

# Zwiększenie rozdzielczości obrazów termowizyjnych metodą sieci neuronowych głębokiego uczenia

Piotr Więcek, Dominik Sankowski

Politechnika Łódzka, Instytut Informatyki Stosowanej, ul. Stefanowskiego 18/22, 90-924 Łódź

**Streszczenie:** W pracy przedstawiono nowy algorytm zwiększenia rozdzielczości obrazów termowizyjnych. W tym celu zintegrowano sieć resztkową z modułem współdzielonego filtra z podpróbkowaniem obrazu KSAC (ang. Kernel-Sharing Atrous Convolution). Uzyskano znaczne skrócenie czasu działania algorytmu przy zachowaniu dużej dokładności. Sieć neuronową zrealizowano w środowisku PyTorch. Przedstawiono wyniki działania proponowanej nowej metody zwiększenia rozdzielczości obrazów termowizyjnych o wymiarach  $32 \times 24$ ,  $160 \times 120$  i  $640 \times 480$  dla skali 2–6.

**Słowa kluczowe:** resztkowe sieci neuronowe, głębokie uczenie, superrozdzielczość, obraz termograficzny, PyTorch

## 1. Wprowadzenie

Problematyka zwiększenia rozdzielczości obrazów cyfrowych rozwijana jest od wielu lat. Dotychczas najczęściej stosowane są metody interpolacyjne, do których można zaliczyć algorytm najbliższego sąsiada (NN) oraz metody interpolacji biliniowej i dwusześcienniej (ang. *bicubic*) [21]. Bardziej zaawansowane techniki stosują filtry Lanczosa [3] lub interpolacje za pomocą funkcji sklepanych [10]. Znane są sprzętowe metody zwiększenia rozdzielczości systemów termowizyjnych, które stosują technikę mikro skaningu [19]. Zwiększenie rozdzielczości systemów termowizyjnych staje się obecnie pilnym do rozwiązania problemem technicznym ze względu na coraz większą ofertę tanich matryc bolometrycznych o małej rozdzielczości [22–24].

Ostatnio w literaturze pojawiają się prace, w których autorzy proponują nowe zastosowania algorytmów głębokiego uczenia do zwiększenia rozdzielczości obrazów, znane pod nazwą metod superrozdzielczości [5, 8, 9, 11–13, 20], które dotyczą w przeważającej większości obrazów wizyjnych. Podejmowane są także próby zastosowania metod superrozdzielczości w innych zastosowaniach, np. do rekonstrukcji obrazów MRI [14], a także w termowizji w podczerwieni [13, 17].

Na podstawie ostatnio publikowanych wyników badań można skonstatować, że zastosowanie sieci resztkowych RDLNN (ang. *Residual Deep Learning Neural Network*) daje lepsze rezultaty

w porównaniu z klasycznymi sieciami spłotowymi CNN (ang. *Convolutional Neural Network*), głównie przez skrócenie czasu uczenia sieci [9, 11, 12]. W ogólnym przypadku, podczas uczenia głębokiego sieci metodami optymalizacji gradientowej, występuje problem zerowania gradientów przy użyciu arytmetyki o skończonej precyzji, co uniemożliwia wykonanie pełnego procesu uczenia. W celu zredukowania efektu zaniku gradientów, wprowadza się połączenia bezpośrednie, omijające wybrane bloki sieci RDLNN [2, 4, 7, 15]. W rezultacie obraz na wyjściu warstw ukrytych jest różnicą (wartością resztkową) obrazu [8]. Obraz resztkowy zawiera szczegóły obrazu o dużych wartościach częstotliwości przestrzennych, podobnych do krawędzi.

Inspiracją do podjęcia badań nad zwiększeniem rozdzielczości obrazów termowizyjnych były publikacje przedstawiające różne wersje architektury zagnieżdżonych sieci resztkowych RIR (ang. *Residual In Residual*) [12, 20]. W pracy [12] autorzy zaproponowali modyfikację sieci RIR, w której zachowując długie połączenia globalne, zredukowano liczbę wewnętrznych bloków resztkowych do dwóch warstw filtrów spłotowych z jedną nieliniową warstwą usuwania ujemnych wartości cech ReLU. Dodatkowo usunięto bloki normalizujące, co znacząco skróciło czas uczenia. Algorytm superrozdzielczości o przedstawionej architekturze zaimplementowano w środowisku *PyTorch*, które jest udostępnione na zasadzie darmowej licencji [25–27]. Przeprowadzono próby zwiększenia rozdzielczości obrazów wizyjnych o skali  $s = 2, 3$  i  $4$ .

