечения полыми интегрального влагосодержания атмосферы и водности облаков на основе спутниковых микроволновых данных.

Литература

1. *Arohan A., Koustav A., Abhishek S.* A Review of Convolutional Neural Networks // 2020 Intern. Conf. Emerging Trends in Information Technology and Engineering. 2020. P. 1–5. DOI: 10.1109/ic-ETITE47903.2020.049.
2. *Bai L., Tang J., Guo R., Zhang S.* Quantifying interagency differences in intensity estimations of Super Typhoon Lekima (2019) // *Frontiers of Earth Science*. 2022. V. 16. P. 5–16. DOI: 10.1007/s11707-020-0866-5.
3. *Chen B.-F., Chen B., Lin H.-T., Elsberry R. L.* Estimating tropical cyclone intensity by satellite imagery utilizing convolutional neural networks // *Weather and Forecasting*. 2019. V. 34. No. 2. P. 447–465. <https://doi.org/10.1175/WAF-D-18-0136.1>.
4. *Combinido J. S., Mendoza J. R., Aborot J.* A convolutional neural network approach for estimating tropical cyclone intensity using satellite-based infrared images // *Proc. 24th Intern. Conf. Pattern Recognition (ICPR-2018)*. 2018. P. 1474–1480. DOI: 10.1109/ICPR.2018.8545593.
5. *Dvorak V. F.* A Technique for the Analysis and Forecasting of Tropical Cyclone Intensities from Satellite Pictures. Washington, D. C.: National Oceanic and Atmospheric Administration, 1973. 25 p. <https://repository.library.noaa.gov/view/noaa/18546>.
6. *Kingma D. P., Ba J. L.* Adam: A method for stochastic optimization // *Proc. 3rd Intern. Conf. Learning Representations (ICLR, 2015)*. 2015. 15 p. <http://arxiv.org/abs/1412.6980>.
7. *Lee J., Im J., Cha D.-H. et al.* Tropical cyclone intensity estimation using multi-dimensional convolutional neural networks from geostationary satellite data // *Remote Sensing*. 2020. V. 12. Iss. 1. Article 108. <https://doi.org/10.3390/rs12010108>.
8. *Sharkov E. A.* Global Tropical Cyclogenesis. Berlin; Heidelberg; L.; N. Y. etc.: Springer/PRAXIS, 2000. 361 p.
9. *Sharkov E. A.* Global tropical cyclogenesis. 2nd ed. Berlin, Heidelberg: Springer-Verlag, 2012. 604 p.
10. *Sun H., Lei X., Tang J., Yao L.* Comparisons of the characteristics of tropical cyclones experiencing extra-tropical transition in the western north pacific based on different dataset // *J. Tropical Meteorology*. 2017. V. 23. No. 3. DOI: 10.16555/j.1006-8775.2017.03.005.
11. *Velden C. S., Herndon D.* An update on the SATellite CONsensus (SATCON) algorithm for estimating tropical cyclone intensity // *Proc. 31st Conf. Hurricanes and Tropical Meteorology*. 2014. https://tropic.ssec.wisc.edu/misc/satcon/hurrconf_2014_satcon_poster.pdf.
12. *Wimmers A., Velden C., Joshua C.* Using deep learning to estimate tropical cyclone intensity from satellite passive microwave imagery // *Monthly Weather Review*. 2019. V. 147. No. 6. P. 2261–2282. <https://doi.org/10.1175/MWR-D-18-0391.1>.
13. *Xiang K., Yang X., Zhang M. et al.* Objective Estimation of Tropical Cyclone Intensity from Active and Passive Microwave Remote Sensing Observations in the Northwestern Pacific Ocean // *Remote Sensing*. 2019. V. 11. No. 6. Article 627. DOI: 10.3390/rs11060627.
14. *Yang S., Gossuth J.* Satellite remote sensing of tropical cyclones // *Recent Developments in Tropical Cyclone Dynamics, Prediction, and Detection* / ed. Lupo A. R. 2016. DOI: 10.5772/64114.
15. *Yu H., Hu C., Jiang L.* Comparison of three tropical cyclone strength datasets // *J. Meteorological Research*. 2007. V. 21. No. 1. P. 121–128.
16. *Zhao Y., Zhao C., Sun R., Wang Z.* A multiple linear regression model for tropical cyclone intensity estimation from satellite infrared images // *Atmosphere*. 2016. V. 7. No. 40. <https://doi.org/10.3390/atmos7030040>.

Development of a new automatic method for reconstructing the intensity of tropical cyclones from multispectral satellite Earth observations using artificial neural networks

A. N. Yakusheva¹, D. M. Ermakov^{1,2}

¹ Space Research Institute RAS, Moscow 117997, Russia
E-mails: annayakusheva99@mail.ru, pldime@gmail.com

² Kotelnikov Institute of Radio Engineering and Electronics RAS, Fryazino Branch
Fryazino 141190, Moscow Region, Russia

