



POLITECHNIKA ŚLĄSKA

WYDZIAŁ AUTOMATYKI, ELEKTRONIKI I INFORMATYKI

Rozprawa Doktorska

**Sprzętowa implementacja algorytmów
korekcji niejednorodności matryc
bolometrycznych o wysokiej rozdzielczości**

Autor: mgr inż. Jan Kwiatkowski

Promotor: prof. dr hab. inż. Aleksander Nawrat

Gliwice, 2025

Pracę dedykuję ukochanej żonie Patrycji.

*Serdeczne podziękowania składam promotorowi
prof. dr hab. inż. Aleksandrowi Nawratowi,
dr inż. Damianowi Beresce oraz dr inż. Krzysztofowi
Dańcowi, za cierpliwość, poświęcony czas, pomoc
w przygotowaniu niniejszej rozprawy doktorskiej oraz
za możliwość wspólnej pracy przy wielu interesujących
projektach badawczych, rozwojowych i celowych.*

*Składam również wyrazy wdzięczności rodzinie
i przyjaciołom, za słowa otuchy i okazane wsparcie
w trudnych chwilach, a także za nieustanną motywację
do osiągania celów.*

Spis treści

Słownik skrótów i akronimów	10
1. Wstęp	13
2. Przegląd literatury	16
2.1. Przyczyny powstawania niejednorodności	16
2.2. Metody korekcji niejednorodności	19
2.2.1. Metody kalibracyjne	20
2.2.1.1. Metoda jednego punktu	22
2.2.1.2. Metoda dwóch punktów	23
2.2.1.3. Metoda wielu punktów	25
2.2.1.4. Variable Integration Time	26
2.2.1.5. Alternatywne wzorce odniesienia, stosowane w metodach kalibracyjnych	30
2.2.2. Metody bazujące na analizie sceny	32
2.2.2.1. Metody bazujące na sieciach neuronowych	34
2.2.2.1.1. Neural Network Non-Uniformity Correction	35
2.2.2.1.2. Konwolucyjne sieci neuronowe	42
2.2.2.2. Metody oparte o filtrację	43
2.2.2.2.1. Filtracja temporalna	43
2.2.2.2.2. Filtracja przestrzenno-temporalna	45
2.2.2.2.3. Temporal high-pass based on grayscale mapping	46
2.2.2.2.4. Filtr Kalmana	47
2.2.2.3. Metody statystyczne	47
2.2.2.3.1. Constant Statistics Non-Uniformity Correction	48
2.2.2.3.2. Constant Range Non-Uniformity Correction	51
2.2.2.3.3. Constant Statistics of Adjacent Ratios	54
2.2.2.3.4. Temporal Statistics of Adjacent Pixel	56
2.2.2.4. Metody rejestracyjne	56
2.2.3. Korekcja zakłóceń kolumn	61
2.2.3.1. Metody kalibracyjne	62
2.2.3.1.1. Local spatial correlation-based stripe non-uniformity correction	62

Sprzętowa implementacja algorytmów korekcji niejednorodności matryc bolometrycznych o wysokiej rozdzielczości

2.2.3.2.	Metody oparte o sieci neuronowe	63
2.2.3.2.1.	Stripe Noise Correction Using Neural Network	63
2.2.3.2.2.	Stripe Noise Removal Convolutional Neural Network	64
2.2.3.3.	Metody oparte o filtrację	64
2.2.3.3.1.	1-D Guided Filtering Non-Uniformity Correction	64
2.2.3.3.2.	1-D Horizontal Differential Statistics	65
2.2.3.4.	Minimalizacja różnic między kolumnami	66
2.2.3.4.1.	Stripe noise removal based on the most stable window	66
2.2.3.4.2.	Midway Histogram Equalization	67
2.3.	Nieliniowości charakterystyk mikrobolometrów, wchodzących w skład matrycy	68
2.4.	Rozwiązania sprzętowe w korekcji niejednorodności matryc bolometrycznych	69
2.5.	Podsumowanie przeglądu literatury	73
3.	Proponowane rozwiązanie	76
3.1.	Korekcja zakłóceń kolumn	77
3.2.	Korekcja niejednorodności z uwzględnieniem nieliniowości charakterystyk mikrobolometrów	80
3.2.1.	Wyznaczanie wartości granicznych przedziałów przynależności wartości mierzonych	81
3.2.1.1.	Wyznaczanie histogramu	82
3.2.1.2.	Wyznaczanie wartości granicznych przedziałów przynależności wartości mierzonych	83
3.2.2.	Korekcja niejednorodności nieliniowych charakterystyk odpowiedzi mikrobolometrów, wchodzących w skład matrycy	85
4.	Badania doświadczalne	88
4.1.	Stanowisko laboratoryjne	88
4.2.	Poprawa kontrastu	92
4.3.	Korekcja zakłóceń kolumn	92
4.4.	Wzorcowanie matrycy	95
4.5.	Analiza wpływu ilości i jakości danych statystycznych	98
4.6.	Porównanie działania różnych realizacji metody CR-NUC	101
4.7.	Efekty korekcji niejednorodności	106
5.	Podsumowanie	109

6. Literatura.....	112
Dodatek A – Układy logiki programowalnej z rodziny FPGA.....	124
Dodatek B – Filtr bilateralny	126
Dodatek C – Filtr Guided Filter	127
Dodatek D - Wskaźniki jakości działania metod	130
D.1. Średni błąd bezwzględny.....	130
D.2. Szorstkość	130
D.3. Podobieństwo strukturalne.....	131
D.4. Błąd średniokwadratowy.....	131
D.5. Szczytowy stosunek sygnału do zakłócenia	132
D.6. Piksele na sekundę	133
Dodatek E – Wyznaczanie przedziałów przynależności danych na podstawie analizy histogramu	134

Słownik skrótów i akronimów

BRAM – ang. *Block Random Access Memory* – pamięć operacyjna, wbudowana w układ FPGA.

CB-NUC – ang. *Calibration-Based Non-Uniformity Correction* – korekcja niejednorodności, bazująca na danych kalibracyjnych.

CR-NUC – ang. *Constant Range Non-Uniformity Correction* – statystyczna metoda korekcji niejednorodności.

CS-NUC – ang. *Constant Statistics Non-Uniformity Correction* – statystyczna metoda korekcji niejednorodności.

CSAR-NUC – ang. *Constant Statistics of Adjacent Ratios Non-Uniformity Correction* – statystyczna metoda korekcji niejednorodności.

CNN – ang. *Convolutional Neural Network* – konwolucyjna sieć neuronowa.

FPGA - ang. *Field Programmable Gate Array* – układ logiki programowalnej.

FPN – ang. *Fixed Pattern Noise* – zakłócenie o stałym wzorcu.

GF – ang. *Guided Filter* – filtr oszczędzający krawędzie obiektów.

GF-NUC – ang. *1-D Guided Filtering Non-Uniformity Correction* – oparta o jednokierunkowy filtr GF metoda korekcji zakłóceń kolumn.

IIR – ang. *Infinite Impulse Response* – nieskończona odpowiedź impulsowa.

IRFPA - ang. *InfraRed Focal Plane Array* – matryca wrażliwa na promieniowanie podczerwone.

IRST – ang. *InfraRed Search and Tracking* – system termicznego namierzania i śledzenia obiektów latających.

ITAR - ang. *International Traffic in Arms Regulations* - regulacje rządu Stanów Zjednoczonych Ameryki, dotyczące kontroli eksportu i importu towarów, technologii i usług o charakterze wojskowym, podwójnego zastosowania oraz cywilnym.

ITHP-GM-NUC – ang. *Improved Temporal High-Pass based on Grayscale Mapping* – oparta o filtrację metoda korekcji niejednorodności.

MHE – ang. *Midway Histogram Equalization* – metoda korekcji zakłóceń kolumn.

MP-NUC – ang. *Multiple-Point Non-Uniformity Correction* – korekcja niejednorodności metodą wielu punktów.

NCR-NUC – ang. *Non-linear Constant Range Non-Uniformity Correction* – nieliniowa adaptacja metody CR-NUC.

NN-NUC – ang. *Neural Network Non-Uniformity Correction* – bazująca na zastosowaniu sztucznej sieci neuronowej metoda korekcji niejednorodności.

NRMSE – ang. *Normalized Root Mean Square Error* – znormalizowany pierwiastek błędu średniokwadratowego.

NUC – ang. *Non-Uniformity Correction* – korekcja niejednorodności.

OP-NUC – ang. *One-Point Non-Uniformity Correction* – kalibracyjna metoda korekcji niejednorodności.

RAM – ang. *Random Access Memory* – pamięć operacyjna.

RMSE – ang. *Root Mean Square Error* – pierwiastek błędu średniokwadratowego.

SB-NUC – ang. *Scene-Based Non-Uniformity Correction* – korekcja niejednorodności, bazująca na analizie sceny.

SLP-THP-NUC - ang. *Space Low-Pass Temporal High-Pass Non-Uniformity Correction* – oparta o filtrację metoda korekcji niejednorodności.

SNUC – ang. *Stripe Non-Uniformity Correction* – korekcja zakłóceń kolumn.

SNR-CNN-NUC - ang. *Stripe Noise Removal Convolutional Neural Network Non-Uniformity Correction* – oparta o zastosowanie konwolucyjnych sieci neuronowych metoda korekcji zakłóceń kolumn.

TEM – ang. *Thermogram Enhancement Module* – moduł poprawy jakości termogramu.

THP-GM-NUC – ang. *Temporal High-Pass based on Grayscale Mapping* – oparta o filtrację metoda korekcji niejednorodności.

THPF-NUC – ang. *Temporal High-Pass Filter Non-Uniformity Correction* -
oparta o filtrację metoda korekcji niejednorodności.

TP-NUC – ang. *Two-Point Non-Uniformity Correction* – korekcja
niejednorodności metodą dwóch punktów.

TSAP-NUC – ang. *Temporal Statistics of Adjacent Pixel Non-Uniformity
Correction* – statystyczna metoda korekcji niejednorodności.

VLSI – ang. *Very-Large-Scale Integration* – układ scalony o wielkiej
skali integracji.

XGA – ang. *eXtended Graphics Array* – rozdzielczość obrazu, wynosząca
1024x768 pikseli.

1. Wstęp

Reprezentacja obserwowanego otoczenia w formie obrazu cyfrowego jest jedną z podstawowych, powszechnie stosowanych zdobyczy technologicznych. Możliwość rejestracji otoczenia, realizowana z wykorzystaniem matryc sensorów, znajduje zastosowanie w wielu gałęziach współczesnego przemysłu. Zauważalne jest zapotrzebowanie na kamery, służące do rejestracji obrazu o jak najwyższej jakości. Jakość ta jest rozumiana między innymi przez wysoką rozdzielczość matrycy i wysoką czułość budujących ją sensorów. Parametry te pozwalają na uzyskanie wysokiego poziomu szczegółowości i wierności odwzorowania otoczenia. Dodatkową zaletą zastosowania takiego rozwiązania technologicznego jest możliwość rozszerzenia zdolności percepcji człowieka, poprzez rejestrację fal elektromagnetycznych, których częstotliwości znajdują się poza zakresem, który może być rejestrowany przez oko ludzkie.

Podstawowym elementem kamery jest matryca, składająca się z wielu sensorów, służących do rejestracji padającego na nie promieniowania elektromagnetycznego. Ze względu na różnice technologiczne, wynikające ze sposobu akwizycji pomiarów, wyróżnia się m.in. matryce światłoczułe, działające na zasadzie zjawiska fotoelektrycznego oraz matryce bolometryczne, działające na zasadzie pomiaru zmian temperatury elementu, na który pada promieniowanie elektromagnetyczne. W odróżnieniu od matryc światłoczułych, matryce bolometryczne pozwalają na rejestrację fal elektromagnetycznych, wchodzących w szeroko rozumiane spektrum promieniowania podczerwonego, a w szczególności w zakresy średniej i dalekiej podczerwieni.

Wszystkie obiekty o niezerowej temperaturze i niezerowej emisyjności emitują promieniowanie elektromagnetyczne, określane mianem radiacji cieplnej. Częstotliwość emitowanych fal elektromagnetycznych jest zależna od temperatury obiektu i może znajdować się w pewnych zakresach spektrum promieniowania elektromagnetycznego. W warunkach ziemskich znaczna część radiacji

podczerwonej, emitowanej przez obiekty w otoczeniu, znajduje się w pasmie podczerwieni. Z tego względu akwizycja tego typu radiacji jest realizowana z zastosowaniem matryc bolometrycznych.

Rejestracja obrazu z wykorzystaniem matryc bolometrów nosi miano termowizji. Termowizja znajduje zastosowanie w gałęziach przemysłu, w których pojawia się zapotrzebowanie na reprezentację radiacji podczerwonej w formie obrazu. Wśród odbiorców technologii obrazowania podczerwonego warto wyróżnić m.in. ośrodki naukowe, służby cywilne, wojsko, ośrodki medyczne, sektor energetyczny oraz sektor budowlany.

Termogramy, uzyskane z matryc bolometrycznych są obarczone zakłóceniem o stałej charakterystyce, wynikającym z nieidentycznych charakterystyk odpowiedzi mikrobolometrów, wchodzących w skład matrycy oraz zakłóceń toru pomiarowego matrycy, co skutkuje zwiększeniem niejednorodności obrazu.

Przedmiotem rozprawy jest analiza stanu wiedzy naukowej, w zakresie korekcji niejednorodności termogramów, propozycja autorskiego rozwiązania, opartego o przeanalizowany stan wiedzy naukowej, a także opis wdrożenia i procesu badań zaproponowanego rozwiązania.

Celem prac jest realizacja dedykowanego algorytmu korekcji niejednorodności, służącego do korekcji termogramów, uzyskanych przy pomocy niechłodzonej matrycy bolometrycznej, o rozdzielczości 1024x768 pikseli.

Warunki brzegowe, postawione przed rozwiązaniem, obejmują konieczność realizacji korekcji na etapie przetwarzania wstępnego, w ramach implementacji sprzętowej oraz adaptacyjność zaproponowanej metodologii. Adaptacyjność jest rozumiana przez zdolność algorytmu do aktualizacji parametrów korekcyjnych matrycy, w odpowiedzi na temporalne zmiany parametrów charakterystyk odpowiedzi sensorów, wchodzących w skład matrycy. W świetle tych założeń sformułowano pierwszą tezę rozprawy:

Teza 1. Możliwe jest stworzenie i sprzętowa implementacja adaptacyjnego algorytmu, którego zadaniem jest estymacja i korekcja zakłócenia o stałej

charakterystyce, występującego w strumieniach wideo, uzyskanych przy pomocy matrycy mikrobolometrycznej o wysokiej rozdzielczości.

Realizacja algorytmu w ramach przetwarzania wstępnego nie powinna negatywnie wpływać na częstotliwość odświeżania termogramów. Dlatego przed rozwiązaniem postawiono założenie dotyczące częstotliwości uzyskiwania danych przetworzonych. Zgodnie z jego brzmieniem korekcja niejednorodności powinna być realizowana z częstotliwością akwizycji danych z matrycy, co pozwala na formułę drugiej tezy rozprawy:

***Teza 2.** Możliwa jest realizacja algorytmu korekcji niejednorodności według tezy 1, realizowanego w czasie zbliżonym do rzeczywistego, determinowanym szybkością akwizycji danych pomiarowych, dedykowanego dla matrycy mikrobolometrycznych o wysokiej rozdzielczości.*

Charakterystyki odpowiedzi mikrobolometrów, wchodzących w skład matrycy, mogą cechować się nieliniowym przebiegiem. Jednak większość dzieł literaturowych zakłada liniowy model odpowiedzi mikrobolometru. Stwarza to przestrzeń do rozważań na temat potrzeby uwzględnienia nieliniowości odpowiedzi mikrobolometrów i propozycji autorskiego podejścia do tej problematyki. Pozwala to na definicję trzeciej tezy rozprawy:

***Teza 3.** Możliwa jest sprzętowa implementacja adaptacyjnego algorytmu korekcji niejednorodności według tez 1 i 2, pozwalającego na uwzględnienie nieliniowości charakterystyk odpowiedzi mikrobolometrów, wchodzących w skład matrycy mikrobolometrycznej o wysokiej rozdzielczości, na radiację podczerwoną, emitowaną przez obiekty w obserwowanej scenie.*

Narzędziem, wykorzystanym do potwierdzenia sformułowanych tez jest niechłodzona kamera termowizyjna. Składa się na nią matryca mikrobolometryczna o rozdzielczości 1024x768 pikseli, układ przetwarzania analogowo-cyfrowego, dedykowany sprzętowy sterownik matrycy oraz dedykowane oprogramowanie do odbierania danych z kamery i konfiguracji jej parametrów.

2. Przegląd literatury

Rozdział zawiera podsumowanie analizy stanu wiedzy naukowej, obejmującego szeroko pojęte zagadnienie korekcji niejednorodności matryc bolometrycznych. Analiza tematyki pozwoliła na wyodrębnienie pewnych pojęć i przyjętych konwencji, które mogą stanowić wprowadzenie do problematyki, poruszanej w rozprawie. Ponadto, w rozdziale sklasyfikowano, skatalogowano i opisano metody, pozwalające na korekcję niejednorodności odpowiedzi charakterystyk mikrobolometrów, wchodzących w skład matrycy. W przeglądzie szczególną uwagę zwrócono na znane sprzętowe realizacje opisywanych metod.

2.1. Przyczyny powstawania niejednorodności

Tematyka rozprawy porusza zagadnienie korekcji niejednorodności, wynikającej z szeregu negatywnych efektów, którym podlegają mikrobolometry, wchodzące w skład matrycy. Zgodnie z pracą [41], bolometr jest sensorem, którego zadaniem jest konwersja absorbowanego przez niego promieniowania elektromagnetycznego na sygnał elektryczny. Bolometr zawiera element o wysokiej absorpcji promieniowania i niskiej pojemności cieplnej. Absorbowane przez ten element promieniowanie powoduje jego nagrzanie. Powstała w ten sposób różnica temperatur jest następnie konwertowana na sygnał elektryczny, np. poprzez pomiar zmian rezystancji nagrzanego elementu mostkiem Wheatstone’a.

Zadaniem bolometru jest umożliwienie identyfikacji możliwie szerokiego zakresu fal elektromagnetycznych. Optymalnie byłoby nim całe spektrum promieniowania elektromagnetycznego, jednak ze względu na ograniczenia technologiczne, często jego działanie jest zorientowane w pewnym zakresie długości fal elektromagnetycznych.

Bolometry znajdują zastosowanie w rejestracji obrazu, w matrycach wrażliwych na promieniowanie podczerwone (ang. *InfraRed Focal Plane Array*, *IRFPA*). Jak wspomniano w [41], są one zbudowane z mikrobolometrów –

bolometrów, wspartych skalonym układem pomiaru temperatury. Zgodnie z pracą [98], do ich produkcji wykorzystuje się związki: trójskładnikowy stop rtęci, kadmu i telluru HgCdTe lub supersieci InAs/GaSb. Supersieci stanowią zaawansowane struktury półprzewodnikowe, uzyskane na drodze naprzemiennego osadzania cienkich warstw półprzewodnikowych materiałów: arsenku indu i antymonku galu. W pracy [97] wskazano, że istotny element badawczy stanowi doskonalenie procesu produkcyjnego, które obejmuje propozycje nowatorskich sposobów nanoszenia tych warstw.

Mikrobolometry, wchodzące w skład matrycy mikrobolometrycznej, są równomiernie rozmieszczone na jej powierzchni, w kształcie prostokąta. Ilość użytych mikrobolometrów stanowi wtedy o rozdzielczości takiej matrycy.

Zgodnie z pracą [25], ogólnie przyjęta charakterystyka odpowiedzi bolometru jest przybliżana funkcją liniową. Można ją zapisać równaniem:

$$Y_{ij}(n) = A_{ij}(n)X_{ij}(n) + B_{ij}(n) + V_{ij}(n), \quad (2.1)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – numer próbki,

$Y_{ij}(n)$ – wskazanie sensora,

$A_{ij}(n)$ – wzmocnienie sensora,

$B_{ij}(n)$ – błąd zera sensora,

$V_{ij}(n)$ – zakłócenie pomiarowe,

$X_{ij}(n)$ – rzeczywista wartość promieniowania padającego na sensor.