Głównym problemem zastosowania sieci spłotowych w praktyce jest ich długi czas działania i to nie tylko w fazie uczenia. W rezultacie nie jest dziś możliwa ich implementacja w czasie rzeczywistym w praktycznych zastosowaniach. W przedstawionej pracy zaproponowano integrację sieci resztkowej z modułem współdzielonego filtra i podpróbkowaniem obrazu (ang. *Kernel-Sharing Atrous Convolution*) [6].

### Autor korespondujący:

Piotr Więcek, pwiecek@gmail.com

### Artykuł recenzowany

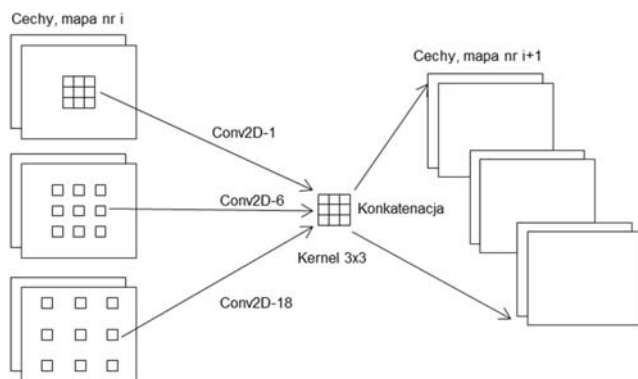
nadesłany 04.07.2021 r., przyjęty do druku 05.08.2021 r.




Zezwala się na korzystanie z artykułu na warunkach licencji Creative Commons Uznanie autorstwa 3.0

## 2. Sieć KSAC-ResNet do zwiększania rozdzielczości obrazów termowizyjnych

Podstawowym elementem architektury nowej sieci splotowej jest moduł KSAC opracowany do segmentacji, rozpoznawania i klasyfikacji obiektów [6]. Działanie modułu KSAC polega na wielokrotnym filtrowaniu obrazu, który poddano kolejnym operacjom podpróbkowania (Rys. 1). W literaturze algorytm ten nazwano przestrzennym piramidalnym podpróbkowaniem obrazu (ang. *Spatial Pyramid Pooling*) [6]. Zastosowanie modułu KSAC zapewnia wyznaczenie cech obrazów z uwzględnieniem zarówno szczegółów w otoczeniu każdego punktu w obrazie, jak również informacje w większym otoczeniu.



Rys. 1. Struktura modułu KSAC  
Fig. 1. Structure of KSAC module



Rys. 2. Struktura sieci resztkowej KSAC-ResNet  
Fig. 2. Structure of residual network KSAC-ResNet

Klasyczna struktura sieci resztkowej zawiera wiele (np. 16 lub 32) szeregowo połączonych lokalnych bloków resztkowych R. Na wejściu zazwyczaj stosuje się klasyczny blok filtracji splotowej sieci głębokiego uczenia C (ang. *Convolutional block*). Na wyjściu sieci w celu zwiększenia rozdzielczości należy zastosować blok nadpróbkowania U (ang. *Up-scaling block*) połączony z wyjściowym blokiem filtru C (Rys. 2). Koncepcja działania nowej sieci splotowej zakłada redukcję liczby lokalnych bloków resztkowych R i zastąpienie ich modulem KSAC.

Uczenie sieci KSAC-ResNet przeprowadzono stosując obrazy innej modalności – obrazy wizyjne dużej rozdzielczości (ang. *transfer learning*). Obrazy treningowe uzyskano z ogólnodostępnej bazy DIV 2K [1]. Zbiór danych uczących zawierał 800 wizyj-


nych obrazów RGB o różnej rozdzielczości, np.  $2040 \times 1404$  lub  $1024 \times 1356$ . W bazie obrazów DIV 2K znajdują się obrazy dużej rozdzielczości HR oraz odpowiadające im obrazy zdegradowane LR do rozmiaru mniejszego metodą interpolacji bikubicznej. Ponadto w procesie uczenia, z każdego obrazu wybierano losowo fragmenty o wymiarach  $192 \times 192$ , co istotnie zredukowało rozmiar przestrzeni cech i przyspieszyło działanie sieci.

