

Исследование методов реконструкции оптических спутниковых изображений с использованием изображений радара с синтезированной апертурой¹

В. Ф. Коновалов

Самарский национальный исследовательский университет имени академика С. П. Королева

Поступила в редколлегию 7.10.2025 г. Принята 25.11.2025 г.

Аннотация—В данной работе исследуется возможность и эффективность использования информации из изображений радара с синтезированной апертурой для восстановления оптических спутниковых изображений. Рассмотрены существующие методы реконструкции изображений и предложен улучшенный метод, использующий диффузионную нейронную сеть. Предложенный метод делит поставленную задачу на обнаружение облачности с последующим ее устранением. Фокус метода смещен на последнее, используя синтетические маски для получения покрытых облачностью изображений из безоблачных изображений. Был предложен новый входной блок, улучшающий кодирование обуславливающей информации. Предложенный метод улучшает численные показатели базового метода на 2-3 PSNR.

КЛЮЧЕВЫЕ СЛОВА: реконструкция изображений, спутниковые снимки, изображения радара с синтезированной апертурой, устранение облачности, дорисовка изображений, нейронные сети, диффузия.

DOI: 10.53921/18195822_2025_25_3.1_626

1. ВВЕДЕНИЕ

Согласно исследованиям [1,24], облака покрывают около 70% поверхности Земли в любой момент времени. Поэтому невозможно избежать проблемы облачного покрова, закрывающего части оптических спутниковых изображений, что приводит к потере информации. Другие типы спутниковых данных, такие как мультиспектральные, радиолокационные (SAR) и гиперспектральные изображения, могут частично компенсировать эту проблему [18-23]. Гиперспектральные изображения позволяют "заглянуть" сквозь облака, однако такие наборы данных встречаются редко и обладают низким разрешением. С другой стороны, мультиспектральные и SAR-изображения значительно более распространены благодаря данным, полученным с аппаратов Sentinel-1 и Sentinel-2. SAR-данные способны легко проникать даже сквозь плотную облачность и достигать поверхности, однако они отличаются высоким уровнем шума, сложны для интерпретации и обладают меньшим разрешением по сравнению с другими методами. Тем не менее, многие спутники используют когистрацию изображений различных типов, и с помощью нейронных сетей можно попытаться восстановить области оптического изображения, закрытые облаками, используя SAR-данные в качестве ориентира.

Облачный покров над поверхностью Земли неравномерен — плотность облаков может варьироваться от полупрозрачной до полностью непрозрачной. Кроме того, удаление облаков

¹ This work was supported by the Ministry of Science and Higher Education, Russia (Agreement No.075-15-2024-558).

также требует реконструкции их теней. В данной работе не проводится разделение типов облачности, так как предложенный метод ориентирован в первую очередь на удаление плотных облаков. В работе применяется декомпозиция задачи на два этапа: обнаружение облаков и их удаление, при этом основной акцент сделан на решении второй задачи. Такое разделение расширяет набор применимых датасетов и методов, делая задачу менее узкоспециализированной. Нейронной сети больше не приходится отвлекаться на побочные факторы, неизбежно возникающие при работе с реальными данными. Структура работы следующая. Сначала рассматриваются существующие методы и их классификация (раздел II). Затем подробно описывается экспериментальная установка (раздел III), включая все улучшения и модификации в процессе обучения, функции потерь и архитектуру. Раздел IV посвящен метрикам тестирования, процедуре проведения тестов и интерпретации полученных результатов.

2. ОБЗОР ЛИТЕРАТУРЫ

Эта тема была предметом многочисленных исследований. Подробный обзор методов восстановления, особенно с использованием данных SAR, представлен в [2]. Задача восстановления, рассматриваемая в данной работе, тесно связана с классической проблемой реконструкции изображений, обзор которой приведён в [3].

2.1. Ранние методы

Ранние методы заключались в разделении облачных и обычных пикселей с помощью определённого алгоритма, после чего для восстановления областей с облаками использовалась информация от соседних пикселей. Другой классический подход — это мозаичное восстановление, при котором результат формируется из последовательности выровненных облачных изображений. При этом используются безоблачные участки и информация от соседних пикселей для реконструкции утраченных данных. Стоит отметить, что в ранних методах задача часто разбивалась на две отдельные части, однако с ростом популярности нейронных сетей такой подход стал использоваться всё реже. Существуют также методы, использующие несколько выровненных изображений одной и той же области, формируя мозаику из безоблачных участков. Однако эффективность таких методов снижается, если изображения были получены с большим временным интервалом. Сверточные нейронные сети позволили эффективно извлекать признаки, что дало возможность расширить и улучшить мозаичные методы, комбинируя признаки с помощью архитектур типа encoder-decoder или U-Net [10].