W pracy [1] zaznaczono, że opisane równaniem (2.1) charakterystyki odpowiedzi pojedynczych mikrobolometrów, wchodzących w skład matrycy IRFPA, mogą się różnić między sobą. Efekt ten prowadzi do powstania niejednorodności w uzyskanym obrazie. Niejednorodność ta objawia się różnicami

jasności pikseli, które nie są związane z rzeczywistymi cechami obrazowanych obiektów.

Ponadto, jak wspomniano w publikacji [44], negatywnym czynnikiem, wpływającym na zwiększenie niejednorodności w obrazie jest dryf temperaturowy parametrów charakterystyk odpowiedzi mikrobolometrów. Zjawisko polega na temporalnych zmianach, wzmocnienia ($A_{ij}(n)$, równanie (2.1)) i błędu zera ($B_{ij}(n)$, równanie (2.1)) każdego z sensorów, wchodzących w skład matrycy. Jak wskazano w pracy [82], zmiany te mogą zależeć zarówno od temperatury samej matrycy, jak i temperatury otoczenia kamery. Zgodnie z pracą [16], dryf temperaturowy wynika z zasady działania mikrobolometru – zastosowanie elementu o wysokiej absorpcji promieniowania może prowadzić do nagrzania matrycy. Zgodnie z badaniami, przedstawionymi w pracach [61] i [99], temperatura matrycy może zmieniać się nawet przez dwie godziny od rozpoczęcia akwizycji.


Inne niekorzystne efekty, które mogą negatywnie wpływać na jednorodność termogramu obejmują:

- efekt narcyza, w wyniku którego mikrobolometr może zacząć reagować na emitowane przez siebie promieniowanie elektromagnetyczne, zamiast na padające na niego promieniowanie,
- martwe piksele, kiedy mikrobolometr ulegnie uszkodzeniu i przestaje reagować na jakiekolwiek promieniowanie elektromagnetyczne,
- zużycie mikrobolometru, mogące wynikać np. z jego eksploatacji czy zabrudzenia,
- zakłócenia pomiarowe.

Zgodnie z publikacją [78], ogół negatywnych efektów, związanych z rejestracją promieniowania elektromagnetycznego jest określany mianem zakłócenia o stałym wzorcu i oznaczany skrótem FPN (ang. *Fixed Pattern Noise*).

2.2. Metody korekcji niejednorodności

Zagadnienie korekcji niejednorodności termogramu nie jest problemem nowym w świecie rejestracji obrazu cyfrowego. Wśród rozwiązań literaturowych znana jest znaczna ilość metod, pozwalających na redukcję niejednorodności w obrazie. Znane są także rozwiązania technologiczne, objęte ochroną patentową, zastrzeżone patentami [93], [94] i [95]. Potwierdza to celowość rozwoju tego typu rozwiązań. Zdecydowana większość analizowanych publikacji naukowych dotyczy matryc, wrażliwych na promieniowanie podczerwone. Wśród ogółu znanych rozwiązań można wyodrębnić pewne cechy wspólne. Pozwala to na propozycję klasyfikacji metod, ze względu na sposób podejścia do problemu oraz sposobu ich realizacji i działania, przedstawioną na rysunku:



Rys. 2.1. Podział metod korekcji niejednorodności.

Podział metod, przedstawiony na rysunku 2.1, zawiera dwie podstawowe klasy metod, wskazywane przez autorów prac [3], [8], [22] i [64]. Obejmują one metody kalibracyjne (ang. *Calibration-Based Non-Uniformity Correction*, *CB-NUC*)

i metody bazujące na analizie sceny (ang. *Scene-Based Non-Uniformity Correction, SB-NUC*). W ramach każdej z klas można wyróżniać dalsze kategorie. Zostały one opisane w dalszych podpunktach, wraz z charakterystyką wybranych metod. Rysunek 2.1. przedstawia także trzecią kategorię metod korekcji niejednorodności, klasyfikującą metody, których celem jest korekcja zakłóceń kolumn w obrazie (ang. *Stripe Non-Uniformity Correction, SNUC*).

Metody tego typu nie skupiają się na indywidualnym podejściu do korekcji każdego z mikrobolometrów matrycy, a na próbie redukcji różnic pomiędzy poszczególnymi kolumnami uzyskanego obrazu. Metody tego typu stanowią istotną część zastanego stanu literatury, a ich działanie może znacząco wspomagać metody, dedykowane indywidualnej korekcji niejednorodności każdego z mikrobolometrów matrycy.

2.2.1. Metody kalibracyjne

Pierwszą z opisywanych klas jest grupa metod kalibracyjnych (ang. *Calibration-Based Non-Uniformity Correction, CB-NUC*). Zasada działania tych metod polega na wzorcowaniu wszystkich mikrobolometrów, wchodzących w skład matrycy. Wzorcowanie jest przeprowadzane na podstawie akwizycji termogramów wzorca o znanej charakterystyce termicznej. W przypadku kamer termowizyjnych rolę wzorca może pełnić obiekt, emitujący znaną, jednorodną radiację podczerwoną o stałym natężeniu i długości fal elektromagnetycznych, ale nie odbijający radiacji pochodzącej z innych źródeł. Taki wzorzec nazywany jest ciałem czarnym. Urządzenie takie bazuje na koncepcji ciała doskonale czarnego. Ciało doskonale czarne to wyidealizowany obiekt, który pochłania całe padające na niego promieniowanie elektromagnetyczne, a cała radiacja pochodząca od niego jest radiacją cieplną, wynikającą z jego niezerowej temperatury. Pobudzając matrycę termowizyjną sygnałem z ciała czarnego, w warunkach laboratoryjnych, można zmierzyć sygnały elektryczne, odpowiadające danej radiacji. Należy jednak pamiętać o wpływie temperatury

matrycy na odczyt. Temperatura ta może się zmieniać podczas użytkowania kamery, co powoduje dryf temperaturowy parametrów charakterystyk mikrobolometrów matrycy. Utrudnia to zastosowanie metod kalibracyjnych, gdyż wymusza wieloetapowy pomiar i interpolację parametrów wszystkich sensorów, wchodzących w skład matrycy, uzależniony od temperatury matrycy lub zapewnienie stałych warunków pracy kamery. Zgodnie z pracą [16], w spotykanych rozwiązaniach technologicznych problem rozwiązuje się poprzez dodanie do kamery układów regulacji temperatury. Zadaniem układów regulacji temperatury jest utrzymanie stałej temperatury pracy matrycy. Pozwala to na uproszczenie kalibracji kamery do pojedynczej serii pomiarów charakterystyk sensorów, wchodzących w skład matrycy. Jednak, takie podejście zwiększa rozmiar kamery i zapotrzebowanie na moc elektryczną, potrzebną do jej zasilania i stanowi wyzwanie dla systemów typu *stand alone*.

Ważną zaletą metod kalibracyjnych jest możliwość uzyskania, na drodze kalibracji, funkcji przejścia pomiędzy odczytem z matrycy oraz temperaturą obserwowanego obiektu. Kalibracja taka wymaga znajomości właściwości fizycznych obserwowanego obiektu: współczynnika emisyjności, albedo (współczynnika odbicia) i współczynnika przepuszczalności promieniowania elektromagnetycznego. Kamera, bazująca na matrycy, skalibrowanej w ten sposób, może służyć do pomiaru temperatury obserwowanych obiektów.

Uzyskane dane kalibracyjne, przechowywane w formie tablicowej, pozwalają na relatywnie szybką korekcję uzyskanych danych. Zwiększa się przez to prawdopodobieństwo osiągnięcia, przez docelową implementację sprzętową, czasu przetwarzania bliskiego rzeczywistemu.

Należy jednak pamiętać, że w czasie użytkowania urządzenia, charakterystyki odpowiedzi mikrobolometrów, wchodzących w skład matrycy, mogą ulegać zmianie. Dlatego może pojawić się konieczność okresowej kalibracji kamery w warunkach laboratoryjnych.

Wśród znanych metod z grupy metody kalibracyjnych warto wyróżnić opisane w kolejnych podpunktach metody jednego punktu (ang. *One-Point Non-Uniformity Correction*, *OP-NUC*), dwóch punktów (ang. *Two-Point Non-Uniformity Correction*, *TP-NUC*) oraz wielu punktów (ang. *Multi-Point Non-Uniformity Correction*, *MP-NUC*).

2.2.1.1. Metoda jednego punktu

Jedną z podstawowych metod kalibracyjnych jest metoda jednego punktu (ang. *One-Point Non-Uniformity Correction*, *OP-NUC*). Bazuje ona na uproszczonym modelu charakterystyki mikrobolometru:

$$Y_{ij}(n) = A_{ij}(n)X_{ij}(n), \quad (2.2)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – numer próbki,

$Y_{ij}(n)$ – wskazanie sensora,

$A_{ij}(n)$ – wzmocnienie sensora,

$X_{ij}(n)$ – rzeczywista wartość promieniowania padającego na sensor.

Uproszczony model charakterystyki mikrobolometru, opisany równaniem (2.2), pomija błąd zera sensora B_{ij} i zakłócenia pomiarowe V_{ij} , obecne w charakterystyce (2.1), których wartości przyjmuje się jako równe zero. Metoda polega na pomiarze radiacji, pochodzącej z pojedynczego, jednorodnego źródła. Temperatura źródła promieniowania jest dobierana w taki sposób, aby emitowana przez nie radiacja odpowiadała średniej radiacji obiektów będących celem obserwacji kamery. Uzyskany w ten sposób pojedynczy punkt charakterystyki odpowiedzi każdego z mikrobolometrów, wchodzących w skład matrycy, pozwala na ujednolicenie ich wzmocnień względem zadanego punktu pracy. Pomiar pozwala na eliminację zakłócenia o stałej charakterystyce dla wzorcowej radiacji.

Metoda jednego punktu daje dobre efekty w przypadkach, gdy błąd zera sensorów, wchodzących w skład matrycy, jest pomijalny.

Zaletą metody jest relatywnie szybki i uproszczony proces kalibracji, a także niska złożoność obliczeniowa obejmująca jedynie multiplikatywną korekcję wzmocnienia sensorów. Ponadto, jak wspomniano w pracy [46], przy zapewnieniu możliwości obserwacji jednorodnego termicznie obiektu, metoda jednego punktu może znajdować zastosowanie podczas aktualizacji istniejącej kalibracji kamery. Przykładowe rozwiązanie tego typu można znaleźć w kamerze Flir Lepton. Zgodnie z dokumentacją urządzenia [100], producent umieścił w wybranych modelach kamery elektronicznie sterowaną przysłonę obiektywu, która zamykana jest podczas automatycznej okresowej aktualizacji parametrów korekcyjnych matrycy, dostarczonych przez producenta wraz z urządzeniem.

Wadą metody jednego punktu jest założenie pomijalnego błędu zera sensorów matrycy, co objawia się pojawiającym się zakłóceniem o stałym wzorcu (FPN), tym wyraźniejszym, im bardziej radiacja obiektów w obserwowanym otoczeniu odbiega od punktu kalibracyjnego. Z tego powodu ta metoda kalibracji jest niewłaściwa dla kamer, których celem jest rejestracja szerokiego spektrum promieniowania elektromagnetycznego, co wynika z publikacji, co wspomniano w pracy [10].

2.2.1.2. Metoda dwóch punktów

Jak wspomniano w pracach [6] i [46], popularną i znajdującą szerokie zastosowanie metodą kalibracyjną, jest metoda dwóch punktów (ang. *Two-Point Non-Uniformity Correction*, *TP-NUC*). Metoda ta zakłada liniowy model charakterystyki odpowiedzi mikrobolometru, opisany równaniem (2.1). Jej działanie polega na pomiarze dwóch punktów charakterystyk odpowiedzi wszystkich mikrobolometrów, wchodzących w skład matrycy. Realizowane jest to poprzez obserwację dwóch jednorodnych źródeł promieniowania elektromagnetycznego. Zgodnie z obserwacjami, przedstawionymi w pracy [15],

istotne dla jakości kalibracji jest zapewnienie odpowiedniej rozpiętości danych wzorcowych (temperatur wzorców kalibracyjnych). Dzięki pomiarom dwóch punktów charakterystyki możliwa jest estymacja oraz korekcja wzmocnień i błędów zera wszystkich sensorów matrycy.

Metoda pozwala na dokładną korekcję zakłócenia o stałej charakterystyce tylko w sytuacji, gdy charakterystyki odpowiedzi mikrobolometrów, wchodzących w skład matrycy, są rzeczywiście liniowe. W przypadku wystąpienia nieliniowości charakterystyk odpowiedzi mikrobolometrów, metoda dwóch punktów może okazać się niewystarczająca. W takim przypadku jakość korekcji jest maksymalna w punktach kalibracji. Zgodnie z pracą [10], pojawiające się zakłócenie o stałej charakterystyce będzie tym wyraźniejsze, im większa będzie różnica między radiacją wzorca kalibracyjnego, a radiacją, emitowaną przez obserwowane obiekty. Problem ten w szczególności dotyczy kamer, które mają służyć do akwizycji szerokiego spektrum promieniowania elektromagnetycznego.

Dzieła literaturowe zawierają opisy implementacji sprzętowych, realizujących korekcję niejednorodności metodą dwóch punktów. Projektanci tego typu rozwiązań bazują na wstępnie przygotowanych danych kalibracyjnych, które następnie są używane do korekcji odczytów, niezależnie dla każdego z mikrobolometrów, wchodzących w skład matrycy. Rozwiązania tego typu opierają się o układy logiki programowalnej z rodziny FPGA oraz dedykowane zewnętrzne pamięci RAM (ang. *Random Access Memory*), w których przechowywane są dane kalibracyjne. Znane sprzętowe realizacje tego typu rozwiązań zostały zaproponowane w pracach [76], [72], [46] i [6].

Implementacja sprzętowa, zaproponowana w pracy [76], wyróżnia się dodatkowo korekcją martwych pikseli w obrazie.

W publikacji [6] opisano dodatkowo sprzętową realizację procesu kalibracji, opartego o zastosowanie żarówki wolframowej o regulowanej jasności, która była wykorzystywana jako wzorzec kalibracyjny. Zgodnie z tym rozwiązaniem,

podczas aktualizacji danych kalibracyjnych kamera musi być przestawiana w specjalny tryb działania, dedykowany kalibracji.

2.2.1.3. Metoda wielu punktów

Relatywnie skomplikowaną metodą kalibracyjną jest metoda wielu punktów (ang. *Multiple-Point Non-Uniformity Correction, MP-NUC*). Rozszerza ona podejście, zastosowane w metodzie dwóch punktów, o zastosowanie więcej niż dwóch wzorców kalibracyjnych. Zgodnie z pracą [46], metoda ta polega na częściowo liniowym przybliżeniu charakterystyki odpowiedzi mikrobolometru, poprzez wyznaczenie wielu jej punktów odniesienia (pomiarów wzorców) i przybliżenie jej łamaną, na którą składają się fragmenty prostych, przechodzące przez sąsiednie punkty pomiarowe i ograniczone tymi punktami. Punkty pomiarowe charakterystyk są dobierane w taki sposób, by pokrywały spektrum radiacji, do którego obserwacji ma być przeznaczona kamera. Następnie, dla każdego liniowego fragmentu, wyznaczane są osobne parametry korekcyjne, które sprowadzają tworzącą go prostą do przyjętej docelowej charakterystyki liniowej. Wybór parametrów korekcji jest uzależniony od mierzonej wartości wyjściowej z mikrobolometru. Metoda wielu punktów znajduje szczególne zastosowanie w kamerach, w których zachodzi konieczność zapewnienia możliwości obserwacji szerokiego spektrum promieniowania elektromagnetycznego, a także, gdy charakterystyki odpowiedzi mikrobolometrów, wchodzących w skład matrycy wykazują nieliniowości. Zgodnie z pracami [10], [34] i [47], szanse na obserwację nieliniowości charakterystyk odpowiedzi mikrobolometrów wzrastają wraz ze wzrostem docelowego zakresu rejestrowanego promieniowania elektromagnetycznego. Wadą podejścia jest utrudnienie procesu pomiarowego, a także zwiększenie obciążenia obliczeniowego i pamięciowego docelowego rozwiązania.

2.2.1.4. Variable Integration Time

W pracy [86] zawarto szczegółowy opis charakterystyki odpowiedzi mikrobolometru, uwzględniający parametry, wynikające z właściwości fizycznych mikrobolometrów, optyki kamery i obserwowanego źródła radiacji:

$$Y_{ij} = \left\{ \tau_0 T_{int} \int_{\lambda_1}^{\lambda_2} L(\lambda, T_{ij}) \eta_{ij}(\lambda) d\lambda \right\} A_{ij} \Omega_{ij} + D_{ij}, \quad (2.3)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

Y_{ij} – wskazanie sensora,

τ_0 – przepuszczalność układu optycznego,

T_{int} – czas integracji mikrobolometru,

λ – długość fali elektromagnetycznej optyczny,

λ_1, λ_2 – ograniczenie górne i dolne długości fal filtrowanych przez układ optyczny,

$L(\lambda, T_{ij})$ – luminancja widmowa źródła o temperaturze T_{ij} ,

η_{ij} – wydajność kwantowa piksela,

A_{ij} – powierzchnia aktywna piksela,

Ω_{ij} – kąt bryłowy, widziany przez mikrobolometr,

D_{ij} – błąd zera mikrobolometru.

Kąt bryłowy mikrobolometru Ω_{ij} , występujący w równaniu (2.3), jest zależny od optyki kamery i wyrażony zależnością:

$$\Omega_{ij} = \frac{\pi \cos^4 \Theta_{ij}}{1 + 4(F/\#)^2}, \quad (2.4)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

$F/\#$ – wartość przysłony okładu optycznego,

Θ_{ij} – kąt pomiędzy osią układu optycznego a linią tworzoną przez środek układu optycznego i piksel matrycy.

Równanie (2.3) uwzględnia także luminancję widmową L źródła promieniowania o temperaturze T_{ij} , wyznaczaną z prawa Plancka, zgodnie z równaniem:

$$L(\lambda, T_{ij}) = \frac{2\Pi c}{\lambda^4 \exp\left(\frac{hc}{\lambda k T_{ij}}\right) - 1}, \quad (2.5)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

λ – długość fali elektromagnetycznej.

T_{ij} – temperatura źródła promieniowania,

h - stała Plancka,

k - stała Boltzmanna,

c – prędkość światła w próżni.

W pracy [86] zwrócono uwagę na liniową zależność charakterystyki odpowiedzi mikrobolometru, opisanej równaniem (2.2), od czasu integracji T_{int} . Parametr ten określa czas akumulacji odpowiedzi z sensora, co składa się na pojedynczy pomiar. Czas integracji T_{int} wpływa bezpośrednio na intensywność otrzymanych wyników. Jego wydłużenie pozwala na akwizycję radiacji o mniejszym natężeniu, jednak wpływa negatywnie na maksymalną możliwą ilość odczytów na sekundę. Ponadto, wydłużenie czasu integracji T_{int} może negatywnie wpływać na szczegółowość obrazu źródła radiacji o wysokim natężeniu, ze względu na możliwość osiągania górnej granicy wartości pikseli w termogramie. Oznacza to istnienie związku pomiędzy czasem integracji matrycy, a dopuszczalnym zakresem temperatur ciała czarnego, wykorzystywanego w procesie kalibracji.