## 3. Wyniki eksperymentów

Badania praktyczne przeprowadzono na komputerze z procesorem  $4 \times$  Xeon 2,2 GHz CPU i pamięcią 20 GB. Komputer wyposażony był w kartę graficzną Tesla T4 16 GB GPU. Badania prowadzono porównując uzyskane wyniki uczenia i walidacji z opublikowanymi wynikami działania referencyjnej sieci resztkowej EDSR16, EDSR32 [12]. Obrazy termowizyjne, mimo że są prezentowane w kolorze, mają charakter obrazów monochromatycznych. Z tego powodu w procesie uczenia podawano przekształcone obrazy RGB z bazy DIV 2K do postaci 16-bitowych obrazów w odcieniach szarości. W każdej iteracji (epoce) zbiór uczący zawierał 16 000 obrazów wizyjnych.

Początkowo stosowano uczenie progresywne, w którym wyniki uczenia dla mniejszej skali zastosowano jako wartości początkowe do uczenia sieci dla skali większej [12]. Badania nie potwierdziły poprawy skuteczności zwiększania rozdzielczości obrazów metodą progresywną, jak również nie skrócił się czas uczenia. Wyniki badań potwierdziły dobrą zbieżność procesu uczenia sieci KSAC-ResNet. Po kilkuset iteracjach osiągnięto stabilizację wartości współczynnika PSNR (ang. *Peak Signal-to-Noise Ratio*) na poziomie około 35 dB (Rys. 3). Warto zwrócić uwagę, że referencyjna sieć EDSR32 wykazywała efekt przecięcia.

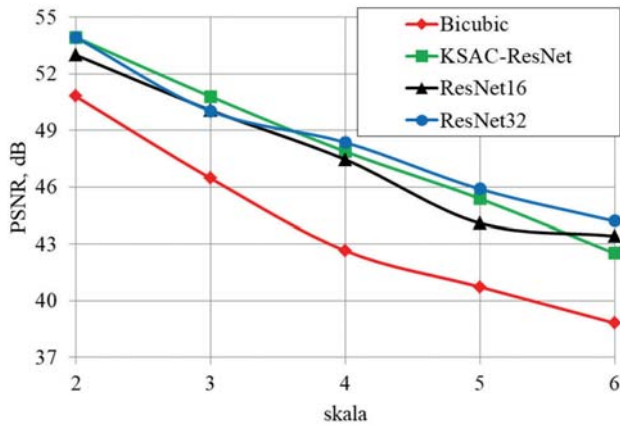
Przeprowadzono zwiększanie rozdzielczości obrazów termowizyjnych o rozmiarze  $640 \times 480$  dla sieci EDSR16 (ResNet16), EDSR32 (ResNet32) i KSAC-ResNet dla współczynników skali  $s = 2, 3, 4, 5, 6$ . Sieci zostały wytrenowane obrazami wizyjnymi dużej rozdzielczości metodą *transfer learning*. Do oceny jakości przetwarzania zastosowano 26 obrazów termowizyjnych o rozdzielczości  $640 \times 480$ . Na wstępie zdegradowano metodą interpolacji bikubicznej każdy obraz odpowiednio w skali od  $1/2$  do  $1/6$ , by zwiększyć rozdzielczość do wartości oryginalnej. Wartości średnie współczynników PSNR dla 26 operacji zwiększenia rozdzielczości przedstawiono na Rys. 4.



