



**Silesian University
of Technology**

WYDZIAŁ AUTOMATYKI, ELEKTRONIKI I INFORMATYKI

STRESZCZENIE ROZPRAWY DOKTORSKIEJ

**Wieloobrazowa rekonstrukcja
nadrozdzielcza z wykorzystaniem
głębokich grafowych sieci
neuronowych**

mgr inż. Tomasz Tarasiewicz

Promotor: **dr hab. inż. Michał Kawulok, prof. PŚ**
Wrzesień, 2023

Rozdział 1: Wprowadzenie

W początkowej części rozprawy zdefiniowano pojęcie rozdzielczości obrazu [9] oraz przedstawiono jego znaczenie w różnorodnych dziedzinach, takich jak medycyna [5], teledetekcja [10] czy fotografia cyfrowa [3]. Akwizycja obrazów o wysokiej rozdzielczości bywa jednak często utrudniona z powodu ograniczeń fizycznych i cyfrowych [8, 11, 19]. Jednym z sposobów na obejście tych ograniczeń są metody rekonstrukcji nadrozdzielczej (ang. *super-resolution reconstruction*, SRR), które mają na celu zwiększenie rozdzielczości przestrzennej obrazów o niskiej rozdzielczości.

W niniejszym rozdziale przedstawiono różnice między rekonstrukcją nadrozdzielczą opartą na pojedynczym obrazie (ang. *single-image super-resolution*, SISR) a wieloobrazową (ang. *multi-image super-resolution*, MISR). Metody SISR koncentrują się na zwiększeniu rozdzielczości opierając się na jednym obrazie [7], podczas gdy metody MISR wykorzystują wiele obserwacji tej samej sceny w celu stworzenia bardziej szczegółowego obrazu o wyższej rozdzielczości [16]. Dodatkowo w rozprawie opisane zostają dwa główne etapy MISR: rejestracja obrazów i fuzja informacji, wraz z wyzwaniem im towarzyszącymi, takimi jak różnice czasowe, okluzje oraz zmienne warunki oświetlenia [12].

W tej części omówione są ograniczenia tradycyjnych sieci neuronowych konwolucyjnych (ang. *convolutional neural networks*, CNN) [14] w kontekście MISR, skupiając się na problemach takich jak trudności w radzeniu sobie z różnicami czasowymi między obrazami wejściowymi oraz ograniczone możliwości przekazywania informacji wejściowej, co wiąże się z wymogiem przedstawienia danych wyłącznie w formie macierzy. Ta dyskusja stanowi punkt wyjścia do przedstawienia motywacji za zastosowaniem grafowych sieci neuronowych (ang. *graph neural networks*, GNN)[13], które oferują alternatywne podejście do wyzwań napotykanych w modelach CNN w kontekście MISR. Następne rozdziały tej dysertacji skoncentrują się na zbadaniu potencjału sieci grafowych w zastosowaniach MISR, dążąc do dostarczenia zarówno dogłębnej analizy teoretycznej, jak i empirycznej walidacji poprzez eksperymenty, mające na celu weryfikację postawionych tez:

- **Teza 1:** Przy użyciu grafowej reprezentacji zbioru obrazów z subpikselowymi przesunięciami, możliwe jest przeprowadzenie rekonstrukcji nadrozdzielczej za pośrednictwem odpowiednio zaprojektowanej grafowej sieci neuronowej. Pozwala to na uzyskanie obrazu o wysokiej rozdzielczości, którego jakość jest porównywalna lub nawet wyższa

niż w przypadku czołowych architektur wieloobrazowej rekonstrukcji nadrozdzielczej bazujących na sieciach konwolucyjnych.

- **Teza 2:** Wybrane rozwiązania architektoniczne zastosowane w wiodących architekturach konwolucyjnych do wieloobrazowej rekonstrukcji nadrozdzielczej mogą znaleźć zastosowanie w modelach grafowych, efektywnie podnosząc jakość ich rekonstrukcji. Techniki te obejmują: indywidualne wydobywanie cech dla każdego obrazu wejściowego, wykorzystanie mechanizmów uwagi, czy też użycie dynamicznych i możliwych do wytrenowania algorytmów rejestracji obrazów.
- **Teza 3:** Wykorzystanie grafowych sieci neuronowych umożliwia rekonstrukcję stanu sceny w wyznaczonym punkcie czasowym, kierując się momentem akwizycji jednego z obrazów wejściowych. W takim ujęciu, jeden obraz z puli dostępnych obrazów wejściowych jest uznany jako wiodący, podczas gdy reszta obrazów służy jako uzupełniające źródła informacji, zwiększając tym samym dokładność rekonstrukcji. Prezentowane podejście skutecznie redukuje niespójności wizualne w obszarach o wysokiej zmienności czasowej, gwarantując uzyskanie obrazu o wyższej rozdzielczości, który jest spójny czasowo.