Wpływ czasu integracji T_{int} został wykorzystany w metodzie kalibracji matryc bolometrycznych, zaproponowanej w pracy [86]. Możliwość zastosowania tej metody jest warunkowana możliwością regulacji czasu integracji matrycy. Autorzy metody wskazują, że odpowiednikiem zmiany wielkości wejściowej radiacji elektromagnetycznej, może być modyfikacja czasu integracji sensora, przy zapewnieniu braku zmienności w obserwowanej scenie. Na tej podstawie proponują oni realizację akwizycji termogramów dla dwóch różnych czasów integracji T_{int} . W celu eliminacji zakłóceń temporalnych, w pracy [81] zaproponowano uśrednienie pomiarów dla wielu klatek sekwencji wideo. Uzyskane pomiary są wykorzystywane do estymacji wzmocnienia A_{ij} i błędu zera B_{ij} charakterystyki mikrobolometru (2.1), zgodnie z zależnościami:

$$\hat{A}_{ij} = \frac{I_{2ij} - I_{1ij}}{E[I_2] - E[I_1]}, \quad (2.6)$$

$$\hat{B}_{ij} = I_{1ij} \quad (2.7)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

I_1 – obraz uzyskany z krótszym czasem integracji,

I_2 – obraz uzyskany z dłuższym czasem integracji,

I_{1ij} – wartość piksela obrazu uzyskanego z krótszym czasem integracji,

I_{2ij} – wartość piksela obrazu uzyskanego z dłuższym czasem integracji,

$\hat{A}_{ij}$ – estymowane wzmocnienie mikrobolometru,

$\hat{B}_{ij}$ – estymowany błąd zera mikrobolometru.

Zastosowanie wyznaczonych parametrów wzmocnienia (2.6) i błędu zera (2.7) w charakterystyce odpowiedzi mikrobolometru (2.1), przy założeniu braku występowania zakłóceń pomiarowych, pozwala na estymację wartości, reprezentującej promieniowanie, padające na sensor:

$$\hat{X}_{ij} = \frac{Y_{ij} - \hat{B}_{ij}}{\hat{A}_{ij}}, \quad (2.8)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

$\hat{X}_{ij}$ – estymowana wartość, reprezentująca promieniowanie, padające na sensor,

$\hat{A}_{ij}$ – estymowane wzmocnienie mikrobolometru,

$\hat{B}_{ij}$ – estymowany błąd zera mikrobolometru.

Wpływ zmian czasu integracji T_{int} stanowi także podstawę rozważań na temat metod kalibracyjnych i samego procesu kalibracji. Ze względu na liniowy wpływ czasu integracji na czułość matrycy, pojedynczy zestaw danych kalibracyjnych, szczególnie dla kamer, służących do pomiaru temperatury, może być uznawany za właściwy tylko dla konkretnego czasu integracji T_{int} . Spostrzeżenie to potwierdzają autorzy dzieł literaturowych. W oparciu o wpływ tego parametru w pracy [43] zaproponowano rozwinięcie metody dwóch punktów, o wielokrotnienie procesu kalibracji dla różnych nastaw czasu integracji. W pracach [34] i [49] opisano podobne podejście w kalibracji metodą wielu punktów. Zaproponowane w przytoczonych publikacjach podejście pozwala na płynną regulację czasu integracji T_{int} matrycy, w zależności od warunków, panujących w obserwowanym otoczeniu (np. zakresu obserwowanych wartości promieniowania).

Algorytm korekcji niejednorodności, oparty o zmienny czas integracji T_{int} matrycy, został zrealizowany w formie implementacji sprzętowej, opisanej w pracy [81]. Dane z matrycy, odczytywano z wykorzystaniem 14-bitowego przetwornika analogowo-cyfrowego. Metoda *Variable Integration Time* wymaga przetworzenia wielu klatek wideo, w celu redukcji zakłóceń temporalnych. Podczas akwizycji wideo uśredniane było 8 poprzednich klatek obrazu.

Gromadzono je w zewnętrznej pamięci, dedykowanej do przechowywania ramek. Podczas kalibracji kamera wymagała przełączania w specjalny tryb działania. Kontrola czasu naświetlania matrycy była realizowana poprzez implementację sprzętową, zrealizowaną w układzie FPGA. Parametry korekcyjne (wzmocnienia i błąd zera) były przechowywane w dedykowanej pamięci. Uzyskane parametry korekcyjne były cyklicznie przeładowywane, odpowiednio do aktualnego piksela, odczytanego z matrycy i wykorzystywane do jego natychmiastowej korekcji. Zgodnie z opisem, do korekcji wymagane było zastosowanie pojedynczego układu mnożącego i pojedynczego układu sumatora, co korzystnie wpływało na minimalizację czasu przetwarzania.

2.2.1.5. Alternatywne wzorce odniesienia, stosowane w metodach kalibracyjnych

Często stosowanym wzorcem kalibracyjnym, wykorzystywanym w metodach kalibracyjnych, jest ciało czarne. Jednak, jak wspomniano w pracy [14], jego zastosowanie wiąże się z nakładem czasowym i kosztami finansowymi, związanymi z procesem badań laboratoryjnych. Ponadto, nie zawsze możliwe jest umieszczenie kamery w laboratorium, np. kiedy kamera znajduje się na orbicie okołoziemskiej, co zostało opisane w pracach [39], [45] i [51]. Wśród znanych rozwiązań literaturowych można natrafić na propozycje, których celem jest optymalizacja procesu kalibracji, ze względu na zastosowany wzorzec odniesienia.

W publikacji [14] zaproponowano rozwiązanie, pozwalające na wykorzystanie pojedynczego wzorca odniesienia w metodzie dwóch punktów. Twórcy rozwiązania opisują wyniki użycia do tego celu dedykowanej przysłony obiektywu. Przysłona jest zaprojektowana w taki sposób, aby jej umieszczenie nie zmieniało równomierności oświetlenia mikrobolometrów matrycy, natomiast wpływało na zredukowanie intensywności radiacji, padającej na mikrobolometry. Dzięki takiemu zastosowaniu, przy zachowaniu niezmiennego czasu integracji,

możliwe jest uzyskanie danych kalibracyjnych dla dwóch punktów charakterystyki odpowiedzi mikrobolometru.

Kolejne alternatywne podejście do wzorca odniesienia zaprezentowano w pracy [28]. Autorzy opisują w niej zastosowanie komory termicznej w procesie kalibracji. Badana przez twórców kamera termowizyjna była w procesie kalibracji zamknięta w komorze termicznej. Podobne rozwiązanie, oparte o regulację temperatury zewnętrznej, opisano w pracy [16]. W obu publikacjach uzyskane wyniki miały na celu umożliwienie wyprowadzenia zależności parametrów kalibracyjnych od temperatury zewnętrznej.

W pracy [47], jak również pracy [32], zawarto opis zastosowania obrazów bezchmurnego nieba w korekcji niejednorodności. Opisywany przez autorów problem dotyczy systemu namierzania i śledzenia obiektów (ang. *InfraRed Search and Track,IRST*), znajdujących się w przestrzeni powietrznej. Zauważają oni, że w detektorach podczerwonych znaczący wpływ na jakość wyników korekcji mają temperatury wzorca odniesienia. Temperatura otoczenia obiektu, czyli powietrza, zmienia się wraz z wysokością. W takich warunkach obserwacyjnych, ze względu na nieliniowości odpowiedzi mikrobolometrów i znaczne różnice temperatur wzorca laboratoryjnego i nieba, kalibracja laboratoryjna może powodować trudności w identyfikacji obiektu. Autorzy proponują rozwiązanie, oparte o właściwość atmosfery, jaką stanowi gradientowy spadek temperatury powietrza wraz z wysokością. Przy zapewnieniu odpowiedniej optyki obiektywu (długa ogniskowa), warunków atmosferycznych (relatywnie niskie zachmurzenie) oraz poziomego ułożenia matrycy, możliwe jest uzyskanie dwóch scen referencyjnych, które będą reprezentowały dwa punkty kalibracyjne (wartości średnie poziomów szarości obu scen) dla każdego z mikrobolometrów, wchodzących w skład matrycy. Metoda jest zależna od warunków atmosferycznych, w szczególności od poziomu zachmurzenia i opadów, jednak należy pamiętać o wysokiej przenikalności fal podczerwonych, co zwiększa prawdopodobieństwo uzyskania dobrych wyników kalibracji.

Kolejnym alternatywnym wzorcem odniesienia, opisanym w pracy [6], jest regulowane źródło radiacji, oparte o żarnik wolframowy (promiennik lub żarówka). Zgodnie z propozycją, źródło promieniowania było wykorzystywane do pobudzenia matrycy sygnałem o wysokiej i niskiej intensywności radiacji cieplnej. Uzyskane dane wykorzystywane były w kalibracji metodą dwóch punktów. Rozwiązanie zostało przez autorów przetestowane w implementacji sprzętowej.

Regulowane źródło radiacji podczerwonej zostało także wykorzystane przez autorów pracy [39], w celu przeprowadzania kalibracji kamery linikowej, umieszczonej w przestrzeni kosmicznej, na podstawie źródła o modulowanej radiacji, wkomponowanego w system optyczny.

2.2.2. Metody bazujące na analizie sceny

Kolejną klasę metod, których celem jest korekcja niejednorodności termogramu stanowią metody, bazujące na analizie sceny (ang. *Scene-Based Non-Uniformity Correction, SB-NUC*). Ich zasada działania polega na przechwytywaniu i analizie dyskretnych szeregów czasowych, będących ciągami równoodległych w czasie próbek, uzyskanych ze strumienia wideo, rejestrowanego przez matrycę. Metody z tej klasy bazują na proponowanych przez autorów założeniach, będących pewną dodaną informacją, dotyczącą warunków pracy kamery lub specyfiki sekwencji próbek. Dlatego też sposób określenia tych zależności oraz wysnucie odpowiednich założeń stanowi istotny problem badawczy.

Zaletą metod, bazujących na analizie sceny, jest potencjał adaptacji do zmiennych warunków pracy kamery. Wynika on z faktu, że metody tej klasy można stosować w dowolnym momencie pracy urządzenia. W ten sposób można regularnie aktualizować parametry korekcji, w znacząco mniejszym horyzoncie czasowym niż w przypadku metod kalibracyjnych, które wymagają zastosowania wzorca laboratoryjnego, a także zapewnienia stabilnych warunków pracy kamery

(temperatury matrycy). Ze względu na możliwość relatywnie szybkiej aktualizacji parametrów korekcyjnych, metody te pozwalają na eliminację negatywnych efektów, wynikających ze zmiennych warunków pracy kamery, takich jak dryf temperaturowy parametrów charakterystyk mikrobolometrów. Jednak, aby możliwa była cykliczna adaptacja metody bazującej na analizie sceny, w czasie pobierania danych aktualizacyjnych muszą zajść dwa warunki: relatywnie niska zmienność temperatury otoczenia względem częstotliwości aktualizacji parametrów korekcyjnych oraz wysoka zmienność mierzonego sygnału z matrycy (klatek wideo, wartości pikseli). Dlatego niepożądanym efektem, który może zmniejszyć dokładność metod z opisywanej grupy jest szybka zmiana warunków otoczenia lub matrycy (np. nagłe zabrudzenie matrycy, gwałtowna zmiana temperatury) oraz brak wymaganego poziomu zmienności w obrazie, uzyskanym z kamery. Zmienność w obrazie może wynikać ze zmiany radiacji podczerwonej, emitowanej przez obiekty w obserwowanej scenie lub ich przemieszczenie w płaszczyźnie obrazowej. Każdy element obrazu, który jest statyczny w czasie próbkowania może zostać błędnie oceniony jako zakłócenie o stałej charakterystyce i skorygowany. Efekt ten może się objawiać poprzez kompensację z obrazu istotnych elementów obserwowanego otoczenia. Jak wspomniano w pracy [75], taka kompensacja skutkuje efektem powidoku (ang. *ghosting*). Powidok objawia się występowaniem artefaktów w obrazie, posiadających wygląd uprzednio błędnie zidentyfikowanych jako zakłócenie o stałym wzorcu (FPN), a następnie skompensowanych, statycznych obiektów w sekwencji wideo.

Wadą metod, bazujących na analizie sceny jest brak deterministycznego efektu ich działania. Korekcja niejednorodności polega w tym przypadku na ujednoliceniu charakterystyk wszystkich sensorów, wchodzących w skład matrycy, natomiast nie polega na sprowadzeniu danych pomiarowych z matrycy bolometrycznej do wartości, reprezentującej wielkość fizyczną. Ze względu na brak wzorca odniesienia, metody tego typu zakładają prawdziwość

charakterystyki jednego z sensorów, natomiast pozostałe sensory matrycy są kalibrowane tak, aby działały zgodnie z charakterystyką sensora wiodącego. Sprawia to, że wynik działania metody może być nieprzewidywalny – kilkakrotnie przeprowadzona kalibracja może dać różne wyniki w kontekście parametrów korekcyjnych każdego sensora, gdyż nie istnieje jedno rozwiązanie, które można by uznać za prawdziwe. Ze względu na brak zastosowania znanego wzorca, metody klasy SB-NUC nie pozwalają na dokładny pomiar temperatur obiektów w obserwowanej scenie.

Kolejną wadą opisywanego podejścia jest złożoność obliczeniowa. W odróżnieniu od metod kalibracyjnych, dla których korekcja odbywa się z wykorzystaniem uprzednio przygotowanych danych tablicowych, metody bazujące na analizie sceny mogą wymagać algorytmicznej aktualizacji zmiennych parametrów charakterystyk każdego z sensorów, wchodzących w skład matrycy. Oznacza to konieczność zastosowania układów obliczeniowych zdolnych podołać temu zadaniu. Przekłada się to na większe zużycie energii elektrycznej. Jednak, ze względu na potencjał adaptacyjności, pozwala to także na eliminację układów regulacji temperatury matrycy, co z kolei może okazać się czynnikiem zmniejszającym pobór energii elektrycznej przez docelowe urządzenie. Wśród znanych metod, bazujących na analizie sceny warto wyróżnić kilka podklas, obejmujących: metody oparte o filtrację, metody statystyczne, metody rejestracyjne oraz metody, bazujące na zastosowaniu sieci neuronowych. Podklasy te zostały opisane w kolejnych podpunktach, wraz z przykładowymi metodami korekcji, znanymi z dzieł literaturowych.

2.2.2.1. Metody bazujące na sieciach neuronowych

Zastany stan literatury zawiera propozycję metod, bazujących na analizie sceny, opartych o zastosowanie sztucznych sieci neuronowych. Wybrane metody tego typu zostały opisane w kolejnych podpunktach.

2.2.2.1.1. Neural Network Non-Uniformity Correction

Podejście, rozwijane w wielu pozycjach literaturowych zostało zaproponowane w pracach [70] i [91]. Opisano w nich zastosowanie sieci liniowo scharakteryzowanych neuronów, inspirowanej siatkówką oka. Neurony takiej sieci zawierają informację o korekcyjnym wzmocnieniu (waga sygnału wejściowego neuronu) i błędzie zera (bias neuronu) obserwowanych odpowiedzi z sensorów. Odczyt z matrycy jest sygnałem wejściowym neuronu, natomiast wartość sygnału wyjściowego sieci można opisać równaniem:

$$\hat{X}_{ij}(n) = \hat{g}_{ij}(n) * Y_{ij}(n) + \hat{o}_{ij}(n), \quad (2.9)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

$Y_{ij}(n)$ – mierzony sygnał wejściowy,

$\hat{X}_{ij}(n)$ – skorygowany odczyt,

$\hat{g}_{ij}(n)$ – waga neuronu,

$\hat{o}_{ij}(n)$ – bias neuronu.

Równanie (2.9) zawiera parametry korekcyjne wagi $\hat{g}_{ij}(n)$ i biasu $\hat{o}_{ij}(n)$ neuronu, a ich związek z charakterystyką mikrobolometru, opisaną równaniem (2.1), wyraża się równaniami:

$$\hat{g}_{ij}(n) = \frac{1}{\hat{A}_{ij}(n)}, \quad (2.10)$$

$$\hat{o}_{ij}(n) = -\frac{\hat{B}_{ij}(n)}{\hat{A}_{ij}(n)}, \quad (2.11)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

$\hat{A}_{ij}$ – estymowane wzmocnienie mikrobolometru,

$\hat{B}_{ij}$ – estymowany błąd zera mikrobolometru.

Wagi neuronów są aktualizowane w czasie rejestracji strumienia wideo z matrycy, z wykorzystaniem metody najszybszego spadku, w celu minimalizacji błędu, określonego przez funkcję kosztów:

$$E_{ij}(n) = [\hat{X}_{ij}(n) - T_{ij}(n)]^2, \quad (2.12)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

$\hat{X}_{ij}$ – skorygowany odczyt,

$T_{ij}(n)$ – oczekiwana wartość zmierzonego sygnału.

Z racji tego, że oczekiwana wartość zmierzonego sygnału $T_{ij}(n)$ jest często nieznana, jako jej miarę przyjmuje się średnią arytmetyczną odczytanych wartości wyjściowych mikrobolometrów w otoczeniu badanego piksela matrycy.

Na podstawie funkcji kosztów oraz parametru, definiującego szybkość uczenia sieci, aktualizowane są wagi i biasy każdego z neuronów sieci, zgodnie z równaniami:

$$\hat{g}_{ij}(n+1) = \hat{g}_{ij}(n) - \eta * E_{ij}(n) * Y_{ij}(n), \quad (2.13)$$

$$\hat{o}_{ij}(n+1) = \hat{o}_{ij}(n) - \eta * E_{ij}(n), \quad (2.14)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

$E_{ij}(n)$ – wartość funkcji kosztów,

$Y_{ij}(n)$ – mierzony sygnał wejściowy,

$\hat{g}_{ij}(n)$ – waga neuronu,

$\hat{o}_{ij}(n)$ – bias neuronu,

η – szybkość uczenia sieci.

Obecny w równaniach (2.13) i (2.14) parametr szybkości uczenia sieci η ma istotne znaczenie dla jakości wyników kalibracji. Zgodnie z pracą [36], zbyt niska wartość nastawy powoduje wolne tempo zbieżności wyników korekcji, a w konsekwencji brak nadążania za zmiennością parametrów charakterystyk mikrobolometrów matrycy. Natomiast zbyt wysoka szybkość aktualizacji nastaw powoduje, że elementy statyczne sceny są kompensowane jako zakłócenie o stałej charakterystyce, co powoduje powstanie efektu powidoku w otrzymanym obrazie. Efekt ten jest okazał się być na tyle znaczący, że stał się podstawą badań, podejmowanych przez wielu badaczy tematyki. Znane rozwinięcia metody dotyczą sposobu realizacji procesu uczenia sieci. Celem badaczy jest przede wszystkim redukcja zjawiska powidoku, przy zachowaniu wysokiego tempa zbieżności i jakości korekcji niejednorodności. Ogół rozwiązań, proponowanych przez autorów tego typu rozwiązań skupia się przede wszystkim na modyfikacjach procesu uczenia sieci, obejmującego algorytmy oceny jakości uzyskanych wyników oraz na zapobieganiu sytuacji, promujących powstawanie powidoku.

Rozważania nad poprawieniem zbieżności parametrów sieci podjęto w pracy [89]. W publikacji opisano trzy propozycje poprawy jakości procesu uczenia. Obejmują one modyfikacje sposobu aktualizacji wag i błędów zera (bias) neuronów. Pierwsza propozycja obejmuje wprowadzenie addytywnego składnika do równania (2.13), zgodnie z równaniem:

$$\hat{g}_{ij}(n+1) = \hat{g}_{ij}(n) - \eta * E_{ij}(n) * Y_{ij}(n) + \lambda \left(1 - \frac{1}{NM} \sum_{k=1}^N \sum_{l=1}^M \hat{g}_{kl}(n) \right), \quad (2.15)$$

gdzie:

ij, kl – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

$E_{ij}(n)$ – wartość funkcji kosztów,

$Y_{ij}(n)$ – mierzony sygnał wejściowy,

$\hat{g}_{ij}(n)$ – waga neuronu,

η – szybkość uczenia sieci,

λ – poziom istotności addytywnego składnika,

N – ilość wierszy matrycy,

M – ilość kolumn matrycy.

Addytywny składnik równania (2.15) pozwala na unifikację wzmocnień wszystkich neuronów, poprzez uwzględnienie nastaw całej matrycy.

