

## Нейросетевая сегментация облачности и снежного покрова по мультиспектральным данным гидрометеорологического спутника «Электро-Л» № 2

Н. В. Беляков<sup>1</sup>, А. В. Васильев<sup>1</sup>, С. В. Колпинский<sup>2</sup>

<sup>1</sup> *Московский государственный университет имени М. В. Ломоносова  
Москва, 119991, Россия*

*E-mail: nikita.belyakov@cosmos.msu.ru*

<sup>2</sup> *Национальный исследовательский университет «МЭИ», Москва, 111250, Россия  
E-mail: kolpinskyv@mpei.ru*

Работа посвящена методике детектирования облачности и снежного покрова по мультиспектральным данным с аппаратуры многозонального сканирующего устройства геостационарного (МСУ-ГС) космического аппарата (КА) «Электро-Л» № 2 с применением нейронной сети свёрточного типа. Для разработки нейросетевого алгоритма был создан собственный набор данных, содержащий мультиспектральные снимки с аппаратуры МСУ-ГС, установленной на космическом аппарате «Электро-Л» № 2, с разметкой снега и облачности. Для создания разметки облачного и снежного покрова были использованы репроецированные на точку стояния «Электро-Л» № 2 снимки с космических аппаратов GOES-16 (*англ.* Geostationary Operational Environmental Satellite) и Meteosat-10. В качестве дополнительных сведений приложена географическая информация: широта, долгота и высота для пикселей снимков. В качестве модели нейросети применяется MANet (*англ.* Multi-Scale Attention Network). Одной из существенных проблем при разработке алгоритма сегментации снега и облачности становится отсутствие коротковолновых инфракрасных каналов (1300–1600 нм), необходимых для работы классических алгоритмов сегментации на основе тестов по нормированному снежному индексу. При ограничениях на спектральные характеристики аппаратуры МСУ-ГС и низком разрешении снимков в качестве решения задачи выделения снега и облаков на мультиспектральных данных предлагается нейросетевой алгоритм, способный по неявным признакам и закономерностям дифференцировать снег и облака. Для репрезентативности снимки в выборке включают в себя все времена года и разные уровни освещённости (12:00–17:00 UTC (*англ.* Coordinated Universal Time, всемирное координированное время)). Обученная нейронная сеть для сегментации протестирована в различных сценариях, включая зимний и летний периоды года в дневное время суток при разном уровне освещённости снимков применительно к данным с прибора МСУ-ГС спутника «Электро-Л» № 2. По результатам тестирования получены следующие метрики качества сегментации:  $F_{1s} = 0,7454$ ,  $F_{1c} = 0,8773$  и  $IoU_s = 0,7398$ ,  $IoU_c = 0,7976$  (*англ.* Intersection over Union index) для классов снега (*англ.* snow, субскрипт *s*) и облачности (*англ.* clouds, субскрипт *c*) соответственно.

**Ключевые слова:** «Электро-Л» № 2, МСУ-ГС, свёрточная нейронная сеть, сегментация, облачный покров, снежный покров, географическая информация, карта высот

Одобрена к печати: 29.03.2024

DOI: 10.21046/2070-7401-2024-21-2-36-50

### Введение

Оперативность получения информации и относительно высокое пространственное разрешение позволяют рассматривать геостационарные спутники в качестве основного инструмента глобального мониторинга состояния окружающей среды, климата и атмосферы. Приборы, устанавливаемые на геостационарные космические аппараты (КА), позволяют проводить съёмку в широком диапазоне длин волн от видимого до длинноволнового инфракрасного (ИК) излучения. Это даёт возможность решать ряд задач, связанных с определением опасных метеорологических явлений, мониторингом состояния атмосферы и др. Эти и многие другие задачи подразумевают использование маски облачности, а также снежного покрова, к которым выдвигается ряд требований. Расчёт масок должен выполняться за время, достаточное для работы в оперативном режиме с учётом высокой частоты съёмки (10–30 мин); маски

должны рассчитываться для различных климатических условий. Задачи мониторинга снежного покрова и облачности являются очень востребованными на сегодняшний день для улучшения точности прогноза погоды, оценки изменения глобального климата, уровня аэрозоля в атмосфере.

Исходя из задач, решаемых в настоящее время в Научно-исследовательском центре космической гидрометеорологии «Планета» (НИЦ «Планета») и в центрах оперативного мониторинга Земли, возникает та же необходимость в создании алгоритмов получения масок облачности и снежного покрова, учитывающих вышеобозначенные требования. Рассматриваемый в настоящей работе подход основан на применении нейросетевых свёрточных моделей сегментации. Предлагаемый метод сегментирования опирается на опыт ранее проведённых исследований в области обработки данных со спутников дистанционного зондирования Земли (ДЗЗ) и геостационарных КА (Bloshchinskiy et al., 2020; Li et al., 2022; Wu et al., 2021; Yin et al., 2022; Zhang et al., 2020). Полученный нейросетевой алгоритм предназначен для применения к данным с аппаратуры МСУ-ГС (многозональное сканирующее устройство геостационарное) на КА «Электро-Л» № 2, позволяет использовать его для анализа снега и облачности в режиме реального времени.

Сложность задачи различения снега и облаков заключается в схожести их спектральных характеристик почти во всех спектральных диапазонах. Класс «суша/вода» легко отличим от других классов в видимом спектре. Во многих алгоритмах обнаружения снежного покрова (Heidinger et al., 2017; Khlopenkov et al., 2007) задействуются ИК-каналы в диапазоне от 1,3 до 1,6 мкм. Но из-за отсутствия этих каналов на МСУ-ГС необходимо разработать собственный алгоритм, позволяющий эффективно разделять данные классы.

## Методы детектирования облачности и снежного покрова

На сегодняшний день существует несколько подходов к решению задачи выделения масок снега и облачного покрова: методы на основе пороговых значений, статистические методы, подходы на основе машинного и глубокого обучения.

Подход на основе пороговых значений — самый простой и распространённый. В его основе лежит спектральный анализ подстилающей поверхности и облачности в каждом пикселе изображения. Результаты классификации с помощью этих методов легко поддаются физическому обоснованию (Miller et al., 2005). Однако качество их работы сильно зависит от точности подбора пороговых коэффициентов. Процесс такого подбора становится трудоёмким для территорий с различными климатическими условиями и для каждого типа съёмочной аппаратуры (Bloshchinskiy et al., 2020).

В сценах, где присутствует снег или оптически тонкая перистая облачность, качество классификации значительно падает из-за схожести спектральных характеристик снега и ледяных облаков, а также из-за искажений, возникающих при прохождении излучения сквозь облака (Bloshchinskiy et al., 2020).