Rozdział 2: Przegląd literatury

W ostatnich latach zaznaczył się znaczny rozwój w obszarze SRR, podyktowany rosnącym zapotrzebowaniem na obrazy wysokiej rozdzielczości w wielu sektorach. W tym okresie przedstawiono liczne metody mające na celu sprostanie wyzwaniom, które niesie za sobą rekonstrukcja nadrozdzielcza [1, 4, 6, 15, 18, 20, 21]. W świecie uczenia maszynowego, sieci neuronowe stały się kluczowym narzędziem rozwoju wielu obszarów, takich jak rozpoznawanie gestów i mowy czy przetwarzanie języka naturalnego [2, 22]. Metody, które istotnie przyczyniły się do rozwoju SRR, zostały zarysowane i omówione w tym rozdziale, obejmując zarówno rekonstrukcję nadrozdzielczą jednoką i wieloobrazową. Ponadto, poruszono temat ściśle powiązany z SISR, jakim jest rekonstrukcja nadrozdzielcza obrazów wielospektralnych.

W tym rozdziale przedstawiono również grafowe sieci neuronowe, przedstawiając ich zalety w kontekście wyzwań związanych z MISR. Omówione zostały ograniczenia typowe dla tradycyjnych sieci konwolucyjnych, takie


jak problemy z przetwarzaniem danych o nieregularnej strukturze oraz tendencja do pomijania informacji o relacjach w danych wejściowych [17]. Dyskusja ta rysuje obraz, jak grafowe sieci neuronowe mogą efektywnie zaradzić tym problemom.

Niniejszy rozdział stanowi kompleksowy przegląd literatury na temat technik rekonstrukcji nadrozdzielczej, ze szczególnym uwzględnieniem podejść opartych na uczeniu głębokim. Przedstawiono w nim istniejące luki badawcze i wyzwania związane z obecnymi technikami MISR, kładąc tym samym fundament pod zaproponowaną metodę wykorzystującą głębokie sieci grafowe, opisaną w następnym rozdziale.


Rozdział 3: Opis zaproponowanych architektur

W początkowych częściach tego rozdziału omówiono proces tworzenia grafu z wielu obrazów przedstawionych w formie macierzy 3D. Zaprezentowane podejście zapewnia bezstratną konwersję, zachowując wszystkie informacje macierzy wejściowej. Co więcej, przekształcenie to jest nie tylko bezstratne, ale także zwiększa ilość przechowywanej informacji, określając relacje przestrzenne między każdą połączoną parą węzłów. Ten proces, przedstawiony na Rysunku 1, można podzielić na trzy główne etapy:


1. **Pozycjonowanie węzłów:** Krok ten opisuje proces przeniesienia pikseli z macierzy na węzły umieszczone na wspólnej płaszczyźnie dwuwymiarowej, przy czym pozycja każdego węzła odzwierciedla oryginalną pozycję piksela w macierzy przed konwersją. Cechy każdego węzła odpowiadają dokładnym wartościom pikseli, nawet tym wielokanałowym.
2. **Obliczanie przemieszczenia:** W tym kroku wyliczane są wektory przemieszczenia każdego obrazu względem obrazu referencyjnego. Następnie każdy węzeł zostaje odpowiednio przesunięty na podstawie przypisanego mu wektora przesunięcia.
3. **Konstrukcja grafu:** Połączenia między węzłami są tworzone na podstawie ich odległości od siebie, przy użyciu określonego promienia. Dodatkowo każda krawędź (połączenie) pomiędzy dwoma węzłami posiada swój wektor cech, przechowujący wektor przesunięcia konkretnego węzła względem węzła sąsiadującego.




(1) Stos $N = 3$ obrazów wejściowych o wymiarach 5×5 .



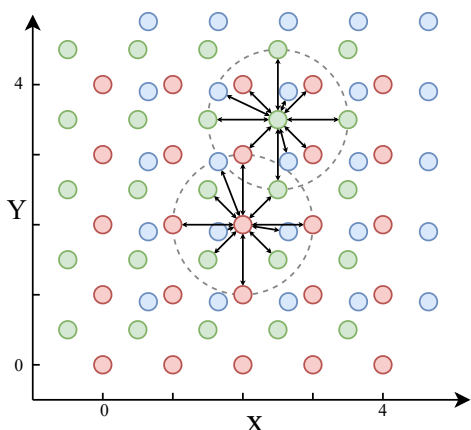
(2) Konwersja pikseli na węzły, oraz umieszczenie ich na wspólnej płaszczyźnie dwuwymiarowej.



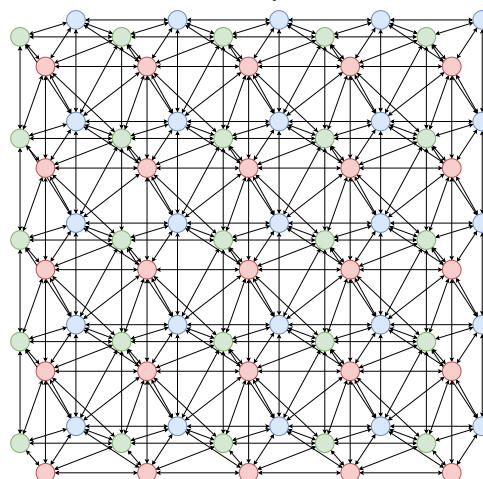
(3) Wyliczenie wektorów przesunięć dla każdego obrazu wejściowego względem obrazu referencyjnego.



(4) Dostosowanie pozycji węzłów przy użyciu obliczonych wektorów przesunięć.