Kolejną propozycją, zawartą w pracy [89], obejmuje zastosowanie w procesie uczenia metody momentum:

$$\hat{g}_{ij}(n+1) = \hat{g}_{ij}(n) - \eta * E_{ij}(n) * Y_{ij}(n) + \alpha (\hat{g}_{ij}(n) - \hat{g}_{ij}(n-1)), \quad (2.16)$$

$$\hat{o}_{ij}(n+1) = \hat{o}_{ij}(n) - \eta * E_{ij}(n) + \alpha (\hat{o}_{ij}(n) - \hat{o}_{ij}(n-1)), \quad (2.17)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

$E_{ij}(n)$ – wartość funkcji kosztów,

$Y_{ij}(n)$ – mierzony sygnał wejściowy,

$\hat{g}_{ij}(n)$ – waga neuronu,

$\hat{o}_{ij}(n)$ – bias neuronu,

η – szybkość uczenia sieci,

α – parametr zapominania.

Równania (2.16) i (2.17) opisują sposób wprowadzenia do procesu uczenia bezwładności, uwzględniającej poprzednie zmiany wartości wag $\hat{g}_{ij}(n)$ i biasów

$\hat{o}_{ij}(n)$ neuronów. Zwiększa to odporność algorytmu na osiągnięcie minimum lokalnego.

Trzecia modyfikacja procesu uczenia, zaproponowana w pracy [89], obejmuje sposób wyznaczania parametru szybkości uczenia sieci:

$$\eta_{ij}(n) = K * \frac{1}{1 + \sigma_{Y_{ij}(n)}^2}, \quad (2.18)$$

gdzie:

ij – współrzędne sensora na matrycy,

n – numer próbki,

$Y_{ij}(n)$ – wskazanie sensora,

$\eta_{ij}(n)$ – szybkość uczenia sieci,

$\sigma_{Y_{ij}(n)}^2$ – wariancja wartości mierzonych w otoczeniu mikrobolometru ij ,

K – stała regulująca szybkość procesu uczenia.

Równanie (2.18) opisuje sposób adaptacji parametru szybkości uczenia sieci $\eta_{ij}(n)$, do zmienności sygnału wejściowego w danej próbce, w pewnym otoczeniu wokół badanego piksela.

Zgodnie z pracą [53], artefakty, związane ze zjawiskiem powidoku, są zorientowane głównie w fragmentach obrazu, w których występują krawędzie obiektów. Wynika to z przyjęcia w funkcji kosztów (2.12) wartości referencyjnej $T_{ij}(n)$ równej średniej arytmetycznej wartości pikseli, w pewnym otoczeniu wokół badanego piksela. To założenie jest słuszne w obszarach jednorodnych, lecz nie jest właściwe w przypadku występowania detali i krawędzi w obrazie. Praca [80] zawiera opis rozwiązania tego problemu. Obejmuje ono zastosowanie filtracji bilateralnej w procesie uczenia, oszczędzającej krawędzie obiektów. Zasada działania filtru bilateralnego została opisana w dodatku B. Do tego samego problemu odnoszą się także autorzy pracy [50], proponując w swojej publikacji zastosowanie filtru *Guided Filter* (GF), także oszczędzającego krawędzie. Filtr GF

został zaproponowany w pracy [30], jako alternatywa filtru bilateralnego. Zasada działania filtru GF została opisana w dodatku C.

Detekcja krawędzi i zastosowanie jej wyników w procesie uczenia stanowi także myśl przewodnią rozwiązania, przedstawionego w pracy [71]. Zawiera ono mechanizm detekcji krawędzi, którego wynikiem jest zbinaryzowana informacja o krawędziach w obrazie. Zgodnie z pracą [42], zarówno w przypadku zastosowania filtru bilateralnego, jak i w przypadku detekcji krawędzi, zaproponowanej w pracy [71], algorytmy te wymagają zastosowania relatywnie trudnej w doborze wartości progowej.

Publikacja [79] zawiera opis sposobu poprawy jakości uzyskanych wyników i zbieżności procesu uczenia, poprzez wyznaczanie korelacji temporalnych i przestrzennych pomiędzy kolejnymi klatkami sekwencji wideo. Rozwiązanie pozwala na uwzględnienie ruchu obiektów i detekcję krawędzi w obrazie.

Inne podejście do redukcji powidoku, powodowanego przez krawędzie obiektów, zaproponowano w pracy [77]. Opisane tam rozwiązanie rozwija propozycję według pracy [70], o adaptacyjną weryfikację stabilności parametrów statystycznych sygnału błędu. Analizowane parametry statystyczne obejmowały wartość oczekiwaną i odchylenie standardowe. Jeżeli wartość bezwzględna różnicy błędu i jego wartości oczekiwanej znacząco przekraczała wartość odchylenia standardowego, to pomiar nie uczestniczył w procesie uczenia, co korzystnie wpływało na redukcję zjawiska powidoku.

Czynnikiem promującym występowanie powidoku są sytuacje, gdy sekwencja wideo pochodzi z obserwacji statycznej sceny, w wyniku czego obserwowane obiekty mogą być klasyfikowane jako zakłócenie o stałej charakterystyce i adaptacyjnie korygowane z obrazu. Rozwiązanie tego problemu zostało zaproponowane w pracy [48]. Zaproponowano w niej sposób wyłączania aktualizacji parametrów neuronów, w sytuacjach, gdy obserwowana scena jest statyczna. Metoda jest oparta o analizę temporalną próbek sygnału wejściowego neuronu. Zgodnie z publikacją [42] znalazła ona szerokie zastosowanie, jednak

zawodzi w sytuacjach, gdy matryca służy do obserwacji statycznej sceny, w której występuje migotanie lub inne temporalne fluktuacje sygnału wejściowego. Rozwiązanie tego problemu, zostało zaproponowane w pracy [13]. Autorzy publikacji rozszerzyli analizę temporalną o analizę przestrzenną sygnału wejściowego w otoczeniu badanego piksela. Jednak, jak wskazano w pracy [42], rozwiązanie to jest również podatne na występowanie zakłóceń, w tym przypadku zakłóceń przestrzennych, szumów w obrazie. W publikacji zwrócono uwagę na fakt, że utrudnia to dobór wartości progowych, powodujących modyfikację szybkości uczenia, zarówno w przypadku progowania opartego o analizę przestrzenną, jak i analizę temporalną. W pracy zaproponowano rozwiązanie, w którym ograniczenie procesu uczenia jest realizowane w oparciu o adaptacyjnie dobierane wartości progowe parametrów przestrzennych i temporalnych. Ponadto, zaproponowano sposób ich wyznaczania, oparty o wykrywanie krawędzi w dwóch prostopadłych kierunkach, przy pomocy operatora Sobela oraz progowanie temporalne. Zgodnie z pracą [9], adaptacyjne wyznaczanie parametru szybkości uczenia sieci istotnie zwiększa złożoność obliczeniową algorytmu.

Prace [36] i [40] zawierają propozycję zastosowania innego czynnika, regulującego szybkość uczenia sieci, opartego o zastosowanie filtru TV (ang. *Total Variation*) oraz jego bilateralnej adaptacji BTV (ang. *Bilateral Total Variation*), uwzględniającej krawędzie podczas przetwarzania. Ponadto, autorzy proponują własny sposób adaptacyjnego nastawiania współczynnika szybkości uczenia sieci, bazujący na analizie przestrzennej i temporalnej.

W celu umożliwienia szybkiej reakcji nastaw sieci neuronowej na zmiany czasu integracji matrycy, autorzy pracy [66] zaproponowali hybrydowe rozwiązanie, oparte o sztuczną sieć neuronową i adaptację metody *Variable Integration Time*, opisaną w podpunkcie 2.2.1.4. Poprzez kalibracyjne wyznaczenie zależności wzmocnień i błędów zera mikrobolometrów od czasu integracji, możliwa jest wstępna korekcja niejednorodności matrycy. Parametry

matrycy są w kolejnym etapie dalej aktualizowane, zgodnie z metodą, opartą o zastosowanie sztucznych sieci neuronowych.

Znane realizacje sprzętowe z grupy rozwiązań, opartych o sztuczne sieci neuronowe, zostały zaproponowane w pracach [69], [50] i [5].

Implementacja, opisana w publikacji [69], wykorzystuje sieć neuronową w celu aktualizacji parametrów korekcji oraz nie wymaga osobnego procesu kalibracji. Implementacja sprzętowa, zrealizowana w układzie FPGA, była w stanie przetwarzać dane o rozdzielczości 320x240 pikseli z częstotliwością do 131 klatek na sekundę.

Metody, oparte o zastosowanie sztucznych sieci neuronowych, wykorzystują w procesie uczenia wartość referencyjną, wyznaczaną na podstawie danych pomiarowych z otoczenia badanego piksela matrycy. Implementacja, opisana w pracy [69], wykorzystuje do jej wyznaczania średnią arytmetyczną wartości pikseli. W pracy [50] opisano implementację sprzętową, w której, do wyznaczania wartości referencyjnej, wykorzystany został oszczędzający krawędzie filtr *Guided Filter*, opisany w dodatku C. Zgodnie z publikacją, implementacja, dla termogramów o rozdzielczości 256x256 pikseli, była w stanie osiągnąć wydajność na poziomie 180 klatek na sekundę.

W pracy [5] także zawarto opis sprzętowej implementacji, zawierającej modyfikację procesu uczenia sieci, opisaną w pracy [42]. W implementacji zastosowano metodę adaptacji szybkości uczenia sieci, realizowaną w oparciu o algorytm detekcji krawędzi i regulowane progowanie temporalne. Rozwiązanie było testowane dla termogramów o rozdzielczości 324x256 pikseli.

2.2.2.1.2. Konwolucyjne sieci neuronowe

Wraz ze wzrostem rozdzielczości matrycy rośnie złożoność sieci neuronowej w postaci, opisanej w podpunkcie 2.2.2.1.1. W związku z tym faktem autorzy rozwiązań literaturowych wysuwają wiele propozycji, opartych o zastosowanie konwolucyjnych sieci neuronowych (ang. *Convolutional Neural Network, CNN*).

Konwolucyjne sieci neuronowe nie przypisują neuronów do każdego z pikseli, ale bazują warstwach splotowych, realizujących dyskretny splot obrazu z maską (ang. *kernel*), dostrajaną w procesie uczenia. Filtracja pozwala na ekstrakcję cech, na podstawie których w kolejnych warstwach sieci z obrazu wydobywana jest informacja o zakłóceniu o stałej charakterystyce. Dzięki temu zastosowaniu optymalizowana jest ilość parametrów sieci. Sieci konwolucyjne znajdują szerokie zastosowanie w przetwarzaniu obrazów, także tych, pochodzących z matryc mikrobolometrycznych. Autorzy publikacji [4], [9], [11] i [23] skupiają się przede wszystkim na postaci sieci neuronowej, obejmującej rodzaj i układ warstw sieci, a także sposobu filtracji danych w ramach sieci neuronowej, co opisano w pracy [12].

2.2.2.2. Metody oparte o filtrację

Wśród znanych rozwiązań literaturowych, osobną podgrupę metod, bazujących na analizie sceny, stanowią metody, implementujące szeroko pojętą filtrację sygnału dyskretnego, pochodzącego z matrycy. Ze względu na sposób działania, do tej grupy można by także zaliczyć metody, oparte o zastosowanie konwolucyjnych sztucznych sieci neuronowych, opisane w podpunkcie 2.2.2.1.2, jednak metody z tej kategorii często zawierają dodatkowe etapy przetwarzania, jak zwiększenie rozdzielczości obrazu (ang. *super-resolution*), co wynika z pracy [57]. Filtracja, w zależności od propozycji, może być realizowana w różnie zdefiniowanych wymiarach odniesienia, takich jak oś czasu (filtracja temporalna), czy płaszczyzna matrycy (filtracja przestrzenna). Sposób realizacji filtracji, a także dobór parametrów zastosowanych filtrów stanowi wyzwanie, podejmowane przez badaczy i twórców tego typu rozwiązań.

2.2.2.2.1. Filtracja temporalna

Cytowaną w pracach [12], [31] i [73] metodą, opartą o filtrację, jest zaproponowana w pracy [83] metoda THPF-NUC (ang. *Temporal High-Pass Filter Non-Uniformity Correction*). Bazuje ona na założeniu, że zakłócenie o stałej

charakterystyce (FPN) zmienia się ze znacznie mniejszą częstotliwością niż obraz, rejestrowany przez matrycę podczerwoną, a wartość wielkości mierzonej z piksela matrycy jest sumą rejestrowanej radiacji i zakłócenia o stałej charakterystyce. Oznacza to, że wynik filtracji dolnoprzepustowej odpowiedzi mikrobolometru powinien stanowić estymatę wolnozmiennnej części sygnału, czyli zakłócenia, wynikającego z niejednorodności matrycy IRFPA. Zgodnie z metodą THPF-NUC korekcja niejednorodności mikrobolometru polega na odjęciu od wielkości mierzonej wyniku jej filtracji, zgodnie z zależnością:

$$\hat{X}_{ij}(n) = Y_{ij}(n) - f_{ij}(n), \quad (2.19)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

$f_{ij}(n)$ – wynik filtracji temporalnej,

$Y_{ij}(n)$ – mierzony sygnał wejściowy,

$\hat{X}_{ij}(n)$ – skorygowany pomiar,

Jako algorytm filtracji temporalnej $f_{ij}(n)$ (równanie (2.19)), w publikacji [83] zaproponowano dolnoprzepustowy filtr IIR (ang. *Infinite Impulse Response*) z oknem, malejącym w sposób eksponencjalny, opisany równaniem:

$$f_{ij}(n) = \frac{1}{M} Y_{ij}(n) + \left(1 - \frac{1}{M}\right) * f_{ij}(n - 1), \quad (2.20)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

$f_{ij}(n)$ – wynik filtracji temporalnej,

$Y_{ij}(n)$ – mierzony sygnał wejściowy,

M – szerokość okna filtracji.

Szerokość okna filtru, opisanego równaniem (2.20), jest zależna od parametru M , który jest rozumiany jako ilość klatek obrazu. Dobór parametru M jest kluczowy dla jakości działania filtracji – zbyt duża wartość powoduje wydłużenie czasu ustalania wyników (zmniejszenie tempa konwergencji wyników), natomiast zbyt mała wartość M powoduje niechcianą redukcję wolno zmieniających się scen, rozpoznawanych błędnie jako zakłócenie o stałej charakterystyce. Zaletą rozwiązania jest jego adaptacyjność i prostota obliczeniowa, natomiast, zgodnie z pracą [31] wadą jest potencjalna kompensacja wolnozmiennych scen, skutkująca efektem powidoku. Metoda THPF-NUC stanowi podwaliny propozycji rozwoju tej tematyki, prezentowanych przez wielu badaczy, opisanych w kolejnych podpunktach.

2.2.2.2.2. Filtracja przestrzenno-temporalna

Rozszerzenie filtracji temporalnej o filtrację przestrzenną, zostało zaproponowane w pracy [7]. Rozwiązanie zostało nazwane SLP-THP-NUC (ang. *Space Low-Pass Temporal High-Pass Non-Uniformity Correction*). Zgodnie z propozycją, podczas filtracji uwzględniany jest także przestrzenny składnik, którego zadaniem jest dolnoprzepustowa filtracja wartości pikseli, w otoczeniu badanego wskazania. Wynik filtracji jest odejmowany od obrazu wejściowego, a następnie filtrowany temporalnie, celem estymacji zakłócenia o stałej charakterystyce.

Metoda SLP-THP-NUC cechuje się nadmiernym rozmyciem krawędzi obiektów w obrazie, co wykazano w pracy [33]. W celu ograniczenia tego zaproponowano zastosowanie w filtracji przestrzennej filtru bilateralnego, oszczędzającego krawędzie obiektów. Filtr bilateralny został opisany w dodatku B. Podobne rozważania przedstawiono w pracy [2], gdzie zaproponowano algorytm, oparty o filtr *Guided Filter*, również oszczędzający krawędzie w obrazie. Zasada działania filtru *Guided Filter*, znanego z pracy [83], została opisana w dodatku C.

Ze względu na podatność metody SLP-THP-NUC, opartej o filtrację, oszczędzającą krawędzie obiektów, na brak przemieszczeń obiektów w obserwowanej scenie, w pracy [59] zaproponowano rozwinięcie metody, zaproponowanej w publikacji [33], o wykrywanie ruchu w obserwowanej scenie, w celu włączania i wyłączania aktualizacji parametrów korekcyjnych. Ponadto, w pracy [59] wskazano na gorsze działanie filtracji bilateralnej w obszarach o wysokiej jasności. W publikacji zawarto propozycję wprowadzenia dodatkowego parametru, którego zadaniem jest spowolnienie tempa aktualizacji parametrów korekcyjnych fragmentów matrycy, pobudzanych radiacją o wysokiej częstotliwości.

2.2.2.2.3. Temporal high-pass based on grayscale mapping

Rozwiązanie podobne do metody SLP-THP-NUC, opisanej w podpunkcie 2.2.2.2.2, zaproponowano w pracy [26]. Przedstawione w tej publikacji rozwiązanie nosi nazwę THP-GM-NUC (ang. *Temporal High-Pass Non-Uniformity Correction based on Grayscale Mapping*). Obejmuje ono algorytm filtracji dolnoprzepustowej, uwzględniający różnicę wartości pikseli w otoczeniu wokół badanego piksela. W pracy [52] zaproponowano dalsze rozwinięcie metody, które nazwano ITHP-GM-NUC (ang. *Improved Temporal High-Pass based on Grayscale Mapping Non-Uniformity Correction*), o zastosowanie logiki rozmytej, do klasyfikacji nieba i ziemi w obserwowanej scenie. Celem detekcji było zwiększenie poziomu rozmycia obrazu dla obserwacji nieba i zmniejszenia utraty detali w obserwacjach obiektów na ziemi.

Rozważania teoretyczne zostały poparte sprzętową implementacją metody, opisaną w pracy [52]. Implementacja została zrealizowana w układzie FPGA. Zawarto w niej wymagane elementy architektury:

- klasyfikator nieba, wykorzystujący logikę rozmytą,
- moduł korekcji niejednorodności, oparty o algorytm filtracji przestrzenno-temporalnej, rozwinięty o adaptacyjny dobór progu detekcji krawędzi.

Rozwiązanie zostało przetestowane z wykorzystaniem termogramów o rozdzielczości 320×256 pikseli. Zgodnie z pracą, dla tych danych osiągnięto wydajność przetwarzania na poziomie 50 klatek na sekundę.

2.2.2.2.4. Filtr Kalmana

Kolejną propozycję z kategorii metod, opartych o filtrację, zaproponowano w pracy [38]. Rozwiązanie oparto o filtr Kalmana. Zgodnie z rozwiązaniem, wzmocnienie i błąd zera każdego z mikrobolometrów, wchodzących w skład matrycy, są traktowane jako zmienne stanu w dyskretnym procesie Gaussa-Markova. W pracy [87] zaproponowano rozszerzenie tej metody filtracji. Zgodnie z publikacją, charakterystyka odpowiedzi mikrobolometru może przyjmować nieliniową postać. W związku z tym faktem podzielili oni charakterystykę odpowiedzi mikrobolometru na pewną ilość segmentów i potraktowali je jako częściowo liniowe.

Zgodnie z [2], metoda filtracji oparta o filtr Kalmana zakłada, że w pojedynczym bloku pomiarowym wszystkie detektory są wystawione na działanie tego samego zakresu radiacji, co może być trudne do osiągnięcia w warunkach rzeczywistych.

Rozwiązanie zostało zrealizowane w implementacji sprzętowej, co zostało opisane w publikacji [84]. W pracy zawarto opis implementacji, opierającej się o dwa układy FPGA. Pierwszy układ pełnił rolę porównawczą. Jego zadaniem był odbiór obrazu z matrycy oraz korekcja niejednorodności metodą dwóch punktów. Ponadto, dane nieskorygowane były przekazywane do drugiego układu FPGA, gdzie realizowany był algorytm filtracji, oparty o filtr Kalmana.

2.2.2.3. Metody statystyczne

Metody statystyczne obejmują rozwiązania, w których próbą badawczą są szeregi czasowe, uzyskane niezależnie z każdego z sensorów, wchodzących w skład matrycy. Następnie, przy pewnych założeniach, proponowanych przez autorów, dokonywana jest analiza statystyczna tych szeregów czasowych.