The paper presents an automatic method for reconstructing the intensity of tropical cyclones (TCs) from their satellite images, based on a convolutional neural network. To form a sample of initial data, 43688 records of TCs from the databases of the main regional national tropical cyclone monitoring centers (for brevity, “national hurricane centers”, NHC DB) and corresponding satellite images in several spectral ranges (visible, IR, microwave) were used. The collected data covers observations from 1981 to 2022 in all areas of the World Ocean, except the Indian Ocean, involved in the genesis of tropical cyclones. A study was carried out on the implementation of a neural network with the best performance, restoring the intensity of TCs using the collected volume of data. Based on the results of the study, a neural network was designed, implemented and trained, which provided (when comparing the reconstructed TC intensity value with those indicated in the NHC DB) a root mean square error of about 11.3 (11.4) nodes; the coefficient of determination is about 0.80 (0.82) depending on the combination of types of input information. It is noted that the achieved quality indicators exceed those known from the literature or are comparable to them. At the same time, an analysis of works on the development of approaches to automated assessment of TC intensity showed that all of them were carried out using significantly (orders of magnitude) smaller volumes of input information (individual water areas, single years, certain phases of TC development, etc.). Estimates of the root-mean-square error stated in the literature range from 8 to 14 knots, but the minimum level of error is achieved through special selection of “suitable” data.

Keywords: tropical cyclones, intensity retrievals, artificial neural networks, multispectral satellite observations

Accepted: 29.03.2024

DOI: 10.21046/2070-7401-2024-21-2-336-349

References

1. Arohan A., Koustav A., Abhishek S., A Review of Convolutional Neural Networks, *2020 Intern. Conf. Emerging Trends in Information Technology and Engineering*, 2020, pp. 1–5, DOI: 10.1109/ic-ETITE47903.2020.049.
2. Bai L., Tang J., Guo R., Zhang S., Quantifying interagency differences in intensity estimations of Super Typhoon Lekima (2019), *Frontiers of Earth Science*, 2022, Vol. 16, pp. 5–16, DOI: 10.1007/s11707-020-0866-5.
3. Chen B.-F., Chen B., Lin H.-T., Elsberry R. L., Estimating tropical cyclone intensity by satellite imagery utilizing convolutional neural networks, *Weather and Forecasting*, 2019, Vol. 34, No. 2, pp. 447–465, <https://doi.org/10.1175/WAF-D-18-0136.1>.
4. Combinido J. S., Mendoza J. R., Aborot J., A convolutional neural network approach for estimating tropical cyclone intensity using satellite-based infrared images, *Proc. 24th Intern. Conf. Pattern Recognition (ICPR-2018)*, 2018, pp. 1474–1480, DOI: 10.1109/ICPR.2018.8545593.
5. Dvorak V. F., *A Technique for the Analysis and Forecasting of Tropical Cyclone Intensities from Satellite Pictures*, Washington, D. C.: National Oceanic and Atmospheric Administration, 1973, 25 p., <https://repository.library.noaa.gov/view/noaa/18546>.
6. Kingma D. P., Ba J. L., Adam: A method for stochastic optimization, *Proc. 3rd Intern. Conf. Learning Representations (ICLR, 2015)*, 2015, 15 p., <http://arxiv.org/abs/1412.6980>.
7. Lee J., Im J., Cha D.-H. et al., Tropical cyclone intensity estimation using multi-dimensional convolutional neural networks from geostationary satellite data, *Remote Sensing*, 2020, Vol. 12, Issue 1, Article 108, <https://doi.org/10.3390/rs12010108>.

8. Sharkov E. A., *Global Tropical Cyclogenesis*, Berlin; Heidelberg; London; New York etc.: Springer/PRAXIS, 2000, 361 p.
9. Sharkov E. A., *Global tropical cyclogenesis. 2nd ed.*, Berlin, Heidelberg: Springer-Verlag, 2012, 604 p.
10. Sun H., Lei X., Tang J., Yao L., Comparisons of the characteristics of tropical cyclones experiencing extratropical transition in the western north pacific based on different dataset, *J. Tropical Meteorology*, 2017, Vol. 23, No. 3, DOI: 10.16555/j.1006-8775.2017.03.005.
11. Velden C. S., Herndon D., An update on the SATellite CONsensus (SATCON) algorithm for estimating tropical cyclone intensity, *Proc. 31st Conf. Hurricanes and Tropical Meteorology*, 2014, https://tropic.ssec.wisc.edu/misc/satcon/hurrconf_2014_satcon_poster.pdf.
12. Wimmers A., Velden C., Joshua C., Using deep learning to estimate tropical cyclone intensity from satellite passive microwave imagery, *Monthly Weather Review*, 2019, Vol. 147, No. 6, pp. 2261–2282, <https://doi.org/10.1175/MWR-D-18-0391.1>.
13. Xiang K., Yang X., Zhang M. et al., Objective Estimation of Tropical Cyclone Intensity from Active and Passive Microwave Remote Sensing Observations in the Northwestern Pacific Ocean, *Remote Sensing*, 2019, Vol. 11, No. 6, Article 627, DOI: 10.3390/rs11060627.
14. Yang S., Gossuth J., Satellite remote sensing of tropical cyclones, In: *Recent Developments in Tropical Cyclone Dynamics, Prediction, and Detection*, Lupo A. R. (ed.), 2016, DOI: 10.5772/64114.
15. Yu H., Hu C., Jiang L., Comparison of three tropical cyclone strength datasets, *J. Meteorological Research*, 2007, Vol. 21, No. 1, pp. 121–128.
16. Zhao Y., Zhao C., Sun R., Wang Z., A multiple linear regression model for tropical cyclone intensity estimation from satellite infrared images, *Atmosphere*, 2016. Vol. 7, No. 40, <https://doi.org/10.3390/atmos7030040>.