Rys. 3. Współczynnik PSNR podczas uczenia sieci KSAC-ResNet (wykres czerwony) i EDSR32 (wykres niebieski) monochromatycznymi obrazami wizyjnymi o dużej rozdzielczości dla skali  $s = 2$   
Fig. 3. PSNR metrics during learning of KSAC-ResNet (in red) and EDSR32 (in blue) networks using monochromatic visual image of high resolution for scale  $s = 2$

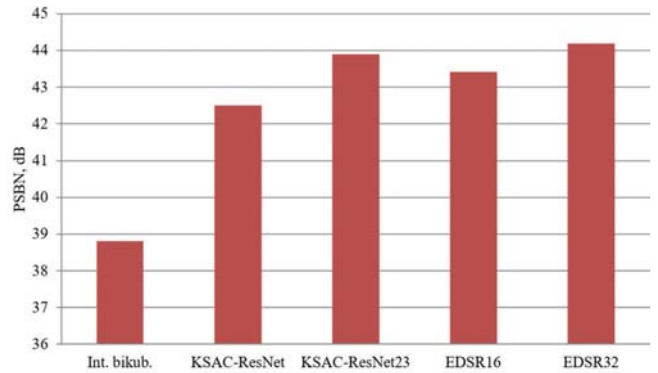
Jak można zauważyć na Rys. 4, wartości współczynnika PSNR są nieznacznie większe dla sieci KSAC-ResNet dla skali  $s = 2$  i  $3$ . Dla skali  $s = 4, 5$  i  $6$  większe wartości współczynnika PSNR osiąga sieć EDSR32. Dla skali  $s = 5$  sieć KSAC-ResNet zapewniła uzyskanie lepszego wyniku w porównaniu z rezultatem sieci EDSR16 o ok. 1,3 dB. Dla skali  $s = 6$ , sieć KSAC-ResNet dała wynik gorszy od sieci EDSR16 o około 1 dB i od sieci EDSR32 o około 1,7 dB. Z tego powodu zaproponowano dla skali  $s = 6$  dwukrotnie wykonane powiększenie wymiarów obrazu w skali  $s = 2$  i  $s = 3$ .

Podsumowując etap badań dotyczący oceny dokładności przetwarzania obrazów o rozdzielczości  $640 \times 480$  można stwierdzić, że uzyskane wartości współczynnika PSNR dla



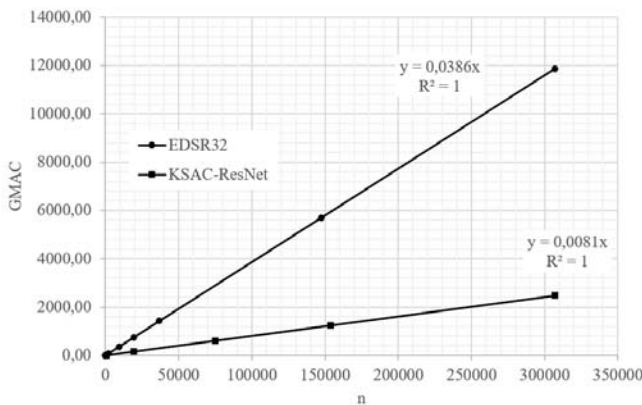
Rys. 4. Wartości współczynnika PSNR dla różnych algorytmów zwiększania rozdzielczości obrazów termowizyjnych o rozdzielczości  $640 \times 480$  sieciami EDSR16 (ResNet16), EDSR32 (ResNet32) i KSAC-ResNet dla różnej skali  $s = 2, 3, 4, 5, 6$

Fig. 4. PSNR metric values for different methods of the resolution increasing of thermal images using EDSR16 (ResNet16), EDSR32 (ResNet32), KSAC-ResNet and bicubic algorithms for scales  $s = 2, 3, 4, 5, 6$



Rys. 5. Porównanie wyników interpolacji bikubicznej i zwiększania rozdzielczości dla sieci KSAC-ResNet, KSAC-ResNet23, EDSR16 oraz EDSR32 obrazów termowizyjnych o rozdzielczości  $640 \times 480$  dla skali  $s = 6$

Fig. 5. Comparison of increasing the resolution using different algorithms for scale  $s = 6$  for ResNet, KSAC-ResNet23, EDSR16, EDSR32 networks and bicubic interpolation




Rys. 6. Zależności liczby operacji MAC w funkcji liczby danych wejściowych (liczby punktów obrazów wejściowych) dla sieci EDSR32 oraz KSAC-ResNet i skali powiększenia  $s = 2$

Fig. 6. Number of MAC operations as a function of the number of input data (number of points of input images) for the EDSR32 and KSAC-ResNet networks and the scale  $s = 2$

nowej sieci resztkowej KSAC-ResNet i referencyjnej sieci EDSR32 są porównywalne (Rys. 5). Na podkreślenie zasługuje fakt, że badania dotyczyły różnych wartości współczynnika skali  $s = 2-6$ .