Pozwala to na dalszą estymację parametrów charakterystyk odpowiedzi każdego z mikrobolometrów, wchodzących w skład matrycy.

2.2.2.3.1. Constant Statistics Non-Uniformity Correction

Jedną z pierwszych, zaproponowanych w literaturze metod statystycznych, jest metoda *Constant Statistics Non-Uniformity Correction* (CS-NUC). Rozważania nad algorytmem zostały zapoczątkowane w pracy [96]. Dotyczyły one jednak jedynie korekcji składowej stałej (błędu zera mikrobolometru). Prace nad metodą były kontynuowane w publikacji [90]. Opisano w niej model matematyczny estymacji wzmocnienia i błędu zera każdego z sensorów, wchodzących w skład matrycy, zgodnie z modelem liniowym charakterystyki odpowiedzi mikrobolometru (2.1). Metoda CS-NUC bazuje na trzech założeniach:

- zakłócenia pomiarowe są eliminowane poprzez filtrację sygnału wejściowego $Y_{ij}(n)$;
- wartość oczekiwana i odchylenie standardowe odpowiedzi każdego z mikrobolometrów są niezmiennie w horyzoncie obserwacji;
- promieniowanie padające na sensor jest zmienną losową o rozkładzie normalnym, charakteryzującym się zerową wartością oczekiwaną i odchyleniu standardowym równym jedności.

Algorytmicznie metoda CS-NUC opiera się o analizę statystyczną sygnału z mikrobolometru, którego charakterystyka odpowiedzi jest zgodna z równaniem (2.1). Wyznaczane parametry statystyczne to wartość oczekiwana i odchylenie standardowe:

$$D[Y_{ij}] = D[A_{ij}X_{ij} + B_{ij} + V_{ij}], \quad (2.21)$$

$$E[Y_{ij}] = E[A_{ij}X_{ij} + B_{ij} + V_{ij}], \quad (2.22)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

Y_{ij} – mierzony sygnał wejściowy,

X_{ij} – promieniowanie, padające na sensor,

V_{ij} – zakłócenia pomiarowe,

A_{ij} – wzmacnienie sensora,

B_{ij} – błąd zera sensora.

Uwzględniając przyjęte założenia oraz korzystając z własności wariancji i odchylenia standardowego, można wyprowadzić estymatory wzmacnienia i błędu zera każdego z sensorów, wchodzących w skład matrycy:

$$A_{ij} = D[Y_{ij}], \quad (2.23)$$

$$B_{ij} = E[Y_{ij}], \quad (2.24)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

Y_{ij} – mierzony sygnał wejściowy,

A_{ij} – wzmacnienie sensora,

B_{ij} – błąd zera sensora.

Wyznaczenie ich wartości pozwala na obliczenie wartości liczbowej, reprezentującej promieniowanie, padające na sensor, wynikającej z charakterystyki mikrobolometru, opisanej równaniem (2.1):

$$X_{ij}(n) = \frac{Y_{ij}(n) - B_{ij}}{A_{ij}}, \quad (2.25)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

Y_{ij} – mierzony sygnał wejściowy,

X_{ij} – skorygowany pomiar,

A_{ij} – wzmacnienie sensora,

B_{ij} – błąd zera sensora.

Ponadto, w publikacji [90] zaproponowano zastosowanie iteracyjnych wzorów do wyznaczania wartości oczekiwanej i średniego odchylenia bezwzględnego, jako estymatora odchylenia standardowego mierzonego sygnału:

$$E[Y_{ij}(n)] = \frac{Y_{ij}(n) + (n-1) \cdot Y_{ij}(n-1)}{n}, \quad (2.26)$$

$$\widehat{D}[Y_{ij}(n)] = \frac{|Y_{ij}(n) - E[Y_{ij}(n)]| + (n-1) \cdot \widehat{D}[Y_{ij}(n-1)]}{n}, \quad (2.27)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

Y_{ij} – mierzony sygnał wejściowy,

$E[Y_{ij}(n)]$ – wartość oczekiwana mierzonego sygnału wejściowego,

$\widehat{D}[Y_{ij}(n)]$ – średnie odchylenie bezwzględne mierzonego sygnału wejściowego.

Zastosowanie iteracyjnego sposobu wyznaczania parametrów statystycznych. przedstawionego na równaniach (2.26) i (2.27) wpływa pozytywnie na możliwość wykorzystania metody w rozwiązaniach sprzętowych, ze względu na minimalizację zużycia pamięci operacyjnej.

W publikacji [90] poruszono także problem zbieżności otrzymanych wyników. Wyprowadzone w niej zależności potwierdzają zbieżność otrzymanych wyników. Zbieżność wartości oczekiwanej, opisanej równaniem (2.26) zależy odwrotnie proporcjonalnie od pierwiastka ilości danych pomiarowych i wprost proporcjonalnie od wariancji sygnału pomiarowego z mikrobolometru. Ponadto, zbieżność odchylenia standardowego, opisanego równaniem (2.27) zależy odwrotnie proporcjonalnie od pierwiastka ilości danych pomiarowych i wprost proporcjonalnie kwadratu wariancji sygnału pomiarowego z mikrobolometru.

Pozwala to na wniosek, że dla dużych wartości odchylenia standardowego sygnału z mikrobolometru może być konieczne przebadanie dużej ilości próbek.

Ponadto, metoda jest silnie zależna od występowania zmienności w sekwencji uzyskanych scen - w sytuacji, gdy wariancja sygnału z mikrobolometru zmierza do zera może powodować zdążanie obliczanej rzeczywistej intensywności promieniowania (2.25) do nieskończoności, co wynika z pracy [2].

2.2.2.3.2. Constant Range Non-Uniformity Correction

Kolejną metodą statystyczną, znaną w literaturze jest metoda *Constant Range Non-Uniformity Correction* (CR-NUC), zaproponowana w publikacji [89]. Podobnie jak w przypadku metody CS-NUC, opisanej w podpunkcie 2.2.2.3.1, metoda bazuje na założeniach, opisujących charakter sygnału odczytanego z mikrobolometru i radiacji, padającej na sensor:

- zakłócenia pomiarowe są eliminowane poprzez filtrację sygnału wejściowego $Y_{ij}(n)$; zakłócenie jest białym szumem gaussowskim, a jego wartość oczekiwana jest równa 0;
- Zmiana w czasie wartości wzmocnienia $A_{ij}(n)$ i błędu zera $B_{ij}(n)$ sensora jest znacznie mniejsza niż zmiany w czasie promieniowania $X_{ij}(n)$ padającego na sensor. Dlatego, w przypadku krótkich czasów próbkowania (do kilku minut, zgodnie z pracą [89]), zakłada się, że ich wartości nie zmieniają się w czasie próbkowania;
- promieniowanie padające na sensor jest zmienną losową o rozkładzie jednostajnym – oznacza to, że w zakresie obserwowanych wartości promieniowania elektromagnetycznego istnieje jednakowe prawdopodobieństwo obserwacji danej długości fali elektromagnetycznej; wartość oczekiwana i wariancja takiego sygnału mogą być wyznaczone z własności rozkładu jednostajnego.

Podobnie jak metoda CS-NUC, metoda CR-NUC polega na analizie statystycznej sygnału z mikrobolometru, którego charakterystyka odpowiedzi jest zgodna z równaniem (2.1). Wyznaczane parametry to wartość oczekiwana i odchylenie standardowe:

$$D[Y_{ij}] = D[A_{ij}X_{ij} + B_{ij} + V_{ij}], \quad (2.28)$$

$$E[Y_{ij}] = E[A_{ij}X_{ij} + B_{ij} + V_{ij}], \quad (2.29)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

Y_{ij} – mierzony sygnał wejściowy,

X_{ij} – promieniowanie, padające na sensor,

V_{ij} – zakłócenia pomiarowe,

A_{ij} – wzmacnienie sensora,

B_{ij} – błąd zera sensora.

W równaniach (2.28) i (2.29) przyjęto liniową charakterystykę odpowiedzi mikrobolometru, opisaną równaniem (2.1). Poprzez analizę wartości oczekiwanej, opisanej równaniem (2.29), i odchylenia standardowego sygnału, opisanego równaniem (2.28) można wyznaczyć wzmacnienie i błąd zera sensora:

$$A_{ij} = \frac{D_{ij}[Y_{ij}]}{D[X]}, \quad (2.30)$$

$$B_{ij} = E[Y_{ij}] - A_{ij}E[X], \quad (2.31)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

A_{ij} – wzmacnienie sensora,

B_{ij} – błąd zera sensora,

$Y_{ij}(n)$ – wskazanie sensora,

X – wartość radiacji, padającej na sensor.

Podobnie jak w przypadku metody CS-NUC, opisanej w podpunkcie 2.2.2.3.1, w rozwinięciu metody CR-NUC zaproponowano zastosowanie wzorów

iteracyjnych do estymacji parametrów statystycznych – wartości oczekiwanej (2.26) oraz średniego odchylenia bezwzględnego (2.27), co opisano w pracy [88].

Dzięki tak skonstruowanemu algorytmowi możliwa jest jego realizacja w ruchomym oknie czasowym. Zapewnia to adaptacyjność metody do temporalnych zmian parametrów charakterystyk sensorów, wchodzących w skład matrycy. Niemniej, zastosowanie ruchomego okna czasowego wymagałoby zastosowania odpowiednio pojemnej pamięci operacyjnej, która przechowywałaby odpowiednio długą historię próbek dla wszystkich sensorów, wchodzących w skład matrycy. Problem rośnie wraz ze wzrostem rozdzielczości matrycy. Zgodnie z pracą [62], rozwiązaniem tego problemu może być zastosowanie dolnoprzepustowych filtrów IIR (ang. *Infinite Impulse Response*), z oknem, malejącym w sposób eksponencjalny:

$$\hat{E}[Y_{ij}(n)] = \alpha \cdot Y_{ij}(n) + Y_{ij}(n-1) \cdot (1 - \alpha), \quad (2.34)$$

$$\hat{D}[Y_{ij}(n)] = \alpha \cdot |Y_{ij}(n) - \hat{E}[Y_{ij}(n)]| + (1 - \alpha) \cdot \hat{D}[Y_{ij}(n-1)], \quad (2.35)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

Y_{ij} – mierzony sygnał wejściowy,

α – poziom istotności (parametr zapominania).

Wyznaczanie parametrów statystycznych zgodnie z równaniami (2.34) i (2.35) pozwala na minimalizację użycia pamięci RAM (ang. *Random Access Memory*), która mogłaby stać się wąskim gardłem całej implementacji, ze względu na ograniczone czasy dostępu do wybranych wartości parametrów. O poziomie istotności pojawiającej się próbki pomiarowej decyduje parametr zapominania α , natomiast wyeliminowana jest konieczność przechowywania historii odczytów każdego mikrobolometru. Metoda CR-NUC została zaimplementowana w rozwiązaniu sprzętowym, opisanym w pracy [74]. Do implementacji

wykorzystano układ FPGA. Zgodnie z wynikami, zaprezentowanymi przez autorów, implementacja była w stanie przetwarzać wideo o rozdzielczości 720x480 pikseli z częstotliwością 30 klatek na sekundę.

Sprzętowa implementacja metody CR-NUC została także opisana w publikacji [62]. Zaproponowano w niej docelową strukturę logiczną układu VLSI, na potrzeby dwóch procesów produkcyjnych. Rozwiązanie zostało dodatkowo rozwinięte o mechanizm redukcji zjawiska powidoku. Zgodnie z publikacją, rozwiązanie było testowane dla strumienia klatek o rozdzielczości 640x480 14-bitowych pikseli. Osiągnięta częstotliwość przetwarzania wyniosła 238 klatek na sekundę. Zrealizowana przez autorów struktura logiczna układu VLSI, w technologii 500 nanometrów, pozwalała na przetwarzanie tego samego strumienia danych z częstotliwością 64 klatek na sekundę.

2.2.2.3.3. Constant Statistics of Adjacent Ratios

Kolejne rozwiązanie, należące do grupy metod statystycznych, zostało zaproponowane w pracy [54] i nosi nazwę CSAR-NUC (ang. *Constant Statistics of Adjacent Ratios Non-Uniformity Correction*). Metoda przyjmuje model charakterystyki mikrobolometru:

$$Y_{ij}(n) = A_{ij} * X_{ij}(n), \quad (2.36)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

A_{ij} – wzmacnienie sensora,

$Y_{ij}(n)$ – mierzony sygnał wejściowy,

$X_{ij}(n)$ – rzeczywista wartość promieniowania padającego na sensor.

Model, opisany równaniem (2.36), jest właściwy dla kalibracyjnej metody jednego punktu (pomijany jest błąd zera mikrobolometrów, wchodzących w skład matrycy).

Metoda CSAR-NUC bazuje na założeniu, że wzmocnienia sensorów nie zmieniają się w pewnym horyzoncie obserwacji. Rozciągając analizę na pewną ilość klatek, nieprzekraczającą tego horyzontu czasowego, można założyć, że w przypadku braku niejednorodności w obrazie z matrycy, statystycznie mediana ilorazu piksela badanego i średniej geometrycznej wartości dwóch sąsiednich pikseli powinna być równa jedności:

$$Me_N \left[\frac{Y_{ij}(n)}{\sqrt[2]{Y_{i-1,j}(n) * Y_{i,j-1}(n)}} \right] = 1, \quad (2.37)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

N – ilość wszystkich próbek, podlegających analizie,

A_{ij} – wzmocnienie sensora,

$Y_{ij}(n)$ – mierzony sygnał wejściowy,

$X_{ij}(n)$ – rzeczywista wartość promieniowania padającego na sensor.

Uwzględniając przyjęty model charakterystyki odpowiedzi mikrobolometru, opisany równaniem (2.38), można wyprowadzić zależność:

$$\frac{A_{ij}}{\sqrt[2]{A_{i-1,j} * A_{i,j-1}}} * Me_N \left[\frac{X_{ij}(n)}{\sqrt[2]{X_{i-1,j}(n) * X_{i,j-1}(n)}} \right] = 1, \quad (2.38)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

N – ilość wszystkich próbek, podlegających analizie,

A_{ij} – wzmocnienie sensora,

$X_{ij}(n)$ – rzeczywista wartość promieniowania padającego na sensor.

Jeżeli wartość mediany, opisanej wyrażeniem (2.37) odbiega od jedności, oznacza to, że należy przeskalować badane wzmocnienie A_{ij} przez jej odwrotność, tak, aby wyrażenie (2.38) osiągnęło oczekiwaną wartość. W oparciu o to założenie zaproponowano zastosowanie rekurencyjnego podejścia, w którym zaczynając od jednego z narożników matrycy wyznaczone są wartości wzmocnień, na podstawie odczytu sąsiednich pikseli. Warunkiem poprawnego działania metody jest niezerowe wzmocnienie początkowe $A_{1,1}$, które arbitralnie jest przyjmowane jako równe jedności. Ponadto, należy uwzględnić dodatkowe warunki dla krawędzi obrazu, w których dla pierwszej kolumny i pierwszego wiersza, możliwe jest uwzględnienie w obliczeniach tylko jednego sąsiedniego piksela.

2.2.2.3.4. Temporal Statistics of Adjacent Pixel

Rekurencyjne podejście do korekcji pomiarów, uzyskiwanych z matrycy mikrobolometrycznej zostało także przedstawione w pracy [8]. Opisywana metoda skupia się na różnicach wartości sąsiednich pikseli, mierzonych w kierunku horyzontalnym i wertykalnym. Wyniki różnicowania są następnie filtrowane dolnoprzepustowo, celem estymacji ich wartości oczekiwanych. Uzyskane w ten sposób parametry statystyczne są wykorzystywane do kompensacji błędów zera sensorów. Autorzy proponują także metodę doboru pikseli, które można uznać za punkty początkowe rekurencyjnego algorytmu, kompensującego różnice pomiędzy sąsiednimi pikselami. Zgodnie z pracą [8], metoda wykazuje podobną skuteczność do metody CSAR-NUC dla tymczasowo statycznych scen, obserwowanych przez kamerę.

2.2.2.4. Metody rejestracyjne

Założeniem metod rejestracyjnych jest próba wydobywania wiedzy o otoczeniu, na podstawie informacji o zmianie położenia obiektów w płaszczyźnie obrazowej. Dane te są wydobywane na podstawie analizy szeregu, składającego się z pewnej

ilości klatek obrazu. Następnie, przy założeniu niezmienności radiacji, emitowanej przez obiekty w czasie akwizycji danych kalibracyjnych, ujednolicane są charakterystyki wszystkich mikrobolometrów, dla których wykryto zmienność (przemieszczenie obiektów) w obrazie.

Rozwiązanie tej kategorii zostało zaproponowane w pracy [21]. Przyjęto w nim model korekcji, opisany równaniem:

$$\hat{X}_{ij}(n) = \hat{g}_{ij}(n) * Y_{ij}(n) + \hat{o}_{ij}(n), \quad (2.39)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

$Y_{ij}(n)$ – mierzony sygnał wejściowy,

$\hat{X}_{ij}(n)$ – skorygowany odczyt,

$\hat{g}_{ij}(n)$ – korekcyjne wzmocnienie,

$\hat{o}_{ij}(n)$ – korekcyjny offset.

W pracy wskazano także na związek liniowej charakterystyki mikrobolometru (2.1) z parametrami korekcyjnymi równania (2.39) – wzmocnienia $\hat{g}_{ij}(n)$ i błędu zera $\hat{o}_{ij}(n)$:

$$\hat{g}_{ij}(n) = \frac{1}{\hat{A}_{ij}(n)}, \quad (2.40)$$

$$\hat{o}_{ij}(n) = -\frac{\hat{B}_{ij}(n)}{\hat{A}_{ij}(n)}, \quad (2.41)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

$\hat{A}_{ij}$ – estymowane wzmocnienie mikrobolometru,

$\hat{B}_{ij}$ – estymowany błąd zera mikrobolometru.

Zgodnie z [83] wyznaczanie przemieszczenia pomiędzy klatkami obrazu jest realizowane metodą korelacji fazowej:

$$(d_i, d_j) = \underset{ij}{\operatorname{argmax}} \left(\operatorname{Re} FFT^{-1} \left\{ \frac{\bar{Y}_{uv}(n) * \bar{Y}_{uv}^*(n-1)}{|\bar{Y}_{uv}(n) * \bar{Y}_{uv}^*(n-1)|} \right\} \right), \quad (2.42)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

d_i, d_j – składowe wektora przesunięcia w płaszczyźnie obrazu,

n – indeks próbki pomiarowej (klatki obrazu),

$\bar{Y}_{uv}(n)$ – transformacja Fouriera badanej klatki sekwencji wideo,

$\bar{Y}_{uv}^*(n-1)$ – sprzężenie zespolone transformacji Fouriera przesuniętej poprzedniej klatki sekwencji wideo.

Równanie (2.42) prezentuje sposób wyznaczenia przesunięcia, dla którego maksymalizowana jest znormalizowana korelacja wzajemna aktualnej klatki przesuniętej o zadany wektor i poprzedniej klatki sekwencji wideo. Wynikiem działania algorytmu jest wyznaczenie wektora przesunięcia pomiędzy kolejnymi klatkami obrazu.

Przy założeniu niezmienności radiacji w obserwowanej scenie, stwarza to możliwość porównania uzyskanych wartości z mikrobolometrów, przesuniętych względem siebie o wyznaczony wektor, estymację błędu odczytu:

$$e_{ij}(n) = \hat{X}_{i-d_i, j-d_j}(n-1) - \hat{X}_{ij}(n), \quad (2.43)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

d_i, d_j – składowe wektora przesunięcia w płaszczyźnie obrazu,

$\hat{X}_{ij}(n)$ – skorygowany odczyt.