Статистические методы детектирования облачности и снега базируются на уравнениях регрессии, полученных из статистического анализа спектральных характеристик отражающей способности и яркостной температуры (*англ.* brightness temperature — BT) среди облачных и безоблачных пикселей (Астафуров и др., 2014). На практике эти методы используются для предварительного анализа данных и обладают теми же недостатками, что и пороговые методы (Heidinger et al., 2017; Khlopenkov et al., 2007).

Практика показывает, что подходы с применением нейронных сетей (НС) в сочетании с текстурными и спектральными признаками демонстрируют наибольшую точность в задаче сегментации (Bloshchinskiy et al., 2020; Wu et al., 2021). Однако данная методика осложняется получением точной разметки. В ряде работ (Khlopenkov et al., 2007; Mohajerani, Saedi, 2019; Wu et al., 2021) показано, что улучшение качества разметки в данных и разнообразие обучающей выборки позволяют существенно улучшить качество сегментации нейросетевыми моделями.

## Анализ результатов имеющихся работ и обзор наборов данных

В настоящее время существует достаточно много работ, использующих подход сегментации для мультиспектральных данных с геостационарных КА в низком разрешении (1–4 км). Наиболее близкими по результатам являются исследования (Bloshchinskiy et al., 2020; Wu et al., 2021). В первом из них используются данные с МСУ-ГС КА «Электро-Л» № 2. Поскольку ни один из спектральных каналов МСУ-ГС не находится в диапазоне 1,3–1,6 мкм, необходимом для отличия снега от облаков, авторы берут набор спектральных каналов на 0,6; 0,7; 0,9; 3,8 и 10,7 мкм (каналы 1–4, 9, табл. 1). Такая гамма спектральных каналов позволяет визуально различить снег и типы облаков на изображении (Bloshchinskiy et al., 2020), что потенциально и позволяет модели НС разделять эти классы. Для ручной разметки используется синтез каналов 0,9; 3,8 и 10,7 мкм, поскольку их спектральные характеристики схожи со спектральными каналами съёмочной аппаратуры SEVIRI (англ. Spinning Enhanced Visible Infrared Imager) спутника Meteosat-8 (Wildt et al., 2007), которые используются в программном обеспечении CAPSAT (англ. Clouds-Aerosols Precipitation Satellite Analysis Tool).

Таблица 1. Характеристики аппаратуры МСУ-ГС КА «Электро-Л» № 2

№ канала	Длина волны, мкм	Разрешение, км
<b>1</b>	<b>0,50–0,65</b>	<b>1</b>
<b>2</b>	<b>0,65–0,80</b>	<b>1</b>
<b>3</b>	<b>0,80–0,90</b>	<b>1</b>
<b>4</b>	<b>3,50–4,00</b>	<b>4</b>
5	5,70–7,00	4
6	7,50–8,50	4
7	8,20–9,20	4
8	9,20–10,2	4
<b>9</b>	<b>10,20–11,2</b>	<b>4</b>
10	11,20–12,5	4

Авторы исследования (Bloshchinskiy et al., 2020) используют нейросетевой классификатор, работающий на текстурах размером 11×11 пикселей в пяти каналах в разрешении 4 км и делающий предсказание класса для центрального пикселя. Набор данных состоит из отдельных текстур (11, 11, 5) в вышеописанных спектральных каналах, для которых определён класс центрального пикселя. Выборка Electro Textures Dataset состоит из 112 000 текстур и разделена на три подвыборки: обучающую (75 %), валидационную (10 %) и тестовую (15 %) ([https://figshare.com/articles/dataset/Electro\\_Textures\\_Dataset\\_vol\\_1/9722723](https://figshare.com/articles/dataset/Electro_Textures_Dataset_vol_1/9722723)).

Текстуры собраны с марта 2018 г. по март 2019 г. Тестовый датасет составлен из 20 полигонов в диапазоне от 30 до 80° в.д. (зона совпадения спутниковых снимков КА «Электро-Л» № 2 и Meteosat-8) с девяти спутниковых снимков.

Предварительно данные по трём каналам видимого спектра (0,6; 0,7 и 0,9 мкм) были скорректированы с использованием угла зенита Солнца (англ. zenith solar angle – ZSA) (1), что позволяет нивелировать эффект затенения на снимках из-за разного местоположения Солнца относительно КА в каждый момент съёмки:

$$\text{Rad}_{\text{ZSA}} = \frac{\text{Rad}}{\cos(\text{ZSA})}. \quad (1)$$

Для обучения и тестирования модели классификатора значения всех каналов были линейно масштабированы на отрезок [0, 1], что является необходимой процедурой для достижения сходимости НС.

Для оценки качества классификации текстур используется метрика  $F_1$ :

$$F_1 = \frac{2TP}{(2TP + FP + FN)}, \quad (2)$$

где TP — количество верно предсказанных объектов данного класса; FP — количество неверных предсказаний модели, что объекты принадлежат данному классу; FN — количество верных предсказаний модели, что объекты не принадлежат данному классу. После обучения модели авторы получили качество  $F_1 = 0,9945$  на тестовой части Electro Textures Dataset.

Отметим, что на тестовых частях снимков в зоне перекрытия «Электро-Л» № 2 и Meteosat-8 авторы получили следующее качество классификации:  $F_1 = 0,8383$ ,  $F_1 = 0,8897$ ,  $F_1 = 0,7915$  для классов «суша/вода», «снег» и «облачность» соответственно, что сопоставимо с результатами алгоритма детекции облачности SEVIRI:  $F_1 = 0,7973$ ,  $F_1 = 0,8289$  для классов «суша/снег» и «облачность» соответственно.

В работе (Wu et al., 2021) используется выборка Levir CS с КА ДЗЗ Gaofen-1, имеющей четыре канала (R — *англ.* red, красный; G — *англ.* green, зелёный; B — *англ.* blue, синий, NIR — *англ.* near infrared, ближний инфракрасный), а также географическую информацию о широте, долготе и высоте каждого пикселя снимка. Изображения в датасете Levir CS имеют размер  $1200 \times 1320$  пикселей в разрешении 160 м. Для получения информации о высоте земной поверхности на снимках использовалась карта высот SRTM (*англ.* Shuttle Radar Topography Mission, <https://srtm.csi.cgiar.org/>) в разрешении 90 м. Кроме этого, каждое мультиспектральное изображение содержит географическую привязку к широте и долготе, соответствующую картографической проекции геодезической системы WGS84 (*англ.* World Geodetic System 1984). Авторы отмечают заметную корреляцию распределения снежного и облачного покрова относительно широты, долготы и высоты на снимках, поэтому использование этой дополнительной информации оправдано и улучшает качество сегментации.