2.2. GAN

GAN могут улучшать традиционные мозаичные методы, генерируя недостающую информацию в тех случаях, когда ни одно изображение из серии не содержит нужных данных. Они также помогают уменьшить снижение эффективности при значительном временном разрыве между изображениями. Генеративные сети, как и сверточные, могут использовать дополнительную условную информацию для улучшения генерации, такую как SAR-изображения. Например, в [4] несколько изображений объединяются с помощью GAN для безусловного удаления облаков, а в [6] используется дополнительная условная информация в виде SAR-данных.

2.3. Диффузионные сети

Диффузионные сети — это разновидность генеративных сетей, которая в последнее время привлекает всё больше внимания. Они особенно хорошо подходят для задач восстановления и подавления шума. Диффузионные сети были применены к задаче удаления облаков в [7], где

используется серия временно различных, но геометрически выровненных изображений, подаваемых в отдельный энкодер в качестве условия для генерации результата. В [8] используется одно изображение и SAR-навигация, закодированная через отдельный энкодер.

3. ПРЕДЛАГАЕМЫЙ МЕТОД

3.1. Набор данных

Для обучения и тестирования использовался датасет SEN12MSCR [9]. Он содержит более 122 000 триплетов вида «облачное изображение» — «чистое изображение» — «SAR-изображение». Облачные и чистые изображения являются мультиспектральными, однако в данной работе использовались только каналы RGB. SAR-изображения состоят из каналов с VV- и VH-поляризацией. Изображения являются заранее попиксельно выровненными между собой, что немаловажно, так как даже коригестрированные изображения могут быть неидеально выровненными [10]. В процессе обучения и тестирования использовались только изображения без облаков и SAR-изображения, поскольку для получения облачных изображений применялась аугментация. Синтетические облачные изображения создавались путём закрытия случайных областей изображения квадратными патчами размером не более 25 % от площади изображения. В некоторых экспериментах дополнительно использовалась аугментация в виде произвольных масок, сгенерированных с помощью алгоритма из работы [11]. Рисунок 1 показывает пример аугментированных изображений.



Рис. 1. Пример изображений с прямоугольными масками и масками свободной формы.

Синтетическое маскирование изображений упрощает обучение нейронной сети, поскольку в этом случае сеть сосредоточена исключительно на восстановлении изображения, а не на необходимости учитывать различия в других областях, как это происходит с реальными облачными изображениями. Таким образом, при использовании синтетических данных задача была разделена на две подзадачи: обнаружение облаков и их удаление. В данной работе мы фокусируемся на второй задаче, предполагая, что обнаружение облаков уже выполнено — либо в виде ограничивающего прямоугольника, либо в виде сегментационной маски.

3.2. Архитектура модели

В качестве модели была выбрана диффузионная модель с отдельным условным энкодером. Диффузионные модели чаще всего используют архитектуру типа U-Net [12] с энкодером-декодером. Принцип работы диффузионной модели основан на прямом и обратном процессе выборки. Прямой процесс постепенно преобразует изображение в гауссов шум, в то время как обратный процесс восстанавливает изображение из полученного шума, приводя его к выборке из распределения обучающего датасета. Обратный процесс моделируется с помощью U-Net. В алгоритме удаления облаков DiffCR [7], основанном на диффузионной модели, используется метод выборки с предсказанием данных (data prediction sampling), при котором изображение t_0 восстанавливается из произвольного шага t_t . Согласно авторам [7], данный метод обеспечил наилучшие результаты и поэтому был выбран в качестве метода генерации в предлагаемом подходе. Для введения условной информации — пары «оптическое изображение с синтетической маской – SAR-изображение» — используется отдельный энкодер. Структура этого энкодера показана на Рисунке 3 и аналогична структуре энкодера, используемого в DiffCR [7]. Энкодер состоит из тех же типов блоков, что и U-Net диффузионной модели, однако блоки энкодера не получают дополнительной информации о текущем шаге диффузионного процесса. В DiffCR условный энкодер вводит условную информацию на каждом уровне энкодера U-Net диффузионной сети, работая параллельно с ним. В ходе экспериментов была внесена модификация в структуру энкодера — первый блок, отвечающий за начальную трансформацию данных, был заменён на комбинированный блок CBAM_mod, структура которого показана на Рисунке 2. Этот блок включает как канальное, так и пространственное внимание.