Finalnym etapem badań była analiza złożoności obliczeniowej opracowanego algorytmu działania sieci KSAC-ResNet i porównanie jej ze złożonością implementacji referencyjnej sieci resztkowej EDSR32. Złożoność obliczeniowa jest powiązana z liczbą parametrów sieci neuronowych. Dla sieci głębokiego uczenia, które stosują operacje splotu dwuwymiarowego, wyznacza się liczbę operacji mnożenia i sumowania MAC (ang. *Multiply-Accumulate*), które realizuje procesor graficzny. Wyznaczono liczbę operacji MAC w funkcji liczby danych wejściowych, tzn. liczby punktów przetwarzanego obrazu dla skali  $s = 2$ . Wyniki symulacji potwierdziły liniową zależność  $MAC = f(n)$  dla obu porównywanych sieci głębokiego uczenia. W rezultacie złożoność ta okazała się złożonością typu  $O(n)$  zarówno dla sieci EDSR, jak i KSAC-ResNet, co przedstawiono na Rys. 6. Wyniki badań potwierdziły znacznie mniejszą złożoność obliczeniową algorytmu sieci KSAC-ResNet. Choć wynik ten przekłada się na szybkość działania sieci podczas realizacji superrozdzielczości, to wciąż na obecnym poziomie technologii systemów komputerowych, jest to wynik uniemożliwiający implementację sieci głębokiego uczenia w czasie rzeczywistym.

Na Rys. 7 przedstawiono powiększone obrazy termowizyjne wzbudnika i mosiężnego wsadu wykonane kamera z detektorem



Rys. 7. Powiększone obrazy termowizyjne wzbudnika i mosiężnego wsadu o skali 6 do rozdzielczości  $960 \times 720$ , a) interpolacja bikubiczna, b) EDSR16, c) EDSR32, d) KSAC-ResNet

Fig. 7. Enlarged thermal images of the inductor and brass charge for scale 6 to resolution  $960 \times 720$ , a) bicubic interpolation, b) EDSR16, c) EDSR32, d) KSAC-ResNet


o rozdzielczości  $160 \times 120$  sensorów podczas grzania i hartowania indukcyjnego. Po zwiększeniu rozdzielczości, rozmiary obrazów wynoszą  $960 \times 720$ . Jakościowa ocena wyników pozwala stwierdzić, że algorytmy sieci głębokiego uczenia są zdecydowanie lepsze z punktu widzenia odwzorowania szczegółów i krawędzi obrazu.

Wydaje się, że można zastosować proponowany algorytm sieci KSAC-ResNet w celu zwiększenia rozdzielczości dla systemów termowizyjnych o bardzo małej rozdzielczości, np.  $32 \times 24$ . Obecnie takie systemy są dostępne na rynku. Przy niewielkiej liczbie sensorów w matrycy, możliwe jest wykonywanie operacji superrozdzielczości w czasie rzeczywistym. Na Rys. 8 przedstawiono wyniki powiększenia rozdzielczości przestrzennej obrazów  $32 \times 24$  dla skali  $s = 5$  do rozmiaru  $160 \times 120$ .

## 4. Wnioski

W pracy przedstawiono nową architekturę sieci resztkowej głębokiego uczenia KSAC-ResNet do realizacji zadania zwiększenia rozdzielczości obrazów termowizyjnych. Przedstawiony materiał jest częścią rozprawy doktorskiej, w której można





Rys. 8. Powiększone obrazy o rozdzielczości  $32 \times 24$  dłoni i wzбудnika wraz z mosiężnym wsadem o skali 5 do rozdzielczości  $160 \times 120$ ; a, c) interpolacja bikubiczna; b, d) KSAC-ResNet