Miarę błędu (2.43) można wykorzystać do iteracyjnej aktualizacji parametrów korekcyjnych matrycy:

$$\hat{g}_{ij}(n) = \hat{g}_{ij}(n-1) + \eta * e_{ij}(n) * Y_{ij}(n), \quad (2.44)$$

$$\hat{o}_{ij}(n) = \hat{o}_{ij}(n-1) + \eta * e_{ij}(n), \quad (2.45)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – indeks próbki pomiarowej (klatki obrazu),

$Y_{ij}(n)$ – mierzony sygnał wejściowy,

$\hat{g}_{ij}(n)$ – korekcyjne wzmocnienie,

$\hat{o}_{ij}(n)$ – korekcyjny błąd zera,

η – poziom istotności błędu.

Szybkość aktualizacji parametrów korekcyjnych z równań (2.44) i (2.45) jest regulowana arbitralnie dobieranym parametrem η .

Zaproponowana przez autorów metoda wykazuje znaczną odporność na występowanie zjawiska powidoku w obrazie, jednak zdarza się, że lokalne przemieszczenia obiektów w obserwowanej scenie mogą negatywnie wpłynąć na estymowane przemieszczenie sceny pomiędzy dwiema klatkami sekwencji wideo, co wynika z pacy [2]. Autorzy pracy [68] zaproponowali rozwinięcie metody o rejestrację przemieszczenia kilku klatek obrazu, co pozwala na zwiększenie stabilności parametrów korekcyjnych, kosztem większej złożoności obliczeniowej.

Jak w swojej publikacji wskazują autorzy pracy [22], szybkość z jaką ustalają się parametry korekcyjne matrycy jest zależna od początkowych wartości wzmocnień. Nominalnie dla metod rejestracyjnych przyjmuje się początkowe wzmocnienie korekcyjne $\hat{g}_{ij}(n)$ równe jedności i zerowy korekcyjny błąd zera $\hat{o}_{ij}(n)$. Autorzy publikacji proponują zastosowanie innych wartości początkowych

wzmocnień, uzyskanych na drodze zastosowania statystycznej metody CSAR-NUC, opisanej w rozdziale 2.2.2.3.3. Zastosowanie tej metody korzystnie wpływa na tempo zbieżności parametrów korekcyjnych matrycy.

Jak wskazano w pracy [65], metody rejestracyjne, bazujące na identyfikacji przemieszczenia między klatkami sekwencji wideo metodą korelacji fazowej wykazują znaczną złożoność obliczeniową, co utrudnia ich implementację w rozwiązaniach sprzętowych. Autorzy w swojej publikacji proponują modyfikację sposobu wyznaczania przemieszczenia pomiędzy sąsiednimi klatkami obrazu poprzez zagregowanie informacji, zawartej w każdej klatce obrazu do pojedynczej kolumny i pojedynczego wiersza, a następnie wyznaczeniu przesunięć, dla których minimalizowana jest wartość wskaźnika błędu, będącego sumą kwadratów różnic odpowiadających sobie wartości obu wektorów.

Sposobem na rozwiązanie problemu złożoności obliczeniowej, związanej z wyznaczaniem przesunięć pomiędzy kolejnymi klatkami wideo może być także wymuszenie znanego globalnego przemieszczenia obiektów w płaszczyźnie obrazowej. Może być ono powodowane przestrzenną zmianą obserwowanej sceny lub położenia matrycy. Takie podejście do korekcji niejednorodności metodą jednego punktu zostało zaproponowane w pracy [55]. Zaproponowany w publikacji algorytm obejmuje przetwarzanie danych z dwóch klatek sekwencji wideo z matrycy. Po akwizycji pierwszej klatki matryca jest mechanicznie przesuwana o szerokość jednego piksela. Drugi obraz z matrycy zawiera tym samym informację o obserwowanej scenie, przesuniętą o jeden piksel. W przypadku jednorodnej pracy matrycy wartość odpowiadających pikseli powinna być taka sama w obu klatkach. Jeżeli jednak pojawią się rozbieżności, to informacja o różnicach w obu odczytach może posłużyć do korekcji niejednorodności matrycy. Metoda do poprawnego działania wymaga możliwości przesunięcia matrycy o jeden piksel.

2.2.3. Korekcja zakłóceń kolumn

Analizując obraz, uzyskany z nieskalibrowanej matrycy bolometrycznej, można zaobserwować, że zakłócenie o stałej charakterystyce wykazuje przestrzenną korelację wzdłuż kolumn obrazu. Zjawisko to objawia się nierównomierną jasnością sąsiednich kolumn w obrazie. Ze względu na swój charakter, zakłócenie wykazuje pewną regularność w płaszczyźnie obrazowej. Wśród dzieł literaturowych można znaleźć publikacje, odnoszące się do redukcji tego problemu. Rozwiązania te należą do grupy metod, oznaczanej skrótem SNUC (ang. *Stripe Non-Uniformity Correction*).

Przesłanką do wskazania, czym to zjawisko mogłoby być powodowane, mogą być informacje, zawarte w opisie patentu [95] oraz publikacjach [17], [24], [27], [56] i [58]. Zgodnie z ich treścią, w matrycach sensorycznych zasadniczo stosowane jest rozwiązanie, w którym odczyt wartości pikseli odbywa się w sposób szeregowy, wiersz po wierszu. Kolumny obrazu są przechowywane w dedykowanych pamięciach analogowych, z których kolejne wiersze są odczytywane poprzez zastosowanie rejestrów przesuwnych. W celu zwiększenia stosunku sygnału do zakłócenia wzmacniany jest sygnał, uzyskany z każdego z pikseli matrycy. Aby uniknąć problemów związanych z minimalnym czasem narastania sygnału wyjściowego wzmacniacza, w matrycach stosuje się szereg niezależnych wzmacniaczy, nazywanych wzmacniaczami kolumn. Ponadto, podczas szeregowego odczytu wierszy wymagana jest duża szybkość transmisji danych, co utrudnia redukcję zakłóceń, natomiast częstotliwość przesuwania rejestrów kolumn jest wielokrotnie mniejsza, zależnie od szerokości wiersza. Odczyt danych z tego typu matrycy wygląda następująco: dane z matrycy znajdują się w rejestrach przesuwnych, reprezentujących kolumny obrazu; podczas odczytu kolejnej linii obrazu, rejestry przesuwają się, natomiast pomiar jest wzmacniany i przekazywany do rejestru przesuwego, będącego linią obrazu; po odczycie całej linii obrazu rejestry przesuwają się ponownie, pozwalając

na odczyt danych o kolejnej linii obrazu. Dzięki takiemu podejściu możliwe jest zmniejszenie wymagań dotyczących częstotliwości pracy wzmacniaczy, gdyż rejestry przesuwne kolumn obrazu są taktowane ze znacznie mniejszą częstotliwością. Na podstawie tych informacji można wysnuć przypuszczenie, że różnice, pojawiające się w sąsiednich pikselach linii obrazu, mogą wynikać z nieidentycznych wartości wzmocnień wzmacniaczy kolumn. Zgodnie z pracą [17], efekt takich rozbieżności objawiałby się dodatkowymi zakłóceniami, których wartość byłaby zależna od indeksu kolumny w przestrzeni obrazu, natomiast nie byłaby zależna od indeksu linii piksela.

2.2.3.1. Metody kalibracyjne

Metody kalibracyjne zakładają często liniowy model zakłócenia kolumn, w którym parametry wzmocnienia i błędu zera, są jednakowe dla wszystkich pikseli w pojedynczej kolumnie obrazu, co wskazano w publikacjach [3], [17], [58] i [63]. W pracy [35], na podstawie eksperymentu z użyciem niejednorodnie nagrzanego ciała czarnego, zwrócono uwagę na nieliniową postać uzyskanych przebiegów dla każdej z kolumn. Na tej podstawie zaproponowano zastosowanie modelu nieliniowego, opartego o wielomian drugiego stopnia i trzy parametry korekcyjne dla każdej z kolumn. Przy znajomości radiacji, padającej na sensor możliwe jest zastosowanie metody najmniejszych kwadratów, w celu wyznaczenia parametrów korekcyjnych, co wynika z pracy [63].

2.2.3.1.1. Local spatial correlation-based stripe non-uniformity correction

Zgodnie z informacjami, zawartymi w pracy [17], efekt zastosowania metod korekcji niejednorodności każdego piksela z osobna, może okazać się niesatysfakcjonujący, co może wpłynąć na pojawienie się pasów w obrazie. Jak zaznaczono w pracy, parametry charakterystyk zakłóceń kolumn mogą nie być już jednakowe dla wszystkich pikseli wzdłuż kolumny i nieznacznie wahać się wzdłuż każdej nich. Oznacza to, że dla każdego piksela wzdłuż kolumny powinny zostać dobrane inne parametry korekcyjne. Jednak odczyty sąsiednich pikseli

wykazują podobny poziom zakłócenia o stałej charakterystyce, przez co autorzy wysnuwają założenie, że pomimo wahań, parametry korekcyjne w ramach pojedynczej kolumny obrazu powinny być ze sobą przestrzennie skorelowane. Na podstawie tych założeń proponują oni zastosowanie metody najmniejszych kwadratów, w celu minimalizacji błędu pomiędzy skorygowanym wyjściem, a jego wartością oczekiwaną. Jako wartość oczekiwaną autorzy przyjmują średnią odczytów w jednowymiarowym otoczeniu badanego piksela (wzdłuż wiersza). W celu zmniejszenia rozmycia krawędzi, algorytm uśredniania został rozszerzony o arbitralnie przyjmowany parametr, za pomocą którego w uśrednianiu nie są uwzględniane odczyty, których wartości znacząco odbiegają od wartości badanego piksela.

Implementacja sprzętowa metody została opisana w pracy [17]. Rozwiązanie zostało przetestowane dla termogramów o rozdzielczości 288x384 pikseli.

2.2.3.2. Metody oparte o sieci neuronowe

Wśród przeanalizowanych metod korekcji zakłóceń kolumn można znaleźć także rozwiązania, oparte o zastosowanie sztucznych sieci neuronowych.

2.2.3.2.1. Stripe Noise Correction Using Neural Network

W pracy [27] zaproponowano metodę korekcji zakłóceń kolumn, stanowiącą adaptację metody, opartej o zastosowanie sieci neuronowych, opisanej w podpunkcie 2.2.2.1.1. Autorzy zauważyli, że wyznaczana w klasycznym podejściu wartość oczekiwana, bazująca na otoczeniu piksela, może nie być wyznaczana właściwie, ze względu na inne zakłócenia, wynikające z toru pomiarowego każdej z kolumn. Autorzy proponują rozwiązanie problemu poprzez odjęcie od wartości oczekiwanej (średnia arytmetyczna wartości w otoczeniu piksela), średniej wartości wszystkich pomiarów mikrobolometrów, należących do tego samego toru pomiarowego (kolumny), co korygowany mikrobolometr.

2.2.3.2.2. Stripe Noise Removal Convolutional Neural Network

W publikacji [57] opisano propozycję metody usuwania pasów, opartą o zastosowanie konwolucyjnych sieci neuronowych. Metoda ta jest oznaczana w literaturze skrótem SNR-CNN-NUC (ang. *Stripe Noise Removal Convolutional Neural Network Non-Uniformity Correction*). Metoda wykorzystuje pojedynczą warstwę konwolucyjną do korekcji niejednorodności z wykorzystaniem filtracji, a także dwie warstwy konwolucyjne dla celów rekonstrukcji obrazu w zwiększonej rozdzielczości (ang. *super-resolution*). W pracy [37], a także w pracy [9], wskazano problemy metody. Wadą rozwiązania jest niedopasowanie do problemu (ang. *underfitting*), przez niską złożoność sieci neuronowej, skutkującą brakiem pełnej identyfikacji zakłócenia o stałej charakterystyce. Ponadto, zgodnie z pracą [37], proces uczenia sieci został określony jako niepotrzebnie skomplikowany. W celu jego uproszczenia zaproponowano filtrację niskich częstotliwości z obrazu, celem ekstrakcji wysokich częstotliwości, zawierających informacje o zakłóceniu o stałej charakterystyce (FPN), które następnie są używane do trenowania sieci.

2.2.3.3. Metody oparte o filtrację

Wśród znanych rozwiązań algorytmicznych można wyróżnić grupę metod, opartych o szeroko pojętą filtrację przestrzenną kolejnych klatek strumienia wideo, pochodzącego z kamery.

2.2.3.3.1. 1-D Guided Filtering Non-Uniformity Correction

Często przytaczanym w literaturze rozwiązaniem jest metoda *1-D Guided Filtering* (*GF-NUC*), opisana w pracy [60]. Zgodnie z propozycją, estymacja zakłócenia o stałej charakterystyce (FPN), odbywa się w oparciu o zastosowanie zmodyfikowanego filtra *Guided Filter* (*GF*). Zasada działania filtra *Guided Filter* została opisana w dodatku C.

Korekcja niejednorodności kolumn w obrazie obejmuje zastosowanie jednowymiarowego okna filtracji (otoczenia piksela), celem ujednolicenia obrazu

tylko w kierunku horyzontalnym lub wertykalnym. Autorzy zaproponowali ścieżkę przetwarzania danych, obejmującą dwa etapy:

- 1) Przeprowadzenie wygładzania obrazu filtrem GF z oknem horyzontalnym i odjęcie wygładzonego obrazu od obrazu wejściowego; wynikiem operacji dwa obrazy – wygładzony horyzontalnie obraz wejściowy i obraz, prezentujący wysokie częstotliwości w obrazie, obejmujące krawędzie obiektów i zakłócenia kolumn.
- 2) Przeprowadzenie wygładzania obrazu filtrem GF z oknem wertykalnym, wykorzystującym jako obraz prowadzący będący wygładzonym obrazem z etapu 1, celem eliminacji pozostałości krawędzi obiektów, obecnych w obrazie wysokich częstotliwości.

Autorzy zaprezentowali w swojej publikacji rozważania nad sprzętową implementacją metody GF-NUC, z wykorzystaniem układu FPGA. Jednak, nie natrafiono na opis zrealizowanej implementacji sprzętowej tego algorytmu. Metoda GF-NUC jest wykorzystywana jako metoda porównawcza w wielu późniejszych publikacjach naukowych, obejmujących prace: [9], [17], [25], [37], [53], [56]. Zgodnie z pracą [37], metoda pozwala na osiągnięcie relatywnie dobrego balansu pomiędzy redukcją zakłóceń, a zachowaniem wysokiego poziomu szczegółowości.

2.2.3.3.2. 1-D Horizontal Differential Statistics

W celu dalszej redukcji negatywnego efektu identyfikacji krawędzi obiektów jako zakłócenia o stałej charakterystyce, w pracy [56] zaproponowano modyfikację metody GF-NUC, opisaną w podpunkcie 2.2.3.3.1. Obejmuje ona zamianę wertykalnej filtracji GF (drugiego etapu przetwarzania), na adaptacyjny algorytm wertykalnej filtracji krawędzi obiektów, które występują w części wysokoczęstotliwościowej, uzyskanej w wyniku filtracji horyzontalnej jednowymiarowym filtrem GF (wynik pierwszego etapu przetwarzania). Autorzy zauważają, że różnice między wartościami kolejnych kolumn cechują się lokalnie

innym przebiegiem w przypadku wystąpienia krawędzi w obrazie. Na tej podstawie proponują algorytm detekcji krawędzi, którego wynik wpływa następnie na jednowymiarową filtrację w wertykalnym oknie (wzdłuż kolumn), oszczędzając zakłócenie o stałej charakterystyce, celem jego ekstrakcji.

2.2.3.4. Minimalizacja różnic między kolumnami

Wśród znanych dzieł literaturowych można spotkać algorytmiczne podejście do redukcji zakłóceń kolumn, obejmujące próbę minimalizacji różnic pomiędzy kolumnami w obrazie. Zgodnie z [58], zakłócenie jest addytywnym czynnikiem dodanym (offset), niezależnym od radiacji, padającej na sensor, piksele w ramach każdej z kolumn współdzielą zakłócenie o tej samej wartości. Ponadto, zakłócenia poszczególnych kolumn są od siebie niezależne.

Na podstawie tych założeń w pracy [58] zaproponowano rozwiązanie matematyczne, oparte o minimalizację funkcji kosztów, stanowiącą sumę wartości średnich kwadratów różnic pikseli, wchodzących w skład sąsiednich kolumn. Autor wprowadził także do funkcji kosztów dodatkowy czynnik, promujący niskie wartości parametrów korekcyjnych kolumn. Minimalizacja funkcji kosztów jest realizowana z wykorzystaniem metody Eulera-Lagrange’a.

2.2.3.4.1. Stripe noise removal based on the most stable window

W pracy [20] zaproponowano algorytm, oparty o analizę statystyczną pojedynczych kolumn w obrazie. Bazuje on na założeniu jednakowej charakterystyki odpowiedzi sensorów, wchodzących w skład pojedynczej kolumny matrycy. Analizując wartości średnie odpowiedzi wybranych sensorów, wchodzących w skład sąsiednich kolumn matrycy, można ujednolicić ich jasność. Dobór sensorów, podlegających analizie statystycznej odbywa się poprzez wybranie fragmentu kolumny (okna), w którym wariancja mierzonego sygnału przyjmuje najmniejszą wartość. W ten sposób minimalizowana jest szansa na uwzględnienie w algorytmie niewielkich detali o wysokiej intensywności w obserwowanej scenie. Ma to szczególne znaczenie w przypadku obserwacji

satelitarnych, dla których dedykowane było rozwiązanie. Na podstawie wybranego okna wyznaczane są wartości oczekiwane poziomów szarości w obrazie, a ich różnica jest wykorzystywana do korekcji drugiej z kolumn. Autorzy zakładają, że pierwsza z kolumn zawiera informacje prawdziwe, natomiast kolejna kolumna podlega korekcji. Ponadto, autorzy zakładają, że pierwsza kolumna obrazu zawiera informację o wartości oczekiwanej poziomu szarości całego obrazu. W ten sposób iteracyjnie korygowane są wszystkie kolumny w obrazie.

Autorzy swoje rozważania poparli sprzętową implementacją metody, zrealizowaną z wykorzystaniem układu FPGA. Zgodnie z pracą [20], wydajność przetwarzania termogramów, o rozdzielczości 256x256 pikseli, wyniosła 1457 klatek na sekundę.

2.2.3.4.2. Midway Histogram Equalization

Jedną z częściej cytowanych metod korekcji niejednorodności, wynikających z zastosowania wzmacniaczy kolumn jest metoda MHE (ang. *Midway Histogram Equalization*), oznaczana także MIRE (ang. *Midway InfraRed Equalization*). Została ona zaproponowana w pracy [67]. Metoda ma na celu korekcję niejednorodności kolumn, przeprowadzaną na podstawie pojedynczej klatki obrazu poprzez jednakową zmianę wartości pikseli, wchodzących w skład kolumn w obrazie, w taki sposób, aby zminimalizować różnice histogramów pikseli z sąsiednich kolumn. Zgodnie z zaproponowanym w publikacji algorytmem, celem przetwarzania jest sprawienie, aby histogramy sąsiednich kolumn iteracyjnie zbliżały się do siebie i spotkały się „w połowie drogi”, z czego wywodzi się nazwa metody.

Zgodnie z pracą [37], wadą metody MHE jest wysoka złożoność obliczeniowa, a także modyfikacja wartości pikseli w obrazie do histogramu uśrednionego, co może negatywnie wpływać na dokładność odwzorowania elementów sceny, poprzez wprowadzanie zakłóceń, obserwowanych w płaszczyźnie matrycy. Próbę

optymalizacji problemu złożoności obliczeniowej podjęto w pracy [85], poprzez zastosowanie próbkowania oszczędnego (ang. *Compressive Sensing*). Dzięki zastosowanemu podejściu możliwe okazało się 75 procentowe obniżenie ilości kolumn, dla których ujednolicano histogramy, przy zachowaniu zbliżonej jakości uzyskanych wyników. Metoda MHE została wykorzystana jako metoda porównawcza w wielu późniejszych pracach, między innymi w: [35], [37], [38], [45], [56], [57], [58], [60], [78] oraz [79].