Рис. 2. Структура модифицированного блока пространственно-канального внимания.

Канальное внимание формирует вектор размером C , где C — число каналов, причём каждое значение вектора отражает важность соответствующего канала среди всех каналов признаков. Пространственное внимание формирует тепловую карту размером $N \times M$, где N и M — высота и ширина изображения соответственно; карта показывает важность каждого пикселя по всем каналам. Комбинация пространственного и канального внимания образует структуру, способную выделять наиболее значимые области на картах признаков. Структура модифицированного блока аналогична блоку CBAM, предложенному в [13]. Пространственное внимание сначала рассчитывается отдельно для SAR-изображений и для оптических изображений. Полученные признаки затем проходят сверточный слой, конкатенируются и используются для вычисления канального и пространственного внимания аналогично CBAM. Такой подход позволяет выявлять ключевые области в SAR- и оптических изображениях по отдельности; затем объединённые признаки обрабатываются CBAM-блоком. Этот блок служит своеобразным

«мостом» между различными типами изображений. В качестве базовой архитектуры диффузионной модели использовалась U-Net, структура которого соответствует описаниям в [14, 7]. В первой версии модели использовались блоки NAF, предложенные в [15], как более эффективное сочетание различных компонентов из архитектур восстановления изображений и удаления шума. Эти блоки включают модифицированный механизм канального внимания. Общая структура показана на Рисунке 3.




Рис. 3. Общая схема нейросети DiffCR с модификациями. Пунктиром отмечены блоки используемые только в некоторых модификациях.

Сети обучались с различными комбинациями параметров и вариантов условных входов. В некоторых версиях в качестве дополнительного входа использовалась синтетическая маска облаков. В других версиях блок CBAM_mod заменялся блоком NAF, аналогичным остальным блокам энкодера. Эти эксперименты проводились для оценки влияния внесённых модификаций.

3.3. Функции потерь и параметры обучения

В работе использовались различные комбинации функций потерь, включая MSE, SSIM и перцептивную функцию потерь, основанную на нейронной сети VGG-19. В качестве основной функции потерь использовалась MAE, которая напрямую вычисляет абсолютную разницу между двумя изображениями:

$$\text{MAE} = \frac{\sum_{i=1}^N |I_i - \hat{I}_i|}{N \cdot (\max(I_{\max}, \hat{I}_{\max}) - \min(I_{\min}, \hat{I}_{\min}))} \quad (1)$$

где $\hat{I}$ — восстановленное изображение, I — эталонное (ground truth) изображение, N — количество пикселей в изображении. После первоначальных экспериментов в модель была добавлена функция потерь SSIM с целью уменьшить размытие на результирующих изображениях. Данная функция потерь фокусируется на сохранении правильной структуры и границ в выходных изображениях:

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (2)$$

где μ — средние значения изображений x и y , σ — дисперсия и ковариация изображений x и y , $C_1=0,01 \times L$, $C_2=0,01 \times L$, L — динамический диапазон изображения. SSIM принимает значения от -1 до 1 и является метрикой, которая увеличивается с ростом качества изображения. Поэтому, чтобы использовать её в качестве функции потерь, она была модифицирована следующим образом:

$$\text{SSIM_loss} = 1 - \text{SSIM}(x, y) \quad (3)$$

Перцептивные функции потерь представляют собой группу адаптивных функций, которые направлены на восстановление реалистичного изображения, а не на точное послойное сравнение с эталоном. В данной работе они применяются для генерации реалистичного контента в тех случаях, когда SAR-изображение содержит недостаточно информации, а также для сглаживания переходов между восстановленными и исходными (не требующими восстановления) участками изображения:

$$\text{PERC} = \sum_{l \in \{3, 8, 15, 20\}} \text{MAE}(\text{VGG16}_l(I) - \text{VGG16}_l(\hat{I})) \quad (4)$$

где 3, 8, 15 и 20 — номера слоёв сети VGG, по которым производится суммирование. Глубокие слои сети способствуют восстановлению реалистичного контента изображения, тогда как более мелкие слои действуют аналогично классической функции MAE. Функции потерь комбинировались для получения итогового значения. В ходе экспериментов применялись весовые коэффициенты для балансировки влияния каждой из функций. В процессе обучения использовались следующие три варианта комбинаций функций потерь:

$$\text{Loss} = \text{MAE} + \text{SSIM_loss} + \alpha \text{PERC} \quad (5)$$

$$\text{Loss} = \text{MAE} + \text{SSIM_loss} \quad (6)$$

$$\text{Loss} = \text{MAE} \quad (7)$$

Обучение проводилось максимум в течение 100 эпох или до достижения сходимости, чтобы избежать переобучения. Всего было обучено 5 различных моделей, каждая из которых отличалась набором применённых модификаций:

- DiffCR — оригинальная модель DiffCR с функцией потерь (7).
- DiffCR + SSIM — модель DiffCR с функцией потерь (6).