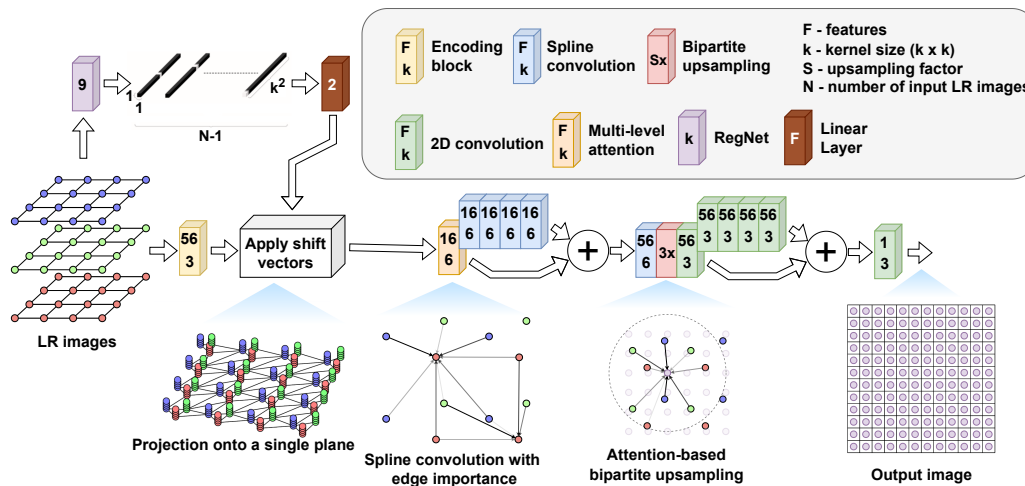
(5) Procedura łączenia dwóch losowo wybranych węzłów dla promienia $r = 1$.



(6) Graf końcowy.

RYSUNEK 1: Wizualizacja przedstawiająca kolejne kroki konwersji zbioru obrazów wejściowych w kompletny graf.

Rozdział ten prezentuje również modele opracowane w celu uzasadnienia wszystkich tez niniejszej rozprawy. Zaproponowane modele zostały dokładnie omówione, a każdy z nich charakteryzuje się specyficzną modyfikacją względem poprzedniego:



RYSUNEK 2: Architektura modelu MagNet.

- **MagNet:** Analizując graf wejściowy składający się z wielu obrazów o niskiej rozdzielczości, MagNet stanowi pierwszą inicjatywę w obszarze MISR bazującą na sieciach grafowych. Traktowany przez autora jako wstępny dowód koncepcji, model ten posiada pewne ograniczenia, które zostały omówione w dedykowanej sekcji. Jednym z zidentyfikowanych ograniczeń jest redukcja liczby węzłów grafu na pewnym etapie procesu, co potencjalnie prowadzi do zmniejszenia ilości informacji wykorzystywanych na etapie zwiększania rozdzielczości.
- **MagNet++:** Ten model wprowadza próbkowanie oparte na grafach, aby poprawić jakość rekonstrukcji, adresując jednocześnie ograniczenia zidentyfikowane w architekturze MagNet. Uwzględnienie próbkowania grafowego pozwala na lepsze modelowanie zależności przestrzennych, co jest jednym z kluczowych zagadnień omawianych w drugiej tezie niniejszej rozprawy.
- **MagNet_{enc}:** Prezentowany model zawiera ulepszoną procedurę ekstrakcji cech dla każdego obrazu wejściowego indywidualnie, co przyczynia się do lepszego uchwycenia szczegółów obiektów z każdego obrazu wejściowego.
- **MagNAT:** Charakteryzujący się dynamiczną rejestracją poprzez trenowalny moduł rejestrujący, ten model również dla każdej krawędzi grafu

wylicza współczynnik uwagi, określając znaczenie węzła w kontekście sąsiadującego węzła. W eksperymentalnej części dysertacji, MagNAt służy jako główny model spośród zaproponowanych, i zostaje użyty do porównań z aktualnie dominującymi modelami MISR. Architektura MagNAt jest przedstawiona na rysunku 2.

- **MagNAt_{no_reg}**: Ta wersja modelu MagNAt jest pozbawiona komponentu dynamicznej rejestracji, umożliwiając ocenę wpływu tego komponentu na jakość rekonstrukcji.
- **MagNAt_{lead}**: Modyfikacja modelu MagNAt zrealizowana w celu potwierdzenia trzeciej tezy, skoncentrowana na rekonstrukcji sceny w określonym punkcie czasowym determinowanym przez wiodący obraz wejściowy.

Rozdział 4: Opis i symulacja danych

W tym rozdziale przedstawiono zbiory danych, które zostały wykorzystane w trakcie badań, podkreślając ich znaczenie w procesie treningu oraz walidacji proponowanych modeli i modeli wiodących.

- **Dane symulowane**: Omówiono dwa zestawy danych symulowanych, SRRB oraz SRRB_{enh}, które charakteryzują się różnymi poziomami trudności. Zestawy te zostały stworzone z myślą o treningu i ewaluacji modeli w kontrolowanych warunkach. Dodatkowo, omówiono procesy generowania tych zestawów danych oraz ich znaczenie w przeprowadzonych badaniach.
- **Dane rzeczywiste**: W celu ewaluacji modeli na danych rzeczywistych, wykorzystano dane ze zbioru Proba-V. Dodatkowo, przedstawiono strukturę tego zbioru, pasma spektralne (NIR i RED), oraz omówiono sposoby radzenia sobie z problemami związanymi z pozyskiwaniem danych w warunkach rzeczywistych. Podkreślono również znaczenie zbioru Proba-V w badaniach nad MISR.