Fig. 8. Enlarged  $32 \times 24$  pixel images of a hand and an inductor with a brass insert for scale 5, to the final resolution  $160 \times 120$  resolution; a, c) bicubic interpolation; b, d) KSAC-ResNet

znaleźć więcej wyników symulacji i eksperymentów [18]. Głównym osiągnięciem przeprowadzonych badań jest opracowanie algorytmu zwiększenia rozdzielczości obrazów termowizyjnych o mniejszej złożoności obliczeniowej w porównaniu z innymi znanymi i publikowanymi algorytmami sieci głębokiego uczenia. Na obecnym stanie techniki zaproponowany algorytm może być zastosowany w aplikacjach czasu rzeczywistego jedynie dla systemów termowizyjnych o małej rozdzielczości, np.  $32 \times 24$ . Uczenie sieci KSAC-ResNet przeprowadzono metodą *transfer-learning* z zastosowaniem bazy obrazów wizyjnych o dużej rozdzielczości. Dalszym kierunkiem badań w zakresie zwiększania rozdzielczości obrazów termowizyjnych może być poszukiwanie prostej architektury sieci spłotowej głębokiego uczenia o mniejszej złożoności obliczeniowej. Wydaje się, że wspomaganie sprzętowe działania sieci głębokiego uczenia może doprowadzić do zwiększenia skuteczności ich działania.

## Bibliografia

- Agustsson E., Timofte R., *NTIRE 2017 challenge on single image super-resolution: Dataset and study*, 2017, [https://data.vision.ee.ethz.ch/cvl/DIV2K], DOI: 10.1109/CVPRW.2017.150.
- Bengio Y., Simard P., Frasconi P., *Learning long-term dependencies with gradient descent is difficult*. "IEEE Transactions on Neural Networks", Vol. 5, No. 2, 1994, 157–166, DOI: 10.1109/72.279181.
- Duchon C.E., *Lanczos filtering in one and two dimensions*, "Journal of Applied Meteorology and Climatology", Vol. 8, No. 18, 1979, 1016–1022, DOI: 10.1175/1520-0450(1979)018<1016:LFIOAT>2.0.CO;2.
- Glorot X., Bengio Y., *Understanding the difficulty of training deep feedforward neural networks*, Proceedings of the 13<sup>th</sup> International Conference on Artificial Intelligence and Statistics, 2010.
- Gu J., Wang Z., Kuen J., Ma L., Shahroudy A., Shuai B., Liu X.W.T., Wang G., *Recent advances in convolutional neural networks*, Pattern Recognition, Elsevier, 2017.
- Huang Y., Wang Q., Jia W., He X., *See more than once – kernel-sharing atrous convolution for semantic segmentation*, arXiv:1908.09443 [cs.CV], 16 November, 2019.
- Ioffe S., Szegedy C., *Batch normalization: Accelerating deep network training by reducing internal covariate shift*, Proceedings of the 32<sup>nd</sup> International Conference on Machine Learning, 2015, Lille, France.
- Kim J., Lee J.-K., Lee K.-M., *Accurate image super-resolution using very deep convolutional networks*, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 1646–1654, Munich, September 8–14, 2016, DOI: 10.1109/CVPR.2016.182.
- Kim J.-H., Lee J.-S., *Deep residual network with enhanced upscaling module for super-resolution*, 15<sup>th</sup> European Conference on Computer Vision, 800–808, Salt-Lake City, June 18–22, 2018.
- Kincaid D., Cheney W., *Analiza numeryczna*, Wydawnictwo Naukowe Techniczne, 2007, ISBN 83-204-3078-X.
- Li J., Fang F., Mei K., Zhang G., *Multi-scale residual network for image super-resolution*, 15<sup>th</sup> European Conference on Computer Vision, Munich, September 8–14, 2018.
- Lim B., Son S., Kim H., Nah S., Lee K.M., *Enhanced deep residual networks for single image super-resolution*, The IEEE Conference on Computer Vision and Pattern Recognition Workshops, July 21–26, 2017, Honolulu.
- Mandanici E., Tavasci L., Corsini F., Gandolfi S., *A multi-image super-resolution algorithm applied to thermal imagery*. "Applied Geomatics", Vol. 11, No. 3, 2019, 215–228, DOI: 10.1007/s12518-019-00253-y.
- Shi W., Caballero J., Huszar F., Totz J., Aitken R.B.A.P., Rueckert D., Wang Z., *Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network*, [In:] IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA, 1974–1883, 2016, DOI: 10.1109/CVPR.2016.207.
- Szegedy C., Ioffe S., Vanhoucke V., Alemi A., *Inception v4, inception-ResNet and the impact of residual connections on learning*, arXiv:1602.07261, 2016.
- Wang Z., Chen J., Hoi S.C.H., *Deep learning for image super-resolution: A survey*, arXiv:1902.06068 [cs.CV], 8 Feb. 2020, 1, 2020.
- Więcek P., Sankowski D., *Low-cost, low-resolution IR system with super-resolution interpolation of thermal images for industrial applications*, "Measurement Automation Monitoring", Vol. 64, No. 4, 2018, 108–111.
- Więcek P., *Wybrane algorytmy ilościowej analizy obrazów rozkładu temperatury wsadów w procesach nagrzewania indukcyjnego*, Rozprawa doktorska, Instytut Informatyki Stosowanej, Politechnika Łódzka, 2021.
- Wu X.-S., Cai Y., *Techniques of optical microscan in infrared imaging system*, "Journal of Infrared and Millimeter Waves", Vol. 26, No. 1, 2007, 10–14.
- Zhang Y., Li K., Li K., Wang L., Zhong B., Fu Y., *Image super-resolution using very deep residual channel attention networks*, 15<sup>th</sup> European Conference on Computer Vision, Munich, September 8–14, 2018.
- Zieliński T., *Cyfrowe przetwarzanie sygnałów. Od teorii do zastosowań*. Wydawnictwa Komunikacji i Łączności WKŁ, 2007.
- Flirone, Flir Systems, 2020, [www.flir.com/products/flir-one-pro].
- Melexis. Melexis Inspired Engineering, 2019, [www.melexis.com/en/product///mlx90640/far-infrared-thermal-sensor-array].
- Optris, Optris, 2020, [www.optris.global/thermal-imager-optris-pi160].
- PyTorch v1.3, Pytorch, 2020, [https://pytorch.org].
- Pytorch-Flopscounter v0.6, 2020, [https://github.com/sovrasov/flops-counter.pytorch].
- Pytorch-forwardhook, PyTorch, 2020, [https://pytorch.org/docs/stable/nn.html].