- DiffCR + SSIM + CBAM mod — модель DiffCR с функцией потерь (6) и модифицированным входным блоком энкодера.
- DiffCR + SSIM + CBAM mod + freeform — модель DiffCR с функцией потерь (6), модифицированным входным блоком энкодера и датасетом с синтетическими масками произвольной формы (freeform).
- DiffCR + CBAM mod + freeform + VGG — модель DiffCR с функцией потерь (7), модифицированным входным блоком энкодера и датасетом с синтетическими масками произвольной формы.

4. ЭКСПЕРИМЕНТАЛЬНАЯ ЧАСТЬ

Для оценки эффективности моделей тестовый датасет был дополнен прямоугольными и произвольными (freeform) масками. Однако для обеспечения справедливого сравнения производительности моделей синтетические маски в форме прямоугольников и произвольных фигур были предварительно сгенерированы с использованием тех же параметров, которые применялись на этапе обучения, как описано в Разделе 3. Эксперименты проводились отдельно для всех пяти вариантов моделей и для трёх конфигураций масок:

- только прямоугольные маски
- только маски произвольной формы
- комбинация масок (50 % прямоугольные и 50% произвольной формы)

Для оценки качества работы моделей использовались следующие метрики: PSNR (8), SSIM (2) и MAE (1).

$$\text{PSNR} = 10 \cdot \log_{10} \left(\frac{\max(I_{\max}, \hat{I}_{\max}) - \min(I_{\min}, \hat{I}_{\min})}{\sqrt{\frac{1}{N} \sum_{i=1}^N (I_i - \hat{I}_i)^2}} \right) \quad (8)$$

Эта формула для PSNR динамически рассчитывает необходимый диапазон значений на основе максимального диапазона входных изображений. Поскольку значения в датасете смещены ближе к нулю, такой подход позволяет более точно скорректировать результат. Несмотря на широкое распространение, PSNR часто даёт искажённую оценку, поскольку склонен отдавать предпочтение размытым изображениям в ущерб тем, что лучше сохраняют структурную точность [16]. Согласно количественным результатам, приведенным в таблице 1, все модели демонстрируют достаточно высокий уровень качества. Оценка производилась по всей области изображения, так как важно учитывать не только качество восстановления замаскированных областей, но и переходы между восстановленными и нетронутыми частями изображения, которые должны быть максимально плавными. Это преимущественно отражается в метрике SSIM. Как и ожидалось, включение freeform-масок снижает количественные показатели моделей, поскольку требует от них адаптации к более сложным шаблонам маскирования. Качественные результаты приведены на Рисунке 4.

Как по этим примерам, так и по количественным данным можно увидеть, что модель с использованием VGG loss (эксперимент 5), хотя и демонстрирует более низкие числовые показатели по сравнению с другими моделями, позволяет получать более реалистичные реконструкции областей, покрытых облаками. Эксперимент 1 представляет собой базовую модель без модификаций. Несмотря на то, что она показывает сопоставимые метрики, качество восстановления у неё заметно ниже — результат часто размытый, с видимыми артефактами. Добавление функций потерь SSIM, VGG и предложенного блока CBAM mod значительно улучшает качество восстановления.