Для оценки качества сегментации авторы работы (Wu et al., 2021) пользуются метриками  $F_1$  (2) и Jaccard Index или же Intersection over Union (IoU) (3):

$$\text{IoU} = \frac{|Y_{pr} \cap Y_{gt}|}{|Y_{pr} \cup Y_{gt}|}, \quad (3)$$

где  $Y_{pr}$ ,  $Y_{gt}$  — метки предсказанного (*pr* — от *англ.* predicted) и истинного (*gt* — от *англ.* ground truth) классов соответственно.

В качестве архитектуры для сегментации снега и облачности на снимках с Gaofen-1 в работе (Wu et al., 2021) создана модель GeoInfoNet. После её обучения и проверки качества сегментации на тестовой подвыборке Levir CS авторы приводят результаты, показанные в табл. 2.

Таблица 2. Результаты GeoInfoNet на тестовой выборке Levir CS из работы (Wu et al., 2021)

Метрика	Класс облачности	Класс снега
$F_1$	0,9515	0,8393
IoU	0,9074	0,7826

В настоящей работе используются описанные в рассмотренных исследованиях подходы к применению свёрточных моделей сегментации, задействована дополнительная географическая информация, ИК-каналы, а также метрики для оценки качества сегментации. При этом в стратегии обучения НС был учтён дисбаланс классов, использована обучающая выборка большего размера по сравнению с работой (Bloschinskiy et al., 2020), применён подход сегментации вместо классификации, задействованы все доступные ИК-каналы съёмочной аппаратуры МСУ-ГС, а также географическая информация.




## Используемые данные и формирование собственных выборок

Настоящая работа использует данные с метеорологических КА «Электро-Л» № 2, Meteosat-10, GOES-16 (*англ.* Geostationary Operational Environmental Satellite), а также системы Terra/MODIS (*англ.* Moderate Resolution Imaging Spectroradiometer) для создания нейросетевого алгоритма для сегментации на снимках с МСУ-ГС. Характеристики съёмочной аппаратуры МСУ-ГС на спутнике «Электро-Л» № 2 представлены в *табл. 1*. Таким образом, объектами анализа становятся изображения, содержащие 10 каналов. Изображения в первых трёх каналах имеют размер  $11\,136 \times 11\,136$  пикселей, в следующих семи каналах —  $2784 \times 2784$  пикселей. Периодичность съёмки — 30 мин (подробнее про аппаратуру МСУ-ГС см. по ссылке <https://ntsomz.ru/elektro/>). Снимки хранятся в формате HDF (*англ.* Hierarchical Data Format) в НИЦ «Планета» (все каналы в разрешении 4 км) вместе с географической привязкой к широте и долготе. Значения пикселей представлены в форматах яркости Rad (*англ.* Radiance) для видимого и ближнего ИК-каналов и яркостной температуры (BT) для ИК-каналов. Последний переход от Rad к BT осуществляется через формулу Планка (4):

$$BT = \frac{(fk_2 / \ln(fk_1 / \text{Rad})) - bc_1}{bc_2}, \quad (4)$$

где коэффициенты  $fk_1$ ,  $fk_2$  и  $bc_1$ ,  $bc_2$  — нормирующие константы для каждого спектрального ИК-канала. Матрицы коррекции по углу зенита Солнца вычисляются на основе местоположения Солнца относительно КА и Земли на момент съёмки с использованием пакета Python pvlib (<https://doi.org/10.21105/joss.00884>). Данная коррекция (*рис. 1*) применима только для зон съёмки, где угол зенита Солнца не превышает  $80^\circ$ , поэтому предварительно для матрицы углов осуществляется усечение на диапазон  $[0^\circ, 80^\circ]$  (все значения больше  $80^\circ$  принимаются равными  $80^\circ$ ).




*Рис. 1.* Снимок с КА «Электро-Л» № 2 в видимом и ближнем ИК-спектрах до (*слева*) и после (*справа*) коррекции по углу зенита Солнца (15.10.2022, 16:00 UTC)

Для получения дополнительной информации о высоте используются карты высот земной поверхности Aster GDEM (*англ.* Global Digital Elevation Model, <https://asterweb.jpl.nasa.gov/gdem.asp>), охватывающие диапазон от  $-83$  до  $83^\circ$  по широте, что позволяет покрыть всю земную поверхность на снимках спутника, в отличие от SRTM (<https://srtm.csi.cgiar.org/>) с диапазоном широт только от  $-60$  до  $60^\circ$ .

Существенной проблемой в разработке точного алгоритма сегментации снега и облачности становится отсутствие разметки для целевых данных с МСУ-ГС. L2-продукты по маскам для КА «Электро-Л» № 2 отсутствуют, а ручная разметка крайне трудоёмка, поскольку в разрешении 4 км без задействования каналов SWIR (*англ.* Short Wave Infrared) даже специалисту затруднительно отличить снег от облаков на снимках. Использование пороговых тестов NDSI (*англ.* Normalized Difference Snow Index) для дифференциации снега и облаков невозможно из-за нехватки того же SWIR-канала. Ниже описана процедура получения разметки классов снега и облачности с использованием L2-продуктов с других спутников.

Мультиспектральные данные с КА GOES-16 и L2-продукты (*англ.* clear sky и cloud moisture imagery), получаемые из них, взяты из базы данных Amazon (<https://home.chpc.utah.edu>). L2-продукты с КА Meteosat-10 доступны на EUMETSAT (*англ.* European Organisation for the Exploitation of Meteorological Satellites) Data Store (<https://navigator.eumetsat.int/product/>). Эти геостационарные спутники были выбраны исходя из того, что имеют близкие точки стояния относительно «Электро-Л» № 2, что позволяет использовать объединение масок с них для покрытия всего поля зрения целевого спутника (*рис. 2г*).



*Рис. 2.* Маска облачности с КА GOES-16 (*а*); маска облачности с КА Meteosat-10 (*б*); среднесуточная маска снега Terra/MODIS (*в*); соединённые маски снега и облачности на снимке 15.02.2022, 14:00 UTC с КА «Электро-Л» № 2 (*г*)



Данные Clear sky L2 GOES-16 хранятся в формате NetCDF (*англ.* Network Common Data Form) в разрешении 2 км. Каждый пиксель снимка размечен одним из четырёх классов: 0 — clear (вероятность облачности менее 10 %); 1 — probably clear (вероятность облачности от 10 до 50 %); 2 — probably cloudy (вероятность облачности от 50 до 90 %); 3 — cloudy (вероятность облачности более 90 %) (подробнее см. в исследовании (Heidinger et al., 2017)). В данной работе только пиксели, помеченные классом 3, принимаются за истинную (*gt*) маску облачности (*рис. 2а*). Все маски с GOES-16 были приведены к разрешению 4 км и репроецированы на точку стояния  $-14,5^\circ$ , соответствующую позиции КА «Электро-Л» № 2 (см. *рис. 2а*).