Rozdział 5: Trening sieci oraz metryki

W bieżącym rozdziale przedstawiono metodykę zastosowaną do treningu poszczególnych modeli oraz opisano metryki użyte w sekcji eksperymentalnej w celu ewaluacji każdej z metod. Zaprezentowano parametry treningowe

dla każdego z wiodących modeli (HighRes-Net, RAMS, PIUNET i TR-MISR), z naciskiem na zachowanie wartości przedstawionych w ich oryginalnych publikacjach, co gwarantuje wierną replikację środowiska treningowego dla każdego modelu. Rozdział ten można podzielić na dwie główne sekcje:

- **Opis treningu:** W tej sekcji opisano procedurę treningu przyjętą dla wszystkich modeli, podkreślając znaczenie dostrajania wydajności w oparciu o walidację, aby zapobiec nadmiernemu dopasowaniu.
- **Metryki ewaluacyjne:** Omówiono konkretne metryki, takie jak cPSNR (ang. corrected peak signal-to-noise ratio), SSIM (ang. structural similarity index measure), LPIPS (ang. learned perceptual image patch similarity), MGE (ang. mean gradient error) i TBE (ang. the blur effect), które zapewniają kompleksowe narzędzia do oceny i porównania jakości rekonstrukcji nadrozdzielczej między poszczególnymi modelami. Zdefiniowano również proces ich dostosowania do wyzwań stawianych przez dane rzeczywiste, proponując ich zmodyfikowane wersje.

Omówienie to stanowi podstawę dla walidacji eksperymentalnej przeprowadzonej w kolejnym rozdziale, zapewniając dogłębne zrozumienie metody, na której opierają się badania.

Rozdział 6: Wyniki eksperymentów i dyskusja

Niniejszy rozdział poświęcony jest ocenie modeli opracowanych w niniejszej rozprawie, z głównym naciskiem na MagNAt. Zawiera on serię eksperymentów przeprowadzonych zarówno na danych symulowanych, jak i rzeczywistych, oferując krytyczny wgląd w możliwości i ograniczenia modelu, a także porównując go z wiodącymi modelami w dziedzinie MISR. Rozdział został podzielony na pięć oddzielnych eksperymentów:

1. **Dane symulowane:** Ewaluacja modeli na dwóch zestawach danych symulowanych została przeprowadzona za pomocą analizy ilościowej (Tabela 1), potwierdzonej testami statystycznymi, oraz analizy jakościowej (Rysunek 3). Zwrócono szczególną uwagę na wydajność modelu MagNAt, demonstrując jego zdolność do generowania wysokiej jakości obrazów zrekonstruowanych w kontrolowanych warunkach. Wyniki liczbowe oraz wizualne zaznaczyły przewagę MagNAt w porównaniu z innymi modelami, tym samym częściowo potwierdzając pierwszą tezę niniejszej rozprawy.