Рис. 4. Качественные результаты экспериментов. а-с) истинные изображения, d-f) результаты эксперимента 4, g-i) результаты эксперимента 2, j-l) SAR изображения




Рис. 4. Качественные результаты экспериментов. а-с) истинные изображения, d-f) результаты эксперимента 4, g-i) результаты эксперимента 2, j-l) SAR изображения

Таблица 1. Результаты экспериментов для разных типов масок

Experiment	Прямоугольные маски			Маски свободной формы			Прямоугольные маски и маски свободной формы		
	PSNR	MAE	SSIM	PSNR	MAE	SSIM	PSNR	MAE	SSIM
1) DiffCR	35.37	0.0108	0.8970	35.73	0.0082	0.9278	34.51	0.0090	0.9117
2) DiffCR + SSIM	37.86	0.0059	0.9670	38.94	0.0043	0.9717	38.18	0.0043	0.9663
3) DiffCR + SSIM + CBAM_mod	37.41	0.0050	0.9710	39.45	0.0033	0.9852	38.92	0.0038	0.9804
4) DiffCR + SSIM + CBAM_mod + freeform	35.02	0.0065	0.9607	37.96	0.0043	0.9786	36.29	0.0054	0.9731
5) DiffCR + SSIM + VGG(alpha=1) + mask + CBAM_mod + freeform	35.24	0.0073	0.9571	37.38	0.0056	0.9690	36.21	0.0064	0.9636

5. ЗАКЛЮЧЕНИЕ

В результате исследования был получен метод устранения облачности с использованием разнородных изображений дистанционного зондирования Земли, улучшающий численные показатели базового метода на 2-3 PSNR, а так же показывающий более реалистичные качественные результаты. Отличительной особенностью предлагаемого метода является разделение задачи устранения облачности на две подзадачи, призванное, во первых, расширить диапазон применимых для задачи архитектур, так как задача сводится к двум широко исследованным задачам - реконструкции фрагментов изображения, и сегментация изображения. Полученный метод использует в качестве каркаса архитектуру DiffCR. Предлагаемая модификация в виде блока CBAM_mod показала свою эффективность по результатам проведенного экспериментального исследования. Использование синтетических данных позволяет легко получать обучающие данные для переобучения или дообучения данного метода. Дальнейшим направлением исследования может стать, например, исследование эффективности предлагаемого блока CBAM_mod в других архитектурах реконструкции изображений. Кроме этого, перспективным направлением может стать обучение данной модели на восстановление облачности при использовании "мягких" масок облачности, учитывающих полупрозрачность неплотных облаков.

СПИСОК ЛИТЕРАТУРЫ

1. King M., Platnick S., Menzel W., Ackerman S., Hubanks P. Spatial and temporal distribution of clouds observed by modis onboard the terra and aqua satellites // IEEE Transactions on Geoscience and Remote Sensing. 2013. vol. 51, no. 7, p. 3826–3852.