L2-продукты Cloud Mask – MSG – 0 degree (содержащие маски clear sky over water, clear sky over land, cloud, or not processed – off the Earth disc) с КА Meteosat-10 хранятся в формате GRIB (*англ.* GRIBdd Binary). Зона покрытия данных масок составляет от  $-67,5$  до  $67,5^\circ$  по широте и долготе с пространственным разрешением 3 км. Следовательно, далее только вышеописанные диапазоны широты и долготы на снимках с «Электро-Л» № 2 берутся для работы (*рис. 2б*). Все маски с Meteosat-10 были также приведены к разрешению 4 км и репроецированы на точку стояния «Электро-Л» № 2.

L2-маски с GOES-16 и Meteosat-10 не содержат информацию о снежном покрове. Поэтому в качестве истинных (*gt*) масок для снега были взяты среднесуточные маски Terra/MODIS ([https://neo.gsfc.nasa.gov/view.php?datasetId=MOD10C1\\_D\\_SNOW&date](https://neo.gsfc.nasa.gov/view.php?datasetId=MOD10C1_D_SNOW&date)), предоставляемые в проекции Plate Caree. Для соотнесения этих масок со снимками с МСУ-ГС они были приведены в геостационарную проекцию с точкой стояния «Электро-Л» № 2. Эти маски имеют разрешение  $0,1^\circ$  и содержат значения доли снега (в %) для каждого пикселя. Для получения бинарных масок брался порог 50 % снега в пикселе, чтобы считать его помеченным классом снега (*рис. 2в*).

Стоит отметить, что алгоритмы получения масок облачности и снежного покрова, используемые при обработке спутниковых снимков с других КА, могут иметь свои ошибки. Так как маски, полученные из снимков других КА, в собственном наборе данных используются как целевые данные для последующего обучения нейронной сети, стоит понимать, что нейронная сеть, вероятно, обучится в том числе и на данных ошибках и при дальнейшем использовании будет их воспроизводить. Противоположностью описанного способа получения масок представляется ручная разметка, являющаяся крайне трудоёмкой и также не лишённой ошибок. Описанный способ получения масок для изображений «Электро-Л» № 2 с привлечением изображений с других КА в данной работе был сочтён как приемлемый в силу относительной простоты, несмотря на возможное наличие ошибок в получаемой разметке.

Итак, собранная выборка представляет собой мультиспектральные снимки с КА «Электро-Л» № 2, каждый из которых имеет геопривязку и разметку, полученную из L2-продуктов GOES-16, Meteosat-10 и Terra/MODIS (Ackerman, Frey, 2015). Выборка размечена на три класса: «суша/вода» (*bg* — от *англ.* background, метка 0), «снег» (метка 1) и «облачность» (метка 2). Выборка охватывает период с 15 января 2021 г. до 15 мая 2023 г. в дневной период 12:00–17:00 UTC (*англ.* Coordinated Universal Time, всемирное координированное время) и соответствует максимальному уровню освещённости снимков «Электро-Л» № 2 в точке стояния. Всего выборка включает 142 снимка, каждый из которых разбит на 144 фрагмента-патча размером  $224 \times 224$  пикселя. Каждый элемент выборки — массив с размерами (12, 224, 224): девять каналов мультиспектральных данных и три канала геоинформации. Все каналы линейно нормированы на отрезок  $[0, 1]$ . Итоговая область для анализа составляет от  $-97,5$  до  $68,5^\circ$  по долготе и от  $-67,5$  до  $67,5^\circ$  по широте.

Разбиение полученной выборки на тренировочную, валидационную и тестовую части проводилось на уровне исходных 142 снимков, что позволяет избежать утечки данных в тренировочную подвыборку. В обучающее множество вошло 112 снимков за весь 2022 г., а оставшиеся 30 снимков за октябрь – декабрь 2021 г. и январь – май 2023 г. были поровну (15 и 15) выделены для валидации и тестирования.

## Модели и результаты

В настоящей работе объединены подходы сегментации и классификации мультиспектральных данных, предложенные в исследованиях (Bloschchinskiy et al., 2020; Wu et al., 2021) для получения итоговых масок снега и облачности по снимкам КА «Электро-Л» № 2. Из анализа работ по смежной тематике (Cao et al., 2022; Li et al., 2022; Zhang et al., 2020) в качестве модели сегментации была выбрана MANet (*англ.* Multi-Scale Attention Network) (Fan et al., 2020), реализованная в библиотеке Python Segmentation-Models-Pytorch ([https://github.com/qubvel/segmentation\\_models\\_pytorch](https://github.com/qubvel/segmentation_models_pytorch)) фреймворка Pytorch (<https://pytorch.org/>) с сжимающей частью (*англ.* encoder) EfficientNet-B0 (Tan et al., 2019) для извлечения скрытых признаков из снимков.

### Функция потерь при обучении

Обучение нейронной сети для решения задачи сегментации относится к парадигме обучения на размеченных данных (*англ.* supervised learning). С формальной точки зрения процесс обучения нейронной сети на размеченных данных является итеративным процессом оптимизации (минимизации) функции потерь по весовым коэффициентам нейронов (параметрам нейронной сети, настраиваемым в процессе обучения). Функцией потерь называется дифференцируемая по своим аргументам функция, которая определяет способ вычисления ошибки нейронной сети — меры несоответствия между её выходом и целевыми значениями (разметкой).

Исходя из анализа распределения экземпляров снега и облачности в собранной выборке с МСУ-ГС, для достижения сходимости обучения нужна функция потерь и метрики, учитывающие сильный дисбаланс классов (менее 2 % пикселей снега). В работе (Zhang et al., 2020) для детекции облачности представлена линейная комбинация CrossEntropyLoss (5) и DiceLoss (6):

$$\text{CrossEntropyLoss} = -\sum_{k=1}^{C=3} y_k \log(p_k), \quad (5)$$

$$\text{DiceLoss} = 1 - \frac{2 \sum_{k=1}^{C=3} p_k y_k}{\sum_{k=1}^{C=3} p_k + \sum_{k=1}^{C=3} y_k}, \quad (6)$$

где  $y_k, p_k$  — истинная (*gt*) вероятность  $k$ -го класса и предсказание вероятности данного класса моделью соответственно;  $C$  — количество классов в задаче (здесь  $C = 3$ : «суша/вода», «облачность», «снег»).

Здесь же с учётом сильного дисбаланса классов в выборке и схожести спектральных характеристик классов снега и облачности CrossEntropyLoss была заменена на FocalLoss (7) (Lin et al., 2018):

$$\text{FocalLoss} = -(1 - p_{pr})^\alpha \log(p_{pr}), \quad (7)$$

где  $\alpha$  — «фокусирующий» коэффициент, увеличивающий относительный вклад в функцию потерь ошибок модели на «сложных» примерах (на которых модель склонна ошибаться) по сравнению с ошибками на «простых» примерах (для которых модель работает достаточно точно);  $p_{pr}$  — предсказанная моделью вероятность истинного класса. В нашей работе выбрано значение  $\alpha = 2$ .