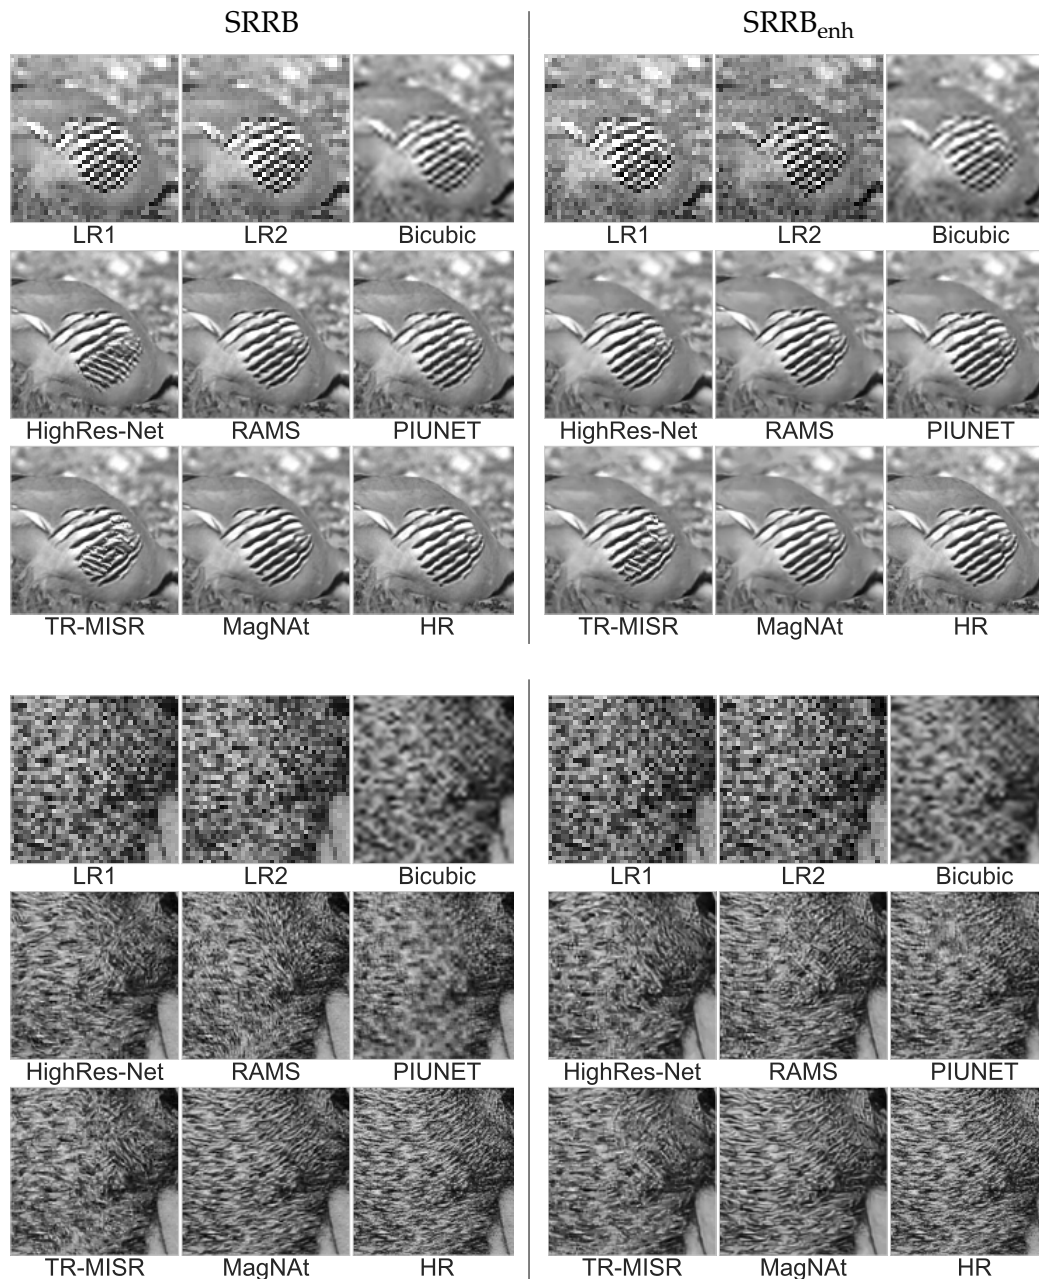
TABELA 1: Zagregowane wskaźniki wydajności, łączące wyniki z obu symulowanych zestawów danych. Najlepsze wyniki są wyróżnione pogrubioną czcionką, a drugie najlepsze podkreślone.

Zbiór danych	Model	cPSNR	cSSIM	cLPIPS	cMGE	TBE
SRRB	Bicubic	24.56	0.783	0.355	0.129	0.405
	HighRes-Net	29.60	0.913	0.057	0.036	<u>0.314</u>
	RAMS	<u>31.96</u>	<u>0.945</u>	0.038	<u>0.021</u>	0.315
	PIUNET	31.49	0.941	0.052	0.026	0.323
	TR-MISR	30.38	0.920	0.055	0.031	0.318
	MagNAt	32.81	0.948	<u>0.041</u>	0.019	0.310
SRRB _{enh}	Bicubic	24.35	0.749	0.386	0.136	0.396
	HighRes-Net	27.83	0.863	0.118	0.051	0.334
	RAMS	<u>29.10</u>	<u>0.888</u>	<u>0.100</u>	<u>0.037</u>	<u>0.333</u>
	PIUNET	28.90	0.884	0.103	0.038	0.340
	TR-MISR	28.06	0.867	0.115	0.045	0.334
	MagNAt	30.12	0.901	0.094	0.026	0.330

TABELA 2: Wskaźniki wydajności uzyskane przez wszystkie testowane metody na zbiorze danych Proba-V. Najlepsze wyniki są wyróżnione pogrubioną czcionką, a drugie najlepsze podkreślone dla każdego pasma spektralnego i metryki niezależnie.

Pasmo	Model	cPSNR	cSSIM	cLPIPS	cMGE	TBE
NIR	Bicubic	33.380	.8625	.2791	.0119	.4595
	HighRes-Net	35.401	.9117	<u>.1361</u>	.0065	.3338
	RAMS	35.648	.9148	.1571	.0065	.3382
	PIUNET	35.769	.9127	.1683	.0067	.3510
	TR-MISR	<u>35.958</u>	.9166	.1307	<u>.0062</u>	<u>.3337</u>
	MagNAt	36.169	<u>.9161</u>	.1777	.0059	.3280
RED	Bicubic	36.419	.9000	.3028	.0068	.4481
	HighRes-Net	37.743	.9337	<u>.1393</u>	.0037	.3245
	RAMS	38.492	<u>.9411</u>	.1601	<u>.0033</u>	<u>.3206</u>
	PIUNET	38.629	.9430	.1706	.0035	.3462
	TR-MISR	<u>38.650</u>	.9396	.1299	<u>.0033</u>	.3238
	MagNAt	38.819	.9406	.1649	.0032	.3195