2.3. Nieliniowości charakterystyk mikrobolometrów, wchodzących w skład matrycy

Wiele znanych metod, bazujących na analizie sceny, zakłada liniowość charakterystyk wszystkich mikrobolometrów wchodzących w skład matrycy termowizyjnych. Tymczasem, jak wskazano w pracach [10], [34], [47], [61], [87], i [99], istnieją przesłanki do stwierdzenia, że charakterystyki te mogą posiadać nieliniową postać, szczególnie w przypadku szerokiego docelowego zakresu rejestrowanego promieniowania elektromagnetycznego. Zauważalnym negatywnym efektem kalibracji, opartej o charakterystykę liniową (2.1), jest brak skutecznej redukcji zakłócenia o stałej charakterystyce (FPN). Zgodnie z [47], efekt jest tym wyraźniejszy, im większa jest różnica radiacji wzorca kalibracyjnego i radiacji, padającej na mikrobolometr.

Jednak, w literaturze pojawia się niewielka ilość publikacji, których autorzy podejmują próbę estymacji charakteru nieliniowości charakterystyki mikrobolometru oraz proponują rozwiązania tego problemu. Rozwiązania takie są oparte o laboratoryjne badania matrycy i zastosowanie metod kalibracyjnych, takich jak metoda wielu punktów. W pracy [86] stwierdzono, że takie rozwiązanie byłoby relatywnie trudne w realizacji sprzętowej. W literaturze znaleziono tylko jedno rozwiązanie, odnoszące się do problemu nieliniowości, bazujące na filtrze Kalmana, opisane w publikacji [87]. Jednak, zgodnie z pracą [2], metoda filtracji oparta o filtr Kalmana bazuje na założeniu, że w pojedynczym bloku pomiarowym

wszystkie detektory są wystawione na działanie tego samego zakresu radiacji, co może być trudne do osiągnięcia w warunkach rzeczywistych. Propozycja metody, bazującej na analizie sceny, uwzględniającej nieliniowości charakterystyk mikrobolometrów, wchodzących w skład matrycy, mogłaby stanowić ważną zaletę technologiczną i stanowi problem badawczy, związany z przedmiotem rozprawy.

2.4. Rozwiązania sprzętowe w korekcji niejednorodności matryc bolometrycznych

Znane rozwiązania, dotyczące korekcji niejednorodności matryc bolometrycznych, walidowane są podczas testów, przeprowadzonych w oparciu o implementację proponowanych algorytmów. Spotykane implementacje obejmują często dedykowane oprogramowanie. Rozwiązania programowe dzierżawią zasoby komputera, którymi z kolei zarządza system operacyjny. Istnienie dodatkowego pośrednika w postaci systemu operacyjnego, konieczność rywalizacji o zasoby z innymi aplikacjami, a także fakt, że komputer stanowi uniwersalne urządzenie, przeznaczone do wielu rodzajów zadań, sprawia, że wydajność przetwarzania danych z matryc bolometrycznych może być optymalizowana. Optymalizacja taka odbywa się poprzez stworzenie dedykowanej implementacji sprzętowej. Implementacja sprzętowa jest terminem używanym w odniesieniu do rozwiązań, w których realizację algorytmu zamiast programowi, powierza się układowi scalonemu lub obwodowi elektrycznemu, o dedykowanej strukturze logicznej. Realizacje sprzętowe są często trudniejsze w wykonaniu i testowaniu, co może przekładać się na wyższy nakład czasowy i finansowy, potrzebny do ich stworzenia. Jednakże, ze względu na fakt, że wynikowe rozwiązanie jest dedykowane konkretnemu zastosowaniu, taka forma implementacji algorytmu korekcji umożliwia istotne zwiększenie jego wydajności.

Potrzeba propozycji rozwiązań, optymalizujących czas przetwarzania danych wynika z faktu, że kamery wszelkiego rodzaju są używane m.in. w nadzorze bezpośrednim, gdzie kluczowy staje się szybki czas reakcji na obserwowane zdarzenie. Oznacza to potrzebę weryfikacji znanych rozwiązań w realizacjach, które za cel nadrzędny stawiają sobie możliwość przetwarzania w czasie maksymalnie zbliżonym do czasu rzeczywistego. Czas rzeczywisty jest definiowany chwilą pojawienia się kolejnych danych wejściowych z matrycy. Układ scalony, który realizowałby zadanie przetwarzania w czasie rzeczywistym, byłby zdolny do natychmiastowego dostarczenia przetworzonych danych wyjściowych. W praktyce jest on niemożliwy do uzyskania, chociażby ze względu na czas propagacji sygnału elektrycznego w strukturze logicznej układu scalonego, realizującego algorytm korekcji. Dlatego implementacjom sprzętowym stawia się wymagania dotyczące koniecznych do spełnienia warunków brzegowych, uwzględniających minimalne wymagania stawiane rozwiązaniu (np. częstotliwość odświeżania obrazu). Postawienie takich założeń sprawia, że niektóre rozwiązania algorytmiczne mogą okazać się niemożliwe do realizacji.

Ponadto, dedykowane rozwiązania sprzętowe pozwalają na minimalizację zapotrzebowania na moc elektryczną. Wynika to z dedykowanej struktury logicznej, przeznaczonej do realizacji konkretnego zadania. Potrzeba minimalizacji zużycia energii wynika z założeń projektowych docelowego rozwiązania. Znane są rozwiązania, dla których niemożliwe jest dostarczenie stałego, wydajnego źródła zasilania. Dotyczy to między innymi obiektów bezzałogowych, w tym urządzeń obserwacyjnych umieszczonych na orbicie okołoziemskiej, jak rozwiązania opisane w pracach [39] i [45].

Wśród zastanego stanu literatury znane są propozycje implementacji sprzętowych, które mają na celu walidację proponowanych rozwiązań algorytmicznych. Jedną z pierwszych propozycji, dotyczącą możliwości zastosowania dedykowanej struktury sprzętowej, została opisana w pracy [92]. W publikacji rozważona została analogowa struktura układu elektrycznego,

w której generacja prądów i napięć, na potrzeby korekcji niejednorodności powierzana byłaby regulowanym źródłom prądowym. Współczynniki korekcji byłyby przechowywane z wykorzystaniem kondensatorów – osobno dla korekcji wzmocnienia i błędu zera. Przetwarzanie danych odbywałoby się bezpośrednio na wyjściu detektora. Takie rozwiązanie, użyte w matrycy mikrobolometrów, stanowiłoby szereg równoległe działających układów korekcyjnych o niskim stopniu złożoności i poborze mocy. Zgodnie z pracą [92], zaproponowano realizację takiego rozwiązania w formie układu VLSI (ang. *Very-Large-Scale Integration*).

VLSI jest szerokim terminem, który odnosi się do układów scalonych o wysokim poziomie integralności, zbudowanych z dużej ilości tranzystorów. Tranzystory są w nich zgrupowane w formie komponentów, pełniących określone zadania i składających się na architekturę układu scalonego. Celem podejścia jest optymalizacja zużycia energii oraz zapewnienie kompaktowości, poprzez implementację złożonej architektury sprzętowej w pojedynczym układzie scalonym. Przykładowe układy VLSI obejmują m.in. mikroprocesory czy rozwiązania SoC (ang. *System-on-a-Chip*). Szczególnym rodzajem układu VLSI są układy FPGA (ang. *Field Programmable Gate Array*), znajdujące zastosowanie w akceleracji sprzętowej algorytmów przetwarzania strumieni wideo, co wskazano w pracach [18] i [19]. Zgodnie z pracą [72], układy FPGA są szeroko wykorzystywane w prototypowaniu i analizie obecnych w literaturze sprzętowych adaptacji algorytmów korekcji niejednorodności matryc bolometrycznych. Zasada działania układów FPGA została opisana w dodatku A.

Sprzętowa implementacja algorytmów korekcji niejednorodności matryc bolometrycznych o wysokiej rozdzielczości

Znane rozwiązania sprzętowe, zostały zestawione w tabeli:

Tabela 2.1. Zestawienie znanych sprzętowych implementacji algorytmów korekcji niejednorodności.

Nazwa metody	Literatura	Podpunkt	Rodzaj	Rozdzielczość	Przepustowość
Metoda dwóch punktów	[76]	2.2.1.2	CB-NUC	384x288 px	68100000 px/s
	[72]	2.2.1.2	CB-NUC	320x240 px	brak danych
	[46]	2.2.1.2	CB-NUC	320x240 px	brak danych
	[6]	2.2.1.2	CB-NUC	64x48 px	12288000 px/s
	[6]	2.2.1.2	CB-NUC	640x512 px	8192000 px/s
Variable Integration Time	[81]	2.2.1.4	CB-NUC	320x240 px	brak danych
Improved Temporal High-Pass based on Grayscale Mapping NUC	[52]	2.2.2.2.3	SB-NUC	320x256 px	4096000 px/s
Filtr Kalmana	[84]	2.2.2.2.4	SB-NUC	320x240 px	brak danych
Neural Network NUC	[69]	2.2.2.1.1	SB-NUC	320x240 px	10060800 px/s
Neural Network NUC (Guided Filter)	[50]	2.2.2.1.1	SB-NUC	256x256 px	11796480 px/s
Neural Network NUC (Adaptacyjna szybkość uczenia sieci)	[5]	2.2.2.1.1	SB-NUC	324x256 px	brak danych
Constant Range NUC	[74][62]	2.2.2.3.2	SB-NUC	640x480 px	73113600 px/s
Local spatial correlation-based stripe NUC	[17]	2.2.3.1.1	SNUC	288x384 px	brak danych
Stripe noise removal based on the most stable window	[20]	2.2.3.4.1	SNUC	256x256 px	95485952 px/s

Tabela 2.1 zawiera porównanie znanych implementacji sprzętowych. Przytoczone nazwy metod zostały opatrzone odniesieniami do literatury i podpunktów przeglądu literatury. Ponadto, przyporządkowane zostały do klas metod: metod kalibracyjnych (CB-NUC), metod bazujących na analizie sceny (SB-NUC) oraz metod, przeznaczonych do korekcji zakłóceń kolumn (SNUC). W tabeli przytoczono także rozdzielczości obsługiwanych matryc i znane przepustowości implementacji sprzętowych, wyrażone w pikselach na sekundę.

2.5. Podsumowanie przeglądu literatury

Podpunkt zawiera podsumowanie przeglądu literatury, przeprowadzone z uwzględnieniem założeń projektowych. Obejmują one propozycję rozwiązania sprzętowego, spełniającego wymagania, wynikające z tez rozprawy:

- zapewnienie adaptacyjności parametrów korekcyjnych, do temporalnych zmian parametrów charakterystyk mikrobolometrów matrycy,
- zapewnienie płynności przetwarzania na poziomie 30 klatek na sekundę, dla termogramów o rozdzielczości 1024x768 pikseli,
- uwzględnienie nieliniowości charakterystyk odpowiedzi mikrobolometrów.

Przeanalizowane opisy rozwiązań sprzętowych były oparte o układy logiki programowalnej z rodziny FPGA.

Istotnym problemem układów FPGA jest niewielka zdolność do gromadzenia dużych ilości danych. Większość zaimplementowanych sprzętowo metod korekcji wykorzystuje do działania zewnętrzne pamięci operacyjne RAM (ang. *Random Access Memory*). Magistrala komunikacyjna między układem FPGA, a pamięcią operacyjną może stać się wąskim gardłem całej implementacji. Złożoność problemu rośnie wraz ze wzrostem rozdzielczości matrycy. Promuje to zastosowanie w docelowym rozwiązaniu metod, pozwalających na minimalizację zużycia pamięci operacyjnej.

Wśród przeanalizowanych rozwiązań sprzętowych nie znaleziono przykładów badań, przeprowadzonych dla matryc o rozdzielczości równej lub większej niż 1024x768 pikseli. W pracy [6] opisano implementację korekcji niejednorodności, opartej o kalibracyjną metodę dwóch punktów (podpunkt 2.2.1.2), przeznaczoną dla matrycy o rozdzielczości 640x512 pikseli. Z metod bazujących na analizie sceny, propozycja, obsługująca matrycę o najwyższej rozdzielczości (640x480 pikseli), została oparta o algorytm CR-NUC (ang. *Constant Range Non-Uniformity Correction*), opisany w rozdziale 2.2.2.3.2.

Rozwiązania sprzętowe, obejmujące metody kalibracyjne, wykazują niską złożoność obliczeniową, co przekłada się na wysoką częstotliwość uzyskiwanych wyników. Jednak, ze względu na brak adaptacyjności, nie są one wystarczające do spełnienia wymagań, stawianych docelowemu rozwiązaniu. Do docelowego rozwiązania należy uwzględnić metody, bazujące na analizie sceny oraz metody korekcji zakłóceń kolumn.

Wśród przeanalizowanych algorytmów, bazujących na analizie sceny, dla których podano zarówno rozdzielczość matrycy, jak również osiągniętą częstotliwość odświeżania obrazu, największą wydajnością cechuje się metoda CR-NUC.

Metody kalibracyjne i metody, bazujące na analizie sceny, są wrażliwe na zakłócenia, wynikające z toru pomiarowego matrycy. Dotyczy to także zakłóceń kolumn. Zakłócenia kolumn mają szczególnie negatywny wpływ na metody, bazujące na analizie sceny, których algorytmy oparto o analizę otoczenia korygowanego piksela. Wśród analizowanych pozycji literaturowych nie spotkano implementacji sprzętowej, która realizowałaby wstępną korekcję zakłóceń kolumn, przed zastosowaniem metody, bazującej na analizie sceny.

W celu ograniczenia negatywnego wpływu wzmacniaczy kolumn zaproponowano zastosowanie dodatkowego wstępnego etapu korekcji. Autorskie rozwiązanie, dedykowane identyfikacji i korekcji tego zakłócenia, opisano w rozdziale 3.

Autorzy przeanalizowanych publikacji literaturowych w większości zakładają liniową charakterystykę odpowiedzi mikrobolometru. Ponadto, wśród przeanalizowanych publikacji można znaleźć wzmianki o nieliniowościach charakterystyk mikrobolometrów. Nie spotkano jednak rozwiązań sprzętowych, uwzględniających te nieliniowości. Jedyne znalezione rozwiązanie z kategorii metod, bazujących na analizie sceny, oparto o zastosowanie filtru Kalmana i częściowo liniowego podejścia do charakterystyki mikrobolometru. Zostało ono opisane w podpunkcie 2.2.2.2.4.

W celu uwzględnienia nieliniowości charakterystyk mikrobolometrów, zaproponowano autorskie rozwiązanie. Wykorzystuje ono metodę, bazującą na analizie sceny i częściowo liniowe podejście do charakterystyki mikrobolometru. Rozwiązanie zostało opisane w rozdziale 3.

Ze względu na adaptacyjność, potencjał optymalizacji zużycia pamięci oraz niską złożoność obliczeniową, do realizacji zadania korekcji wybrano statystyczną metodę CR-NUC. Ponadto, metoda CR-NUC cechuje się zapasem wydajności, pozwalającym na zastosowanie jej w matrycy o rozdzielczości 1024x768 pikseli.

W świetle przeprowadzonego przeglądu literatury, do realizacji rozwiązania sprzętowego wybrano układ FPGA.

Do opisu implementacji sprzętowej, zrealizowanej w układzie FPGA, wykorzystano języki opisu sprzętu VHDL i Verilog. Oprogramowanie do odbioru danych z układu FPGA, zostało napisane w języku C++.

3. Proponowane rozwiązanie


Celem prezentowanego rozwiązania jest propozycja autorskiego podejścia do korekcji niejednorodności matrycy bolometrycznej, spełniającego założenia projektowe, wynikające z tez rozprawy:

- zapewnienie adaptacyjności parametrów korekcyjnych, do temporalnych zmian parametrów charakterystyk mikrobolometrów matrycy,
- zapewnienie przepustowości danych na poziomie 30 klatek na sekundę, dla termogramów o rozdzielczości 1024x768 pikseli,
- uwzględnienie nieliniowości charakterystyk odpowiedzi mikrobolometrów.

Przeanalizowane opisy rozwiązań sprzętowych były oparte o układy logiki programowalnej z rodziny FPGA.

Docelową częstotliwość akwizycji danych z matrycy określono na 30 klatek na sekundę. Dla matrycy o rozdzielczości 1024x768 pikseli oznacza to minimalną częstotliwość korekcji pikseli na poziomie 23.59296 MHz.

Proponowane rozwiązanie bazuje na dwuetapowej korekcji niejednorodności, opartą o trzy komponenty sprzętowe, przedstawione na rysunku:



Rys.3.1. Komponenty architektury, wchodzące w skład modułu TEM (ang. Thermogram Enhancement Module).

Rysunek 3.1 przedstawia komponent architektury dedykowanego sterownika kamery, służący korekcji niejednorodności. Moduł jest oznaczony skrótem TEM (ang. Thermogram Enhancement Module). Zawarto w nim dwie metody korekcji. W pierwszym etapie realizowane jest usuwanie zakłóceń kolumn, wynikających

z toru pomiarowego matrycy, autorską metodą klasy SNUC (ang. *Stripe Non-Uniformity Correction*). W kolejnym etapie zrealizowano sprzętową korekcję niejednorodności, opartą o nieliniową adaptację statystycznej metody CR-NUC, opisanej w rozdziale 2.2.2.3.2. Spodziewanym efektem działania całości implementacji sprzętowej jest adaptacyjna poprawa jakości uzyskanych termogramów. Komponenty modułu TEM zostały opisane w osobnych podpunktach.

Rozwiązanie zostało zoptymalizowane pod kątem możliwości ich sprzętowej akceleracji, z wykorzystaniem układu FPGA. Celem optymalizacji jest minimalizacja zużycia pamięci tymczasowej (ang. *Random-Access Memory*, RAM). Przy zadanej częstotliwości wymiany danych, przepustowość magistrali komunikacyjnej pomiędzy pamięcią RAM i układem FPGA staje się wąskim gardłem całego rozwiązania. Konieczność zastosowania zewnętrznej pamięci RAM jest powodowana faktem, że dedykowane układy pamięciowe BRAM (ang. *Block Random Access Memory*), zawarte w układach FPGA, posiadają niewystarczającą pojemność.

3.1. Korekcja zakłóceń kolumn

Proponowane rozwiązanie bazuje na założeniach, że zakłócenie jest jednakowe dla wszystkich pikseli wzdłuż kolumny oraz że radiacja, padająca na sąsiednie kolumny matrycy powinna być zbliżona. Efekt ten pogłębia się wraz ze wzrostem długości ogniskowej układu optycznego kamery oraz wraz ze wzrostem rozdzielczości matrycy IRFPA – gdy zwiększa się rozmiar obiektów w płaszczyźnie obrazowej. Dla poprawnie skalibrowanej matrycy, wartość oczekiwana różnicy odczytów sąsiednich pikseli, wchodzących w skład sąsiednich kolumn w obrazie powinna być równa zero:

$$E[Y_j] = \frac{1}{N} \sum_{i=0}^{N-1} (Y_{i,j} - Y_{i,j-1}) = 0, \quad (3.1)$$

gdzie:

ij – indeks badanego piksela,


Y_{ij} – piksel obrazu wejściowego,

Y_j – kolumna obrazu wejściowego,

N – ilość pikseli w kolumnie.


Zaproponowane rozwiązanie polega na wyznaczaniu różnic między wartościami oczekiwanymi kolumn, celem ich minimalizacji. Różnica między wartością oczekiwaną aktualnej kolumny obrazu i kolumny poprzedzającej, jest odejmowana od wartości piksela. Celem korekcji jest osiągnięcie sytuacji, w której prawdziwa jest zależność, wyrażona równaniem (3.1). Pierwsza kolumna obrazu jest przyjmowana jako wzorcowa i nie podlega korekcji.

Proponowane rozwiązanie przedstawiono na schemacie blokowym:



Rys.3.2. Schemat blokowy komponentu, korygującego zakłócenia kolumn.

Schemat blokowy, przedstawiony na rysunku 3.2, opisuje sposób działania maszyny stanu komponentu sprzętowego, przedstawionej na rysunku:



Rys.3.3. Maszyna stanu komponentu, korygującego zakłócenia kolumn.