В силу того, что FocalLoss обеспечивает лучшую стабильность обучения, а DiceLoss — лучшее качество сегментации, в качестве итоговой функции потерь для сегментации взята следующая (здесь  $\beta = 0,3$ ):

$$\text{Loss} = \beta \cdot \text{DiceLoss} + (1 - \beta) \text{FocalLoss}. \quad (8)$$



## Обучение и тестирование модели на данных МСУ-ГС

Как было сказано выше, обучение нейронной сети представляет собой итеративный процесс оптимизации функции потерь по настраиваемым параметрам НС. Такая оптимизация обычно проводится градиентными методами первого порядка (методом градиентного спуска). На каждой итерации обучения на вход модели подаются входные данные, вычисляется выход модели, затем — значение функции потерь, после чего — градиент функции потерь по всем весовым коэффициентам нейронов НС. Значение градиента используется для обновления весовых коэффициентов на текущей итерации. Правило обновления весовых коэффициентов с учётом градиента функции потерь зависит от конкретного алгоритма оптимизации (см., например, обзор в работе (Sun et al., 2019)). Основным гиперпараметром различных алгоритмов оптимизации является темп обучения (*англ.* learning rate). Темп обучения может быть постоянным на протяжении всего процесса обучения или меняться по некоторому закону. Закон изменения темпа обучения задаётся так называемым планировщиком темпа обучения (*англ.* learning rate scheduler) (см. обзор в работе (Wu et al., 2019)).

Шаги градиентного спуска осуществляются итеративно по подмножествам образцов обучающей выборки — так называемым мини-батчам (*англ.* mini-batch). Однократное предъявление нейронной сети всех образцов обучающей выборки в составе мини-батчей называется эпохой обучения. Эпохи обучения повторяются до достижения некоторого критерия останова или максимального количества эпох. В процессе обучения состав мини-батчей каждую эпоху формируется случайным образом. В случае сильного дисбаланса классов в обучающей выборке необходимо учитывать частоту встречаемости классов при случайном формировании мини-батчей для повышения сбалансированности классов в пределах каждого мини-батча. Процесс формирования мини-батчей для обучения НС принято называть сэмплированием. Конкретный выбор функции потерь, метода оптимизации, планировщика темпа обучения, правила формирования мини-батчей может быть назван стратегией обучения нейронной сети.

С учётом вышеописанных проблем с различимостью снега и облаков была составлена следующая стратегия обучения НС. Для того чтобы обучить модель различать класс снега, использовался подход взвешенного сэмплирования (*англ.* Weighted Random Sampler — WRS) — частота попадания образцов с наличием снега в разметке в мини-батчи была увеличена. Для каждого патча выборки с КА «Электро-Л» № 2 были определены бинарные метки, соответствующие наличию снега. На их основе были рассчитаны для сэмплирования веса, обратно пропорциональные частоте встречаемости снега на патчах. Благодаря этим весам при сэмплировании экземпляры выборки с наличием снега в разметке попадают в мини-батчи значительно чаще, и каждый мини-батч оказывается сбалансированным по всем классам.

В качестве функции потерь была взята функция (8), описанная выше. В силу ограничений памяти видеокарты NVIDIA Quadro 2000 (6 GB) размер мини-батчей при обучении модели MANet был установлен равным 16. Для увеличения объёма и вариативности данных использовалась аугментация — техника искусственного увеличения вариативности данных в выборке путём синхронного применения к изображениям и маскам преобразований: поворотов, отражений, транспонирования, Fancy PCA (*англ.* Principle Component Analysis) для видимого спектра (искажение цветового представления изображения, основанное на методе главных компонент (Krizhevsky et al., 2012)), искривления, растяжения и других афинных преобразований из библиотеки kornia ([https://kornia-tutorials.readthedocs.io/en/latest/data\\_augmentation\\_segmentation.html](https://kornia-tutorials.readthedocs.io/en/latest/data_augmentation_segmentation.html)). В качестве алгоритма оптимизации использовался Ranger21 optimizer (Wright, Demeure, 2021), основанный на алгоритме оптимизации AdamW с добавлением L2-регуляризации (*англ.* adaptive moment estimation) (Loshchilov, Hutter, 2019), с различными модификациями, ускоряющими сходимость обучения. Дополнительно применялась комбинация оптимизатора AdamW и планировщика Cosine Annealing scheduler (Loshchilov, Hutter, 2017), что позволило лучше исследовать рельеф функции потерь (8) в процессе обучения модели.

Обучение проходило в течение 250 эпох с максимальным темпом обучения (*англ.* learning rate), равным 0,001, с критерием сохранения лучшей модели по метрике IoU на валида-

ционной подвыборке. Это условие позволило сохранить несколько моделей с различными весовыми коэффициентами нейронов, полученных при достижении различных локальных минимумов функции потерь (8) в процессе обучения, но дающих схожие результаты по метрикам  $F_1$  и IoU. В работе (Wortsman et al., 2022) была предложена техника повышения качества моделей под названием Model soups. Она состоит в сохранении нескольких идентичных моделей, полученных при достижении разных локальных минимумов функции потерь, и последующем получении итоговой модели, в которой каждый весовой коэффициент является средним арифметическим от соответствующих весовых коэффициентов промежуточных моделей. Применение подхода Model soups к трём экземплярам модели, сохранённым на 175-й, 198-й и 216-й эпохах, улучшило качество сегментации (лучшие значения метрик выделены полужирным начертанием в табл. 3). При этом время обработки полного изображения с КА «Электро-Л» № 2 осталось таким же (не длиннее 15 с на вычислительных ресурсах, указанных выше), что более чем в 20 раз быстрее алгоритма, представленного в работе (Bloschinskiy et al., 2020).

Таблица 3. Результаты сегментации MANet на тестовой выборке снимков с «Электро-Л» № 2 за конец 2021 г. и первую треть 2023 г. после обучения на данных с МСУ-ГС

Метрика	Суша/вода	Снег	Облачность	Среднее по классам	Model soups
$F_1$	0,8007	0,7416	0,8769	0,8066	нет
	<b>0,8009</b>	<b>0,7454</b>	<b>0,8773</b>	<b>0,8077</b>	да
IoU	0,6924	0,7354	0,7973	0,7418	нет
	<b>0,6925</b>	<b>0,7398</b>	<b>0,7976</b>	<b>0,7432</b>	да





Рис. 3. Тестовые патчи с КА «Электро-Л» № 2 в видимом и ближнем ИК-спектрах (слева), результат сегментации MANet (по центру) и истинная (gt) разметка с GOES-16, Meteosat-10 и Terra/MODIS (справа); зелёный цвет — маски снега, красный — облачности



Для визуальной оценки качества сегментации полученной модели отдельные патчи из тестовой выборки на 15.12.2021, 16:00 UTC и значения метрик на них представлены на *рис. 3* (см. с. 45).