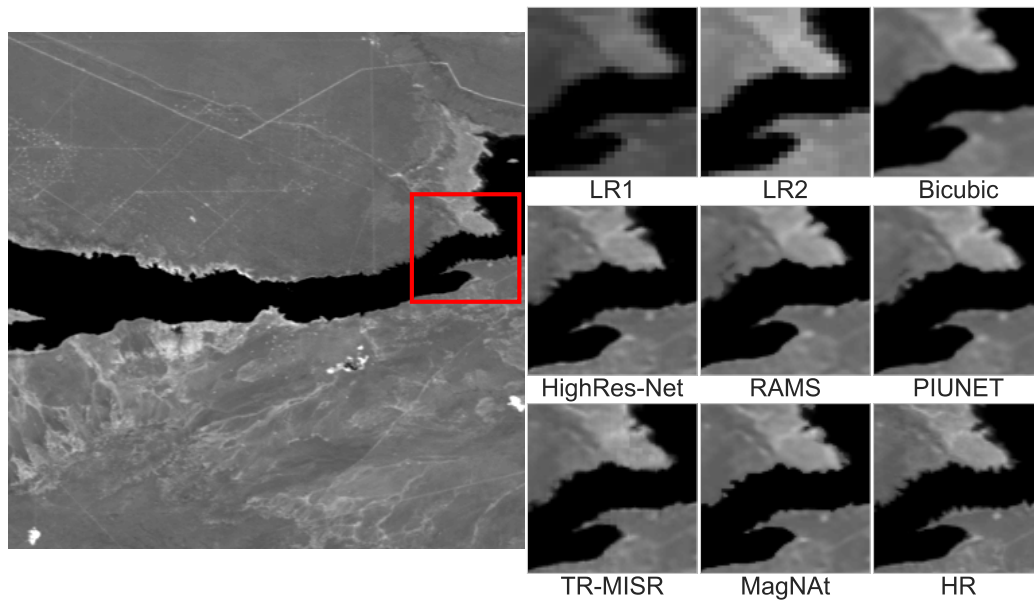
2. **Dane rzeczywiste:** Sekcja ta przedstawia porównanie skuteczności modelu MagNAt z wiodącymi metodami, z wykorzystaniem danych z zestawu Proba-V do ewaluacji. Eksperyment obejmował zarówno analizę ilościową, jak i jakościową, z potwierdzeniem za pomocą testów statystycznych. Wyniki przedstawione zostały w Tabeli 2 oraz na Rysunku 4. Analiza ta wskazuje na konkurencyjną wydajność modelu MagNAt w porównaniu z innymi modelami, skutecznie radząc sobie z




RYSUNEK 3: Przykłady zrekonstruowanych obrazów dla symulowanych zestawów danych BSDS100 (górną) i Set14 (dolną).

wyzwaniami związanymi z danymi rzeczywistymi, co w pełni potwierdziło pierwszą postawioną tezę. Została również omówiona dynamika wydajności przy różnej liczbie obrazów wejściowych dla poszczególnych modeli.

- Zmienność czasowa:** Zwrócono uwagę na wyzwanie związane ze zmiennością czasową danych wejściowych, podkreślając sposób, w jaki




(1) Comparison on NIR subset.



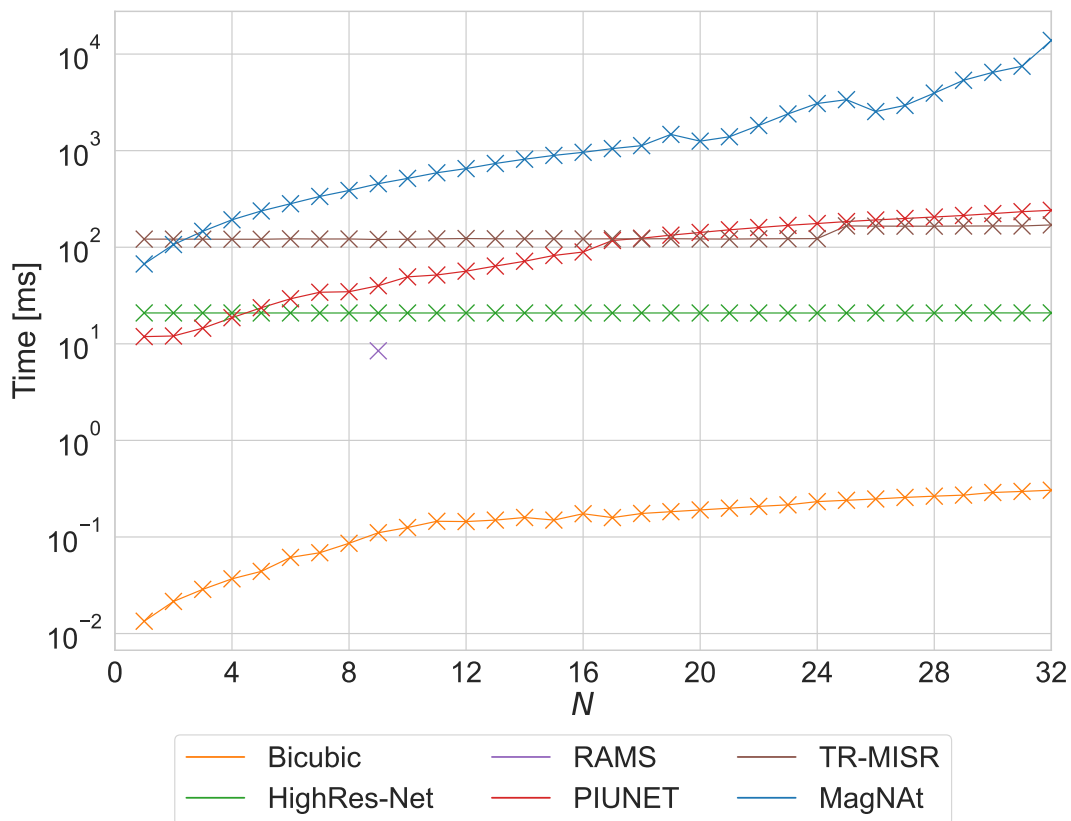
(2) Comparison on RED subset.