2. Xiong Q., G. Yao X., Zhang X. SAR-to-Optical Image Translation and Cloud Removal Based on Conditional Generative Adversarial Networks: Literature Survey, Taxonomy, Evaluation Indicators, Limits and Future Directions. *Remote Sens.* 2023. 15. 1137.
3. Hanyu X, Zou Q., Nawaz M, Xianfeng H., Fan Z., Hongkai Y. Deep learning for image inpainting: A survey // *Pattern Recognition*. 2023. Volume 134.
4. Sarukkai, V., Jain A., Uzcent B., Ermon S. Cloud Removal in Satellite Images Using Spatiotemporal Generative Networks // *WACV 2020*. 2020. Pp 1796-1805.
5. Ebel P., Garnot V., Schmitt M., Wegner J., Zhu X. UnCRtainTS: Uncertainty Quantification for Cloud Removal in Optical Satellite Time Series // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops – 2023*.
6. Bermudez J., Happ P., Oliveira D., Feitosa R. SAR to optical image synthesis for cloud removal with generative adversarial networks // *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.* 2018. IV-1. Pp 5–11.
7. Zou X., Li K. DiffCR: A Fast Conditional Diffusion Framework for Cloud Removal From Optical Satellite Images // *IEEE Transactions on Geoscience and Remote Sensing*. 2024. Vol. 62. P. 1-14.
8. Jing R., Duan F., Lu F., Zhang M., Zhao W. Denoising diffusion probabilistic feature-based network for cloud removal in sentinel-2 imagery // *REMOTE SENS-BASEL*. 2023. vol. 15. № 9. p. 2217-2242
9. Volkov VV, Shvets EA. Neural network algorithm for optical-SAR image registration based on a uniform grid of points. *Computer Optics* 2024; 48(4): 610-618. DOI: 10.18287/2412-6179-CO-1426.
10. Ebel P., Meraner A., Schmitt M., and Zhu X. Multisensor Data Fusion for Cloud Removal in Global and All-Season Sentinel-2 Imagery // *IEEE Transactions on Geoscience and Remote Sensing*. 2020. vol. 59. №7. p. 5866-5878
11. Yu, J., Lin, Z., Yang, J., Shen, X., Lu, X. Huang, T. Free-Form Image Inpainting With Gated Convolution // *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, 2018, Pp. 4470-4479.
12. Ronneberger, O., Fischer, P., Brox, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. // *MICCAI 2015. Lecture Notes in Computer Science()*. 2015. vol 9351.
13. Sanghyun W., Jongchan P., Joon-Young L., In So K. CBAM: Convolutional Block Attention Module. // *Computer Vision – ECCV 2018: 15th European Conference, Munich, Germany, September 8–14, 2018, Proceedings, Part VII*. Springer-Verlag, Berlin, Heidelberg. 2018. 3–19.
14. Chitwan S., William C., Huiwen C., Chris L., Jonathan H., Tim S., David F., Norouzi. M. Palette: Image-to-Image Diffusion Models // *In ACM SIGGRAPH 2022 Conference Proceedings (SIGGRAPH '22)*. Association for Computing Machinery. 2022. Article 15, 1–10.
15. Chen L., Chu X., Zhang X., Sun J. Simple Baselines for Image Restoration // *Computer Vision – ECCV 2022: 17th European Conference*. 2022. P. 17-33.
16. Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E.P. Image Quality Assessment: From Error Visibility to Structural Similarity // *IEEE Trans. on Image Process*. 2004. Vol. 13, №4. P. 600–612.
17. Osipov AV, Pleshakova ES, Gataullin ST. Production processes optimization through machine learning methods based on geophysical monitoring data. *Computer Optics* 2024; 48(4): 633-642. DOI: 10.18287/2412-6179-CO-1373.
18. Pavlov VA, Belov AA, Volvenko SV, Rashich AV. Application of convolutional neural networks trained on optical images for object detection in radar images. *Computer Optics* 2024; 48(2): 253-259. DOI: 10.18287/2412-6179-CO-1316.
19. Zherdev D.A., Kazanskiy N.L., Fursov V.A. Object recognition by the radar signatures of electromagnetic field scattering on base of support subspaces method // *Computer Optics*, 2014, Vol. 38, № 3, pp. 503-510.
20. Zherdev D.A., Kazanskiy N.L., Fursov V.A. Object recognition in radar images using conjugation indices and support subspaces // *Computer Optics*, 2015, Vol. 39, № 2, pp. 255-264.

21. Fursov Vladimir, Zherdev Denis, and Kazanskiy Nikolay. Support subspaces method for synthetic aperture radar automatic target recognition // International Journal of Advanced Robotic Systems, 2016, Vol. 13, Iss. 5, 1729881416664848, pp. 1-11. DOI: 10.1177/1729881416664848.
22. Fursov V., Minaev E., Zherdev D., Kazanskiy N. Support subspaces method for recognition of the synthetic aperture radar images using fractal compression // International Journal of Advanced Robotic Systems, 2017, Vol. 14, Iss. 5, pp. 1-8. DOI: 10.1177/1729881417733952.
23. Nikolay L. Kazanskiy, Vladimir A. Fursov, Evgeny Minaev, and Denis Zherdev "Radar image modeling and recognition Proc. SPIE 11516, Optical Technologies for Telecommunications 2019, 115161J (22 May 2020); <https://doi.org/10.1117/12.2566467>.
24. Мультиспектральный интеллектуальный мониторинг природной и техногенной среды / С.А. Барталев, Е.В. Бурнаев, В.С. Верба, Н.А. Ивлиев, Н.Л. Казанский, А.Ф. Каперко, Е.А. Лупян, А.В. Никоноров, Р.В. Скиданов, А.А. Черниенко - под ред. академика РАН В.Я. Панченко, 2023, Самара: Новая техника, 184 с. - ISBN 978-5-88940-164-3.

Exploring methods of optical satellite images reconstruction using SAR images

V. F. Konovalov

In this work we explore the possibility and effectiveness of reconstructing cloudy optical satellite images using information borrowed from SAR images. Existing methods are reviewed and an improved method, utilizing diffusion neural network is suggested. Suggested method is based on DiffCR. The method splits the task into cloud detection and cloud removal and focuses on the latter, employing synthetic mask augmentation to generate cloudy images from ground truth. A new intro block is suggested to improve conditional information encoding. A qualitative and quantitative efficiency of suggested improvements is evaluated using several metrics.

KEYWORDS: image reconstruction, satellite imagery, SAR, cloud removal, inpainting , neural networks, diffusion.