### Оценка возможного переобучения модели на геоинформации

Для подтверждения, что MANet берет лишь дополнительную, а не основную информацию из широты, долготы и высоты снимка для предсказаний класса снега, были отобраны одни и те же патчи за разное время года. Так, на нескольких снимках одновременно присутствуют и снег, и облака, а в остальных наблюдаются только облака: снег либо заслонен облачностью, либо же отсутствует в принципе. На данной подвыборке были получены предсказания модели и посчитаны метрики сегментации для каждого из классов (*рис. 4*). Доказано, что полученная модель не переобучилась на геоинформации и осуществляет корректное предсказание снега преимущественно на основе мультиспектральных данных.



*Рис. 4.* Тестовый патч с КА «Электро-Л» № 2 в видимом и ближнем ИК-спектрах (*слева*), результат сегментации MANet (*по центру*) и истинная (gt) разметка с GOES-16, Meteosat-10 и Terra/MODIS (*справа*) за разные сезоны; зелёный цвет — маски снега, красный — облачности

Также были отобраны тестовые сцены с одновременным присутствием снега и облачности, на которых был проведён анализ влияния геоинформации на качество сегментации. На этих сценах были посчитаны метрики  $F_1$  и IoU для каждого класса при наличии геоинформации на входе модели; далее входные каналы геоинформации были заполнены гауссовским шумом с параметрами математического ожидания и дисперсии, оценёнными независимо в каждом канале для каждой сцены. Такой способ зашумления каналов геоинформации, по сути, является разновидностью перемешивания входных карт тестируемых признаков для модели. На патчах с зашумленными каналами геоинформации также были получены значе-



ния метрик  $F_1$  и IoU. Результаты исследования, приведённые в *табл. 4*, демонстрируют, что зашумление каналов с геоинформацией ухудшает качество сегментации.

*Таблица 4.* Результаты сегментации MANet на «сложных» тестовых сценах с «Электро-Л» № 2 (2023.02.15) с одновременным присутствием снега и облачности

Метрика	Признаки в каналах геоинформации	Суша/вода	Снег	Облачность	Среднее по классам
$F_1$	актуальные	0,8964	0,5858	0,8893	0,7905
	зашумленные	0,8931	0,5358	0,8822	0,7698
IoU	актуальные	0,8134	0,5552	0,8030	0,7239
	зашумленные	0,8094	0,5182	0,7930	0,7069

## Заключение

В настоящей работе представлено решение задачи семантической сегментации на три класса для мультиспектральных снимков с прибора МСУ-ГС на КА «Электро-Л» № 2 с применением нейросетевых моделей свёрточного типа, обученных на наборах мультиспектральных данных с метеорологических космических аппаратов. Изложен способ получения разметки для целевых данных обработкой разметки с других КА (Meteosat-10, GOES-16, Terra/MODIS), что впервые было применено к мультиспектральным данным МСУ-ГС. С одновременным учётом спектральных, географических и текстурных характеристик облачности и подстилающей поверхности для снимков Земли даже в низком разрешении 4 км удалось добиться приемлемого качества сегментации снега и облачности, сравнимого с результатами других исследований (Bloshchinskiy et al., 2020; Mohajerani, Saeedi, 2019; Wu et al., 2021; Zhang et al., 2020), но для зоны всего диска Земли и с гораздо меньшим временем работы алгоритма. Подтверждена эффективность задействования дополнительной геоинформации для сегментации, что было предложено в работе (Wu et al., 2021). Однако следует отметить, что нейронная сеть может выдавать ошибки сегментации снега во время облачности, накрывающей снежный покров, а также ошибки по краям изображений из-за геометрических искажений и недостаточной освещённости на снимках.

Весь код для сбора и предварительной обработки собранного набора данных с геостационарных спутников, разбиения снимков на патчи, код для обучения и тестирования модели, а также сами веса обученных моделей доступны по ссылке [https://github.com/Nikita-Belyakov/CLOUD\\_SNOW\\_SEGMENTATION](https://github.com/Nikita-Belyakov/CLOUD_SNOW_SEGMENTATION). Все данные с КА «Электро-Л» № 2, используемые в представленной работе, могут быть получены по запросу в Сибирском центре НИЦ «Планета» (<https://rscpod.ru/>).

Исходя из частоты выдачи снимков, предлагаемый метод позволяет обрабатывать снимки с КА «Электро-Л» № 2 в режиме реального времени, тем самым осуществлять динамический анализ облачности и снежного покрова в дневное время суток в любое время года с учётом световой коррекции по углу зенита Солнца.

Исследование выполнено при поддержке Некоммерческого фонда развития науки и образования «Интеллект».

## Литература

1. Астафуров В. Г., Евсюткин Т. В., Курьянович К. В., Скороходов А. В. Статистическая модель текстурных признаков перистой облачности по спутниковым снимкам MODIS // Оптика атмосферы и океана. 2014. Т. 27. № 7. С. 640–646.
2. Ackerman S. A., Frey R. MODIS Atmosphere L2 Cloud Mask Product / NASA MODIS Adaptive Processing System. Goddard Space Flight Center. 2015. DOI: 10.5067/MODIS/MOD35\_L2.061.