RYSUNEK 4: Wizualne porównania wyników na podzbiorach NIR (A) i RED (B) zbioru Proba-V. Wizualizacja skupia się na regionie o rozmiarze 150×150 , wyśrodkowanego w tym samym miejscu dla wszystkich modeli.

model MagNAAt radzi sobie z tym wyzwaniem, kierując proces rekonstrukcji w oparciu o określone ramy czasowe wiodącego obrazu wejściowego. Skuteczność tego podejścia w tworzeniu spójnych czasowo



RYSUNEK 5: Wyniki rekonstrukcji z $\text{MagNAt}_{\text{lead}}$ dla jednej sceny przy użyciu różnych obrazów wiodących, z których jeden (d) został przechwycony w tym samym czasie co obraz o wysokiej rozdzielczości. Odpowiadające wyniki cPSNR i cSSIM znajdują się pod każdym zrekonstruowanym obrazem.



RYSUNEK 6: Czasy obliczeń (w milisekundach) względem liczby obrazów wejściowych (N). Oś pionowa przedstawiona została w skali logarytmicznej.

obrazów nadrozdzielczych zilustrowano na Rysunku 5, oraz przedstawiono jego wyniki ilościowe. Eksperyment ten potwierdził trzecią

tezę dysertacji.

4. **Analiza porównawcza zaproponowanych modeli:** Sekcja ta omawia ewolucję modeli opracowanych w tej rozprawie, ze szczególnym naciskiem na sposób, w jaki model MagNAt poprawił skuteczność rekonstrukcji poprzez integrację technik inspirowanych istniejącymi wiodącymi modelami MISR opartymi na CNN. Przedstawiony został wzrost w jakości każdej zaproponowanej metody względem jej poprzedników, co potwierdziło drugą tezę rozprawy.
5. **Analiza czasowa i pamięciowa:** W ramach tego eksperymentu przeprowadzona została analiza czasowa (Rysunek 6) oraz pamięciowa modelu MagNAt. W porównaniu z wiodącymi modelami, zidentyfikowano możliwości optymalizacji mające na celu poprawę prędkości działania modelu i uczynienie go bardziej odpowiednim dla zastosowań w czasie rzeczywistym.

Rozdział 7: Podsumowanie i wnioski

W tej rozprawie podkreślono znaczenie MISR, zdefiniowano kontekst wykorzystania GNN w MISR oraz sformułowano tezy badawcze. Dokonano kompleksowego przeglądu literatury, co pozwoliło uwypuklić luki i wyzwania istniejących technik MISR, głównie opartych na CNN, torując tym samym drogę dla proponowanego podejścia bazującego na grafowych sieciach neuronowych. Omówiono proces tworzenia grafu z obrazów o niskiej rozdzielczości oraz przedstawiono zaprojektowane modele zdolne do przetwarzania grafu wejściowego w celu rekonstrukcji nadrozdzielczej. Wybrano zestawy danych symulowanych oraz rzeczywistych do oceny, a także opisano szczegóły treningu modeli. Dodatkowo, zarysowano metryki użyte do ewaluacji modeli w sekcji eksperymentalnej. Prezentowane badania zawierają wyniki i dyskusje dotyczące symulowanych i rzeczywistych zestawów danych, weryfikację tez oraz omówienie dynamiki czasowej i ulepszeń modeli. Szczegółowa analiza wymagań czasowych i pamięciowych rzuciła światło na wydajność obliczeniową oraz skalowalność, wraz z identyfikacją możliwości optymalizacji.

Przyszłe kierunki zostały również omówione, w tym koncentracja na optymalizacji wydajności obliczeniowej i skalowalności, badaniu bardziej wydajnych metod konstruowania grafów oraz wykorzystaniu specjalistycznego sprzętu do przyspieszenia obliczeń. Do obiecujących ścieżek badawczych

należą: zastosowanie modelu do wielospektralnej wieloobrazowej rekonstrukcji nadrozdzielczej, modyfikacja metody tworzenia grafu w celu jej dostosowania do obrazów przekształconych w sposób nieafiniczny względem siebie oraz zastosowanie na danych o wyższej nieregularności niż obrazy, jak na przykład chmury pikseli.