# Increasing of Thermal Images Resolution Using Deep Learning Neural Networks

**Abstract:** The article presents a new algorithm for increasing the resolution of thermal images. For this purpose, the residual network was integrated with the Kernel-Sharing Atrous Convolution (KSAC) image sub-sampling module. A significant reduction in the algorithm's complexity and shortening the execution time while maintaining high accuracy were achieved. The neural network has been implemented in the PyTorch environment. The results of the proposed new method of increasing the resolution of thermal images with sizes  $32 \times 24$ ,  $160 \times 120$  and  $640 \times 480$  for scales up to 6 are presented.

**Keywords:** residual neural networks, deep learning, super-resolution, thermographic image, PyTorch

## dr inż. Piotr Więcek

[pwiecek@gmail.com](mailto:pwiecek@gmail.com)

ORCID: 0000-0002-6049-7923

Ukończył studia na Wydziale Elektrotechniki, Elektroniki, Informatyki i Automatyki Politechniki Łódzkiej w 2011 r. Stopień doktora uzyskał w 2021 r. W ramach rozprawy doktorskiej zajmował się przetwarzaniem obrazów NIR i IR. Główny obszar badawczy to głębokie sztuczne sieci neuronowe oraz algorytmy przetwarzania obrazów. Aktualnie pracuje jako programista.



## prof. Dominik Sankowski

[dominik.sankowski@p.lodz.pl](mailto:dominik.sankowski@p.lodz.pl)

ORCID: 0000-0003-2223-6690

Jest absolwentem Wydziału Elektrotechniki, Elektroniki, Informatyki i Automatyki Politechniki Łódzkiej oraz Wydziału Matematyki Uniwersytetu Śląskiego. Był twórcą i wieloletnim kierownikiem Katedry Informatyki Stosowanej w Politechnice Łódzkiej. Specjalizuje się w przetwarzaniu sygnałów, analizie obrazów oraz tomografii procesowej. Był kierownikiem wielu grantów badawczych i wypromował 25 doktorantów. Jest doktorem HC Ukraińskiej Akademii Finansów.