3. *Bloshchinskiy V. D., Kuchma M., Andreev A., Sorokin A.* Snow and cloud detection using a convolutional neural network and low-resolution data from the Electro-L No. 2 Satellite // *J. Applied Remote Sensing*. 2020. V. 14. No. 3. Article 034506. DOI: 10.1117/1.JRS.14.034506.
4. *Cao H., Luo X., Peng Y. et al.* MANet: A Network Architecture for Remote Sensing Spatiotemporal Fusion Based on Multiscale and Attention Mechanisms // *Remote Sensing*. 2022. V. 14. No. 18. P. 4600–4600. <https://doi.org/10.3390/rs14184600>.
5. *Fan T., Wang G., Li Y. et al.* MA-Net: A Multi-Scale Attention Network for Liver and Tumor Segmentation // *IEEE Access*. 2020. V. 8. P. 179 656–179 665. DOI: 10.1109/ACCESS.2020.3025372.
6. *Heidinger A., Botambekov D., Walthe A.* Algorithm theoretical basis document. A Naïve Bayesian Cloud Mask Delivered to NOAA Enterprise. 10 July. 2017. 50 p. [https://www.ospo.noaa.gov/Products/Suites/files/atbd/Cloud\\_Mask\\_Enterprise\\_ATBD\\_v1.1\\_2016.pdf](https://www.ospo.noaa.gov/Products/Suites/files/atbd/Cloud_Mask_Enterprise_ATBD_v1.1_2016.pdf).
7. *Khlopenkov K., Trishchenko A.* SPARC: New cloud, snow, and cloud shadow detection scheme for historical 1-km AVHRR data over Canada // *J. Atmospheric and Oceanic Technology*. 2007. V. 24. No. 3. P. 322–343. DOI: 10.1175/JTECH1987.1.
8. *Krizhevsky A., Sutskever I., Hinton G. E.* ImageNet Classification with Deep Convolutional Neural Networks // *arXiv preprint*. arXiv:1404.5997. 2012. <http://arxiv.org/abs/1404.5997>.
9. *Li R., Zheng S., Duan C. et al.* Multiattention Network for Semantic Segmentation of Fine Resolution Remote Sensing Images // *IEEE Trans. Geoscience and Remote Sensing*. 2022. V. 60. Article 5607713. P. 1–13. DOI: 10.1109/TGRS.2021.3093977.
10. *Lin T., Goyal P., Girshick R., He K., Dollar P.* Focal Loss for Dense Object Detection // *arXiv preprint*. arXiv:1708.02002. 2018. <https://arxiv.org/pdf/arXiv:1708.02002>.
11. *Loshchilov I., Hutter F.* SGDR: Stochastic Gradient Descent with Warm Restarts // *arXiv preprint*. arXiv:1608.03983v5. 2017. <https://doi.org/10.48550/arXiv.1608.03983>.
12. *Loshchilov I., Hutter F.* Decoupled weight decay regularization // *arXiv preprint*. arXiv:1711.05101. 2019. <https://arxiv.org/pdf/1711.05101>.
13. *Miller S., Lee T., Fennimore R. L.* Satellite-based imagery techniques for daytime cloud/snow delineation from MODIS // *J. Applied Meteorology*. 2005. V. 44. No. 7. P. 987–997. DOI: 10.1175/JAM2252.1.
14. *Mohajerani S., Saeedi P.* Cloud-Net: An End-To-End Cloud Detection Algorithm for Landsat 8 Imagery // 2019 IEEE Intern. Geoscience and Remote Sensing Symp. (IGARSS 2019). 2019. P. 1029–1032.
15. *Sun S., Cao Z., Zhu H., Zhao J.* A Survey of Optimization Methods From a Machine Learning Perspective // *arXiv preprint*. arXiv:1906.06821. 2019. <https://arxiv.org/pdf/arXiv:1906.06821>.
16. *Tan M., Le Q. V.* EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks (Image Classification) // *arXiv preprint*. arXiv:1905.11946. 2019. <https://doi.org/10.48550/arXiv.1905.11946>.
17. *Wildt M. D. R. D., Seiz G., Gruen A.* Operational snow mapping using multitemporal Meteosat SEVIRI imagery // *Remote Sensing of Environment*. Elsevier Inc., 2007. V. 109. P. 29–41. DOI: 10.1016/j.rse.2006.12.008.
18. *Wortsman M., Ilharco G., Gadre S. Y. et al.* Model soups: averaging weights of multiple fine-tuned models improves accuracy without increasing inference time // *Proc. 39<sup>th</sup> Intern. Conf. Machine Learning*. PMLR. 2022. V. 162. P. 23965–23998. <https://doi.org/10.48550/arXiv.2203.05482>.
19. *Wright L., Demeure N.* Ranger21: a synergistic deep learning optimizer // *arXiv preprint*. arXiv:2106.13731. 2021. <https://doi.org/10.48550/arXiv.2106.13731>.
20. *Wu X., Shi Z., Zou Z.* A geographic information-driven method and a new large scale dataset for remote sensing cloud/snow detection // *ISPRS J. Photogrammetry and Remote Sensing*. 2021. V. 174. No. 11. P. 87–104. DOI: 10.1016/j.isprsjprs.2021.01.023.
21. *Wu Y., Liu L., Bae J. et al.* Demystifying Learning Rate Policies for High Accuracy Training of Deep Neural Networks // *IEEE Intern. Conf. Big Data*. 2019. P. 1971–1980. DOI: 10.1109/BigData47090.2019.9006104.
22. *Yin M., Wang P., Ni C. et al.* Cloud and snow detection of remote sensing images based on improved Unet3+ // *Scientific Reports*. 2022. V. 12. No. 1. DOI: 10.1038/s41598-022-18812-6.
23. *Zhang J., Li X., Li L. et al.* Lightweight U-Net for cloud detection of visible and thermal infrared remote sensing images // *Optical and Quantum Electronics*. 2020. V. 52. No. 9. P. 397–397. DOI: 10.1007/s11082-020-02500-8.

## Cloud and snow neural network segmentation using Electro-L No. 2 satellite multispectral data

N. V. Belyakov<sup>1</sup>, A. V. Vasiliev<sup>1</sup>, S. V. Kolpinskiy<sup>2</sup>

<sup>1</sup> *Lomonosov Moscow State University, Moscow 119991, Russia*  
*E-mail: nikita.belyakov@cosmos.msu.ru*

<sup>2</sup> *National Research University "Moscow Power Engineering Institute"*  
*Moscow 111250, Russia*  
*E-mail: kolpinskysv@mpei.ru*

This paper is devoted to cloud and snow semantic segmentation of multispectral satellite imagery of a multizone scanning geostationary instrument (MSU-GS) installed on the Russian satellite Electro-L No. 2 using a convolutional neural network. To develop the neural network algorithm, a self-collected dataset containing multispectral images from the MSU-GS instrument installed on the Electro-L No. 2 satellite with snow and cloud masks was created. The images from GOES-16 (Geostationary Operational Environmental Satellite) and Meteosat-10 satellites reprojected to the Electro-L No. 2 position were used to create cloud and snow cover masks. Such geographical information as latitude, longitude and altitude for image pixels is used as additional information. Multi-Scale Attention Network (MANet) is used as a neural network model. One of the significant problems in the development of the snow and cloud segmentation algorithm is the absence of short-wave infrared channels (1300–1600 nm), which are necessary for the operation of classical segmentation algorithms based on normalized snow index tests. Given the limitations on the spectral characteristics of the MSU-GS equipment and low resolution of images, a neural network algorithm capable of differentiating snow and clouds by implicit features and patterns is proposed as a solution to the problem of snow and cloud separation on multispectral data. For representativeness, the images in the dataset include all seasons and different light levels (12:00–17:00 UTC). The trained neural network for segmentation was tested in different scenarios, including winter and summer periods of the year in daytime at different illumination levels of the images on the data from the MSU-GS instrument of the Electro-L No. 2 satellite. According to the test results the following segmentation quality metrics were obtained:  $F_{1s} = 0,7454$ ,  $F_{1c} = 0,8773$  and  $IoU_s = 0,7398$ ,  $IoU_c = 0,7976$  (Intersection over Union index) for snow (subscript  $s$ ) and cloud (subscript  $c$ ) classes respectively.