Bibliografia

- [1] Tai An et al. "TR-MISR: Multiimage Super-Resolution Based on Feature Fusion With Transformers". In: *IEEE J-STARS* 15 (2022), pp. 1373–1388.
- [2] Liqiang Bao et al. "Masked Graph Attention Network for Person Re-Identification". In: *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. 2019, pp. 1496–1505. DOI: 10.1109/CVPRW.2019.00191.
- [3] Alan C. Bovik. *Handbook of Image and Video Processing (Communications, Networking and Multimedia)*. USA: Academic Press, Inc., 2005. ISBN: 0121197921.
- [4] Michel Deudon, Alfredo Kalaitzis, et al. "HighRes-net: Recursive Fusion for Multi-Frame Super-Resolution of Satellite Imagery". In: *arXiv preprint arXiv:2002.06460* (2020).
- [5] Kunio Doi. "Computer-aided diagnosis in medical imaging: Historical review, current status and future potential". In: *Computerized Medical Imaging and Graphics* 31.4 (2007). Computer-aided Diagnosis (CAD) and Image-guided Decision Support, pp. 198–211. ISSN: 0895-6111. DOI: <https://doi.org/10.1016/j.compmedimag.2007.02.002>. URL: <https://www.sciencedirect.com/science/article/pii/S0895611107000262>.
- [6] Chao Dong, Chen Change Loy, and Xiaoou Tang. "Accelerating the Super-Resolution Convolutional Neural Network". In: *CoRR* abs/1608.00367 (2016). arXiv: 1608.00367. URL: <http://arxiv.org/abs/1608.00367>.
- [7] Sina Farsiu et al. "Fast and robust multiframe super resolution". In: *IEEE Trans. on Image Process.* 13.10 (2004), pp. 1327–1344.
- [8] Keith Fife, Abbas El Gamal, and H.-S. Philip Wong. "A 3MPixel Multi-Aperture Image Sensor with 0.7μm Pixels in 0.11μm CMOS". In: *2008 IEEE International Solid-State Circuits Conference - Digest of Technical Papers*. 2008, pp. 48–594. DOI: 10.1109/ISSCC.2008.4523050.
- [9] Rafael C. Gonzalez and Richard E. Woods. *Digital image processing*. Upper Saddle River, N.J.: Prentice Hall, 2008. ISBN: 9780131687288 013168728X 9780135052679 013505267X. URL: <http://www.amazon.com/Digital-Image-Processing-3rd-Edition/dp/013168728X>.

- [10] J.R. Jensen. *Remote Sensing of the Environment: An Earth Resource Perspective*. Prentice Hall series in geographic information science. Pearson Prentice Hall, 2007. ISBN: 9780131889507. URL: <https://books.google.pl/books?id=A6YsAQAAMAAJ>.
- [11] Rajandeep Kaur and. "A Review of Image Compression Techniques". In: *International Journal of Computer Applications* 142 (May 2016), pp. 8–11. DOI: 10.5120/ijca2016909658.
- [12] Michal Kawulok et al. "Deep learning for multiple-image super-resolution". In: *IEEE GRSL* 17.6 (2020), pp. 1062–1066.
- [13] Maciej Krzywda, Szymon Lukasik, and Amir H. Gandomi. "Graph Neural Networks in Computer Vision - Architectures, Datasets and Common Approaches". In: *2022 International Joint Conference on Neural Networks (IJCNN)*. IEEE, July 2022. DOI: 10.1109/ijcnn55064.2022.9892658. URL: <https://doi.org/10.1109%2Fijcnn55064.2022.9892658>.
- [14] Y. Lecun et al. "Gradient-based learning applied to document recognition". In: *Proceedings of the IEEE* 86.11 (1998), pp. 2278–2324. DOI: 10.1109/5.726791.
- [15] Andrea Bordone Molini et al. "DeepSUM: Deep neural network for super-resolution of unregistered multitemporal images". In: *IEEE TGRS* 58.5 (2020), pp. 3644–3656.
- [16] Kamal Nasrollahi and Thomas Moeslund. "Super-resolution: A comprehensive survey". In: *Machine Vision and Applications* 25 (Aug. 2014), pp. 1423–1468. DOI: 10.1007/s00138-014-0623-4.
- [17] Kamal Nasrollahi and Thomas B Moeslund. "Super-resolution: a comprehensive survey". In: *Machine vision and applications* 25.6 (2014), pp. 1423–1468.
- [18] Francesco Salvetti et al. "Multi-Image Super Resolution of Remotely Sensed Images Using Residual Attention Deep Neural Networks". In: *Remote Sensing* 12.14 (2020), p. 2207.
- [19] Yunqing Tang, Yin Xiang, and Guangfeng Chen. "A Nighttime and Daytime Single-Image Dehazing Method". In: *Applied Sciences* 13.1 (2023). ISSN: 2076-3417. DOI: 10.3390/app13010255. URL: <https://www.mdpi.com/2076-3417/13/1/255>.

-
- [20] Tomasz Tarasiewicz et al. "Multitemporal and multispectral data fusion for super-resolution of Sentinel-2 images". In: *IEEE Transactions on Geoscience and Remote Sensing (TGRS)* (in press).
- [21] Diego Valsesia and Enrico Magli. "Permutation Invariance and Uncertainty in Multitemporal Image Super-Resolution". In: *IEEE TGRS* 60 (2022), pp. 1–12.
- [22] Sijie Yan, Yuanjun Xiong, and Dahua Lin. *Spatial Temporal Graph Convolutional Networks for Skeleton-Based Action Recognition*. 2018. arXiv: 1801.07455 [cs.CV].