**Keywords:** Electro-L No. 2, remote sensing, convolutional neural network, cloud and snow segmentation, geographical information, altitude map

Accepted: 29.03.2024

DOI: 10.21046/2070-7401-2024-21-2-36-50

## References

1. Astafurov V.G., Evsyutkin T.V., Kuriyanovich K.V., Skorokhodov A.V., Statistical model of cirrus cloud textural features based on MODIS satellite images, *Atmospheric and Oceanic Optics*, 2014, Vol. 27, No. 7, pp. 640–646 (in Russian).
2. Ackerman S.A., Frey R., *MODIS Atmosphere L2 Cloud Mask Product*, NASA MODIS Adaptive Processing System, Goddard Space Flight Center, 2015, DOI: 10.5067/MODIS/MOD35\_L2.061.
3. Bloschinskiy V.D., Kuchma M., Andreev A., Sorokin A., Snow and cloud detection using a convolutional neural network and low-resolution data from the Electro-L No. 2 Satellite, *J. Applied Remote Sensing*, 2020, Vol. 14, No. 3, Article 034506, DOI: 10.1117/1.JRS.14.034506.
4. Cao H., Luo X., Peng Y. et al., MANet: A Network Architecture for Remote Sensing Spatiotemporal Fusion Based on Multiscale and Attention Mechanisms, *Remote Sensing*, 2022, Vol. 14, No. 18, pp. 4600–4600, <https://doi.org/10.3390/rs14184600>.
5. Fan T., Wang G., Li Y. et al., MA-Net: A Multi-Scale Attention Network for Liver and Tumor Segmentation, *IEEE Access*, 2020, Vol. 8, pp. 179656–179665, DOI: 10.1109/ACCESS.2020.3025372.
6. Heidinger A., Botambekov D., Walthe A., *Algorithm theoretical basis document, A Naïve Bayesian Cloud Mask Delivered to NOAA Enterprise*, 10 July, 2017, 50 p., [https://www.ospo.noaa.gov/Products/Suites/files/atbd/Cloud\\_Mask\\_Enterprise\\_ATBD\\_v1.1\\_2016.pdf](https://www.ospo.noaa.gov/Products/Suites/files/atbd/Cloud_Mask_Enterprise_ATBD_v1.1_2016.pdf).



7. Khlopenkov K., Trishchenko A., SPARC: New cloud, snow, and cloud shadow detection scheme for historical 1-km AVHRR data over Canada, *J. Atmospheric and Oceanic Technology*, 2007, Vol. 24, No. 3, pp. 322–343, DOI: 10.1175/JTECH1987.1.
8. Krizhevsky A., Sutskever I., Hinton G. E., ImageNet Classification with Deep Convolutional Neural Networks, *arXiv preprint, arXiv:1404.5997*, 2012, <http://arxiv.org/abs/1404.5997>.
9. Li R., Zheng S., Duan C. et al., Multiattention Network for Semantic Segmentation of Fine Resolution Remote Sensing Images, *IEEE Trans. Geoscience and Remote Sensing*, 2022, Vol. 60, Article 5607713, pp. 1–13, DOI: 10.1109/TGRS.2021.3093977.
10. Lin T., Goyal P., Girshick R., He K., Dollar P., Focal Loss for Dense Object Detection, *arXiv preprint, arXiv:1708.02002*, 2018, <https://arxiv.org/pdf/arXiv.1708.02002>.
11. Loshchilov I., Hutter F., SGDR: Stochastic Gradient Descent with Warm Restarts, *arXiv preprint, arXiv:1608.03983v5*, 2017, <https://doi.org/10.48550/arXiv.1608.03983>.
12. Loshchilov I., Hutter F., Decoupled weight decay regularization, *arXiv preprint, arXiv:1711.05101*, 2019, <https://arxiv.org/pdf/1711.05101>.
13. Miller S., Lee T., Fennimore R. L., Satellite-based imagery techniques for daytime cloud/snow delineation from MODIS, *J. Applied Meteorology*, 2005, Vol. 44, No. 7, pp. 987–997, DOI: 10.1175/JAM2252.1.
14. Mohajerani S., Saeedi P., Cloud-Net: An End-To-End Cloud Detection Algorithm for Landsat 8 Imagery, *2019 IEEE Intern. Geoscience and Remote Sensing Symp. (IGARSS 2019)*, 2019, pp. 1029–1032.
15. Sun S., Cao Z., Zhu H., Zhao J., A Survey of Optimization Methods From a Machine Learning Perspective, *arXiv preprint, arXiv:1906.06821*, 2019, <https://arxiv.org/pdf/arXiv.1906.06821>.
16. Tan M., Le Q. V., EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks (Image Classification), *arXiv preprint, arXiv:1905.11946*, 2019, <https://doi.org/10.48550/arXiv.1905.11946>.
17. Wildt M. D. R. D., Seiz G., Gruen A., Operational snow mapping using multitemporal Meteosat SEVIRI imagery, *Remote Sensing of Environment*, Elsevier Inc., 2007, Vol. 109, pp. 29–41, DOI: 10.1016/j.rse.2006.12.008.
18. Wortsman M., Ilharco G., Gadre S. Y. et al., Model soups: averaging weights of multiple fine-tuned models improves accuracy without increasing inference time, *Proc. 39<sup>th</sup> Intern. Conf. Machine Learning. PMLR*, 2022, Vol. 162, pp. 23965–23998, <https://doi.org/10.48550/arXiv.2203.05482>.
19. Wright L., Demeure N., Ranger21: a synergistic deep learning optimizer, *arXiv preprint, arXiv:2106.13731*, 2021, <https://doi.org/10.48550/arXiv.2106.13731>.
20. Wu X., Shi Z., Zou Z., A geographic information-driven method and a new large scale dataset for remote sensing cloud/snow detection, *ISPRS J. Photogrammetry and Remote Sensing*, 2021, Vol. 174, No. 11, pp. 87–104, DOI: 10.1016/j.isprsjprs.2021.01.023.
21. Wu Y., Liu L., Bae J. et al., Demystifying Learning Rate Policies for High Accuracy Training of Deep Neural Networks, *IEEE Intern. Conf. Big Data*, 2019, pp. 1971–1980, DOI: 10.1109/BigData47090.2019.9006104.
22. Yin M., Wang P., Ni C. et al., Cloud and snow detection of remote sensing images based on improved Unet3+, *Scientific Reports*, 2022, Vol. 12, No. 1, DOI: 10.1038/s41598-022-18812-6.
23. Zhang J., Li X., Li L. et al., Lightweight U-Net for cloud detection of visible and thermal infrared remote sensing images, *Optical and Quantum Electronics*, 2020, Vol. 52, No. 9, pp. 397–397, DOI: 10.1007/s11082-020-02500-8.