Maszyna stanu, przedstawiona na rysunku 3.3, operuje w dwóch stanach: bezczynności (IDLE) i korekcji (NUC). Stan bezczynności jest osiągalny w przypadku zresetowania sterownika (wejście RST_n, aktywne w stanie niskim) lub przekroczenia maksymalnej wartości licznika kolumn. Stan zapisu jest osiągalny po rozpoczęciu akwizycji linii obrazu (stan wysoki sygnału SOL). Komponent jest wyzwalany zboczem opadającym sygnału zegarowego piksela z matrycy (PCLK). Dane piksela wejściowego (PIN) są wykorzystywane do aktualizacji wartości oczekiwanej kolumny. Ponadto, dane piksela wejściowego są korygowane, z wykorzystaniem różnicy kolumny piksela i kolumny poprzedzającej, przechowywanej w rejestrze i przekazywane na rejestr wyjściowy (POUT). W czasie działania komponent przechowuje informacje o 1024 wartościach oczekiwanych, dla każdej z kolumn. Przechowywanie takiej ilości danych może być zrealizowane z wykorzystaniem wbudowanej w układ FPGA pamięci BRAM (ang. *Block RAM*). Wyznaczanie wartości oczekiwanej pikseli w kolumnie jest realizowane z wykorzystaniem dolnoprzepustowego filtra IIR (ang. *Infinite Impulse Response*), z oknem, malejącym w sposób eksponencjalny. Uzyskany półprodukt stanowi wejście kolejnego etapu przetwarzania.

3.2. Korekcja niejednorodności z uwzględnieniem nieliniowości charakterystyk mikrobolometrów

Etapem, następującym po korekcji zakłóceń kolumn jest korekcja niejednorodności, przeprowadzana z uwzględnieniem nieliniowości charakterystyk mikrobolometrów.

Rozwiązanie bazuje na założeniach, że:

- zakłócenia pomiarowe są eliminowane poprzez korekcję zakłóceń kolumn,
- zmienność wzmocnienia $A_{ij}(n)$ i błędu zera $B_{ij}(n)$ sensora jest znacznie mniejsza niż zmienność promieniowania $X_{ij}(n)$, padającego na sensor. Dlatego, w przypadku krótkich czasów próbkowania (do kilku minut), zakłada się, że ich wartości nie zmieniają się w czasie próbkowania,
- promieniowanie, padające na sensor, jest zmienną losową o rozkładzie jednostajnym,
- charakterystyka odpowiedzi mikrobolometru jest monotoniczna dla mierzonego zakresu wartości promieniowania.

Ponadto, w celu uwzględnienia nieliniowości charakterystyki mikrobolometru, przyjęto częściowo liniowy model, opisany równaniem:

$$Y_{ij}(n) = \begin{cases} A_{1ij}(n)X_{ij}(n) + B_{1ij}(n), & \text{dla } X_{ij}(n) \in [X_{min}, X_1] \\ A_{2ij}(n)X_{ij}(n) + B_{2ij}(n), & \text{dla } X_{ij}(n) \in (X_1, X_2] \\ \vdots & \\ A_{m-1ij}(n)X_{ij}(n) + B_{m-1ij}(n), & \text{dla } X_{ij}(n) \in (X_{m-2}, X_{m-1}] \\ A_{mij}(n)X_{ij}(n) + B_{mij}(n), & \text{dla } Y_{ij}(n) \in (X_{m-1}, X_{max}] \end{cases} \quad (3.2)$$

gdzie:

ij – indeks mikrobolometru na płaszczyźnie matrycy,

n – numer próbki,

m – ilość przedziałów, na które podzielona jest charakterystyka sensora,

$Y_{ij}(n)$ – wskazanie sensora,

$A_{1ij}(n), \dots, A_{mij}(n)$ – wzmocnienie sensora,

$B_{1ij}(n), \dots, B_{mij}(n)$ – błąd zera sensora,

$X_{ij}(n)$ – rzeczywista wartość promieniowania, padającego na sensor,

X_{min} – minimalna wartość promieniowania, padającego na sensor,

X_{max} – maksymalna wartość promieniowania, padającego na sensor,

$X_1, X_2, \dots, X_{m-1}$ – ograniczenia przedziałów charakterystyki.


Parametry liniowych fragmentów charakterystyk (wzmocnienia i błędów zera) są wyznaczane z wykorzystaniem metody CR-NUC (ang. *Constant Range Non-Uniformity Correction*). Należy pamiętać, że proponowana metodologia nie zakłada znajomości rzeczywistego promieniowania, padającego na sensor. Dlatego w przyjętym modelu (równanie (3.2)), problemem staje się określenie ograniczeń przedziałów charakterystyki $X_1, X_2, \dots, X_{m-1}$. Jednak, z punktu widzenia metody CR-NUC, istotny jest jedynie procent charakterystyki, którą pokrywa każdy przedział. Sposób wyznaczania tych wartości, na podstawie obserwacji wskazania sensora $Y_{ij}(n)$, został opisany w dodatku E.

3.2.1. Wyznaczanie wartości granicznych przedziałów przynależności wartości mierzonych

Komponent jest oparty o dwie, równoległe działające maszyny stanu i dwie pamięci operacyjne BRAM (ang. *Block RAM*). W każdej klatce obrazu jedna z pamięci służy do zliczania pikseli, wpadających w poziomy histogram. Jej obsługa jest realizowana przez pierwszą maszynę stanu. Druga pamięć służy do akumulacji wartości wyznaczonego w poprzedniej klatce histogramu, w celu wyznaczenia wartości mierzonych, reprezentujących granice przedziałów częściowo liniowej charakterystyki, opisanej równaniem (3.2). Jej obsługa jest realizowana przez drugą maszynę stanu.


3.2.1.1. Wyznaczanie histogramu

Zadaniem maszyny stanu jest wyznaczenie histogramu, na podstawie pojedynczej klatki sekwencji wideo. Proponowane rozwiązanie przedstawiono na schemacie blokowym:



Rys.3.4. Schemat blokowy komponentu, wyznaczającego histogram pojedynczej klatki.

Schemat blokowy, przedstawiony na rysunku 3.4, opisuje sposób działania maszyny stanu, przedstawionej na rysunku:



Rys.3.5. Maszyna stanu komponentu, wyznaczającego histogram pojedynczej klatki.

Komponent, opisany maszyną stanu, przedstawioną na rysunku 3.5, jest taktowany opadającym zboczem zegara pikseli PCLK. Stan bezczynności IDLE jest osiągany po wystąpieniu sygnału RST_n (aktywny w stanie niskim) lub po zakończeniu akwizycji pojedynczej linii obrazu. Stan HIST (wyznaczanie histogramu) jest osiągany po wystąpieniu stanu wysokiego sygnału początku linii SOL. Histogram jest podzielony na HIST_MAX zakresów, do których przyporządkowywane są kolejne wartości pikseli. Po otrzymaniu sygnału początku linii SOL zliczane są 1024 kolejne piksele. Wartość piksela służy jako wskazanie adresu pamięci BRAM, pod którym jest przechowywany licznik, który ma zostać zwiększony o 1. Adres ten odpowiada kolumnie histogramu.

3.2.1.2. Wyznaczanie wartości granicznych przedziałów przynależności wartości mierzonych

Zadaniem komponentu jest wyznaczenie wartości granicznych $Y_{min}, Y_1, Y_2, \dots, Y_{m-1}, Y_{max}$, ograniczających przedziały modelu częściowo liniowego, opisanego równaniem (3.2). Proponowane rozwiązanie przedstawiono na schemacie blokowym:

Schemat blokowy, przedstawiony na rysunku 3.6, opisuje sposób działania maszyny stanu, przedstawionej na rysunku:




Komponent architektury sprzętowej, jest opisany maszyną stanu, przedstawioną na rysunku 3.7. Maszyna stanu jest taktowana opadającym zboczem zegara PCLK. Stan beczynności (IDLE) jest osiągany po wystąpieniu sygnału RST_n (aktywny w stanie niskim) lub po zakończeniu akwizycji pojedynczej linii obrazu. Stan ACC (akumulacja histogramu) jest osiągany po wystąpieniu stanu wysokiego sygnału początku ramki (SOF). Po otrzymaniu sygnału początku ramki SOF akumulowane są kolejne poziomy histogramu. Po przekroczeniu wartości 5% liczby wszystkich pikseli matrycy, wyznaczana jest wartość Y_{min} , dla której przyjmuje się początek rozkładu jednostajnego. Poziom przekroczenia 95% wszystkich pikseli wyznacza wartość Y_{max} , odpowiadającą najwyższemu zmierzonemu promieniowaniu. Następnie wyznaczane są wartości $Y_1 \dots Y_{m-1}$, w wyniku podziału zakresu $[Y_{min}; Y_{max}]$ na m równych części.

Po odczycie, kolejne poziomy histogramu są zerowane, w celu przygotowania pamięci BRAM na histogram kolejnej klatki obrazu.

3.2.2. Korekcja niejednorodności nieliniowych charakterystyk odpowiedzi mikrobolometrów, wchodzących w skład matrycy


Zadaniem komponentu jest aktualizacja parametrów statystycznych, wyznaczanych zgodnie z metodą CR-NUC (ang. *Constant Range Non-Uniformity Correction*). Proponowane rozwiązanie przedstawiono na schemacie blokowym:

Sprzętowa implementacja algorytmów korekcji niejednorodności matryc bolometrycznych o wysokiej rozdzielczości



Rys.3.8. Schemat blokowy komponentu, realizującego nieliniową adaptację metody korekcji niejednorodności.

Schemat blokowy, przedstawiony na rysunku 3.8, opisuje sposób działania maszyny stanu, przedstawionej na rysunku:



Rys.3.9. Maszyna stanu komponentu, realizującego nieliniową adaptację metody korekcji niejednorodności.

Maszyna stanu, przedstawiona na rysunku 3.9, realizuje proces aktualizacji parametrów statystycznych. Komponent jest taktowany opadającym zboczem sygnału PCLK. Stan bezczynności IDLE jest osiągany po wystąpieniu sygnału RST_n (aktywny w stanie niskim) lub po zakończeniu akwizycji pojedynczej linii obrazu. Stan korekcji niejednorodności NUC jest osiągany po wystąpieniu stanu wysokiego sygnału początku linii SOL. Ilość danych procesowych, wynikająca z rozmiaru matrycy, przekracza zdolności gromadzenia danych wbudowanych pamięci BRAM (ang. *Block Random Access Memory*). Oznacza to konieczność zastosowania zewnętrznej pamięci RAM (ang. *Random Access Memory*). Dane do aktualizacji są pobierane z asynchronicznego bufora FIFO zewnętrznej pamięci RAM. Zaktualizowane dane są następnie przekazywane do modułów dzielących (dzielenie jest realizowane potokowo). Otrzymane wyniki operacji dzielenia są przekazywane do asynchronicznej kolejki FIFO zewnętrznej pamięci RAM.

4. Badania doświadczalne

Zaproponowane rozwiązania algorytmiczne zostały poddane serii badań doświadczalnych, mających na celu weryfikację spełniania warunków brzegowych i prawdziwości postawionych tez. Badania dotyczyły zarówno efektów korekcji, jak również zasadności użycia zastosowanych rozwiązań technologicznych. W tym celu przygotowano stanowisko badawcze, na które składa się autorska, niechłodzona kamera termowizyjna, bazująca na układzie FPGA oraz matrycy mikrobolometrycznej, o relatywnie wysokiej rozdzielczości (1024x768 pikseli) i częstotliwości uzyskanych termogramów (30 klatek na sekundę). Rozwiązanie stanowi także przedmiot wdrożenia. Konieczność realizacji dedykowanego rozwiązania tego typu jest powodowana trudnością w dostępie do tego typu urządzeń – kamery termowizyjne, umożliwiające akwizycję wideo o tak dużych rozdzielczościach i częstotliwości odświeżania klatek, są trudno dostępne. Wynika to między innymi z regulacji ITAR (ang. *International Traffic in Arms Regulations*), dotyczących eksportu tego typu rozwiązań ze Stanów Zjednoczonych. Regulacje te obejmują sprzętowe ograniczenie częstotliwości odświeżania obrazu do 9 klatek na sekundę, natomiast sam proces zakupu wiąże się z utrudnieniami prawnymi i wysokimi kosztami zakupu samej kamery. Ograniczenia dotyczą także zakupów kamer termowizyjnych, realizowanych w celach naukowo-badawczych.

4.1. Stanowisko laboratoryjne

Urządzeniem, służącym do weryfikacji zaproponowanych algorytmów, jest autorska, niechłodzona kamera termowizyjna, przedstawiona na rysunku:




Rys.4.1. Rozwiązanie sprzętowe – niechłodzona kamera termowizyjna o rozdzielczości 1024x768 pikseli.

Sercem kamery, zaprezentowanej na rysunku 4.1, jest matryca mikrobolometryczna ULIS UL 05 25 1-026, o rozdzielczości 1024x768 pikseli. Sygnały elektryczne z matrycy są przekształcane na sygnały cyfrowe, z wykorzystaniem 12-bitowego, dwukanałowego przetwornika analogowo-cyfrowego, obsługiwanego przez dedykowany sterownik matrycy.

Konieczność wyznaczania aktualnych charakterystyk mikrobolometrów wchodzących w skład matrycy, na podstawie analizy statystycznej szeregów czasowych, uzyskanych z 786432 sensorów, wchodzących w skład matrycy o rozdzielczości 1024x768 pikseli, stanowi poważne wyzwanie dla układu obliczeniowego. Warto nadmienić, że w rozwiązaniach literaturowych nie znaleziono żadnej propozycji, dedykowanej matrycom o tak dużej rozdzielczości. Należy także pamiętać, że zadanie korekcji niejednorodności nie powinno być elementem, za który odpowiada jednostka odczytująca dane z kamery (komputer, smartfon itp.). Oznacza to, że całość zadania wstępnej korekcji obrazu powinna być realizowana przez układ sterownika matrycy bolometrycznej, wchodzącego w skład kamery. Jego zadaniem jest inicjalizacja parametrów matrycy i urządzeń przetwarzających sygnał elektryczny oraz

realizacja wstępnego przetwarzania sygnału z matrycy mikrobolometrycznej, w zakresie kondycjonowania obrazu (poprawa kontrastu, korekcja niejednorodności, redukcja zakłóceń pomiarowych), a także przekazywania uzyskanej informacji do urządzenia odbiorczego, z wykorzystaniem interfejsu Gigabit Ethernet. Sterownik matrycy jest zrealizowany w formie rozwiązania sprzętowego, zaimplementowanego w układzie FPGA. Zastosowanie tej technologii pozwala na sprzętową akcelerację wybranego algorytmu korekcji niejednorodności. Poprzez implementację modułu w ramach sterownika matrycy zapewniona jest realizacja korekcji już na etapie przetwarzania wstępnego, dla każdego z mikrobolometrów z osobna. Architektura dedykowanego sterownika matrycy bolometrycznej została przedstawiona na rysunku:



Rys.4.2. Architektura sterownika matrycy bolometrycznej.

Sterownik matrycy, przedstawiony na rysunku 4.2, składa się z szeregu komponentów:

- kontrolera przetwornika analogowo-cyfrowego (ADC_CTRL), którego zadaniem jest konfiguracja i obsługa dwukanałowego, 12-bitowego

przetwornika analogowo-cyfrowego Analog Devices AD5254, służącego do cyfryzacji sygnałów, uzyskanych z matrycy;


- kontrolera pamięci RAM (MEM_CTRL), którego zadaniem jest konfiguracja i obsługa kontrolera pamięci DDR (DDR_CTRL) oraz synchronizacja domen zegarowych układu FPGA i pamięci RAM;
- kontrolera interfejsu Ethernet (ETHERNET), którego zadaniem jest obsługa dwukierunkowej komunikacji sieciowej z przepustowością 1 [Gb/s], w celu umożliwienia odbioru danych z kamery i zadawania jej parametrów;
- modułu TEM (ang. *Thermogram Enhancement Module*), którego zadaniem jest sprzętowa poprawa jakości termogramu.

Rozważania, przedstawione w rozprawie, dotyczą w szczególności implementacji modułu TEM. Zrealizowane w ramach niego rozwiązanie opiera się o dwa główne elementy: redukcję zakłóceń kolumn (ang. *destriping*) oraz korekcję niejednorodności, wynikającej z nieidentycznych charakterystyk odpowiedzi wszystkich mikrobolometrów, wchodzących w skład matrycy.

Algorytm korekcji niejednorodności jest oparty o sprzętową adaptację algorytmu CR-NUC, rozwiniętą o zaproponowane rozwiązanie, pozwalające na uwzględnienie nieliniowości odpowiedzi mikrobolometrów (NCR-NUC). Implementacja jest zrealizowana w oparciu o adaptacyjne algorytmy wyznaczania parametrów statystycznych (wartość oczekiwana, średnie odchylenie bezwzględne), zrealizowane w formie filtrów dolnoprzepustowych z oknem malejącym w sposób eksponentialny. Ich zastosowanie wynika z faktu ich niskiej złożoności obliczeniowej i niewielkiemu obciążeniu pamięciowemu, co w sytuacji, gdy kolejne piksele są uzyskiwane z matrycy z częstotliwością bliską 24MHz (rozdzielczość 1024x768 pikseli, 30 klatek na sekundę), stanowi kluczowe podejście w optymalizacji czasu przetwarzania pojedynczego piksela.

4.2. Poprawa kontrastu

Pierwszy podpunkt sekcji badawczej zawiera wynik korekcji termogramu z wykorzystaniem algorytmu rozciągania histogramu:




Rys.4.3. Przykładowe termogramy przed (A, C) i po (B, D) rozciągnięciu histogramu.

Rysunek 4.3. przedstawia porównanie uzyskanych wyników przed i po operacji rozciągania histogramu. Otrzymane wyniki wskazują na niską skuteczność metod poprawy kontrastu w korekcji niejednorodności matryc bolometrycznych i potwierdzają zasadność stosowania innych etapów przetwarzania: redukcji zakłóceń kolumn i korekcji niejednorodności charakterystyk odpowiedzi mikrobolometrów. Poprawa kontrastu w obrazie może jedynie stanowić ostatni etap przetwarzania, ze względu na fakt, że zwiększa ona rozróżnialność obiektów w obserwowanej scenie.


4.3. Korekcja zakłóceń kolumn

Podczas obserwacji obrazów nieprzetworzonych algorytmami korekcji niejednorodności można spostrzec, że uzyskane obrazy charakteryzują się zakłóceniem, objawiającym się pionowymi liniami w obrazie. Zakłócenia kolumn

zachowują stały charakter w pewnym horyzoncie obserwacji. W celu określenia charakteru zakłócenia przeanalizowano szereg następujących po sobie klatek wideo. Analiza polegała na próbie odpowiedzi na pytanie, czy zakłócenie jest powtarzalne dla wielu klatek obrazu oraz czy jest powtarzalne w każdej linii obrazu. Wyniki zaprezentowano na rysunkach:




Rys.4.4. Wyniki analizy różnic wartości sąsiednich kolumn.



Rys.4.5. Wyniki analizy różnic wartości sąsiednich kolumn - przybliżenie.

Rysunek 4.4 przedstawia porównanie różnic wskazań pikseli z sąsiednich kolumn. Kolorem niebieskim wykreślono różnice wartości sąsiednich pikseli każdej z linii pojedynczej klatki obrazu. Kolorem czerwonym wykreślono uśredniony pomiar różnic wartości sąsiednich pikseli dla pojedynczej klatki obrazu. Kolorem zielonym wykreślono uśredniony pomiar różnic wartości sąsiednich pikseli dla 1024 klatek obrazu. Przybliżenie rysunku 4.4 przedstawiono na rysunku 4.5.

Różnice między pikselami z sąsiadujących kolumn można uznać za stałe w badanym horyzoncie obserwacji (1024 klatki, uzyskane z kamery). Wynik estymacji i korekcji tego zakłócenia zaprezentowano na rysunku:




Rys.4.6. Porównanie obrazu przed korekcją (A) i po korekcji (B) oraz zamodelowane zakłócenie (C). Kolory są efektem dodania palety barw do monochromatycznego termogramu.

W celu zwiększenia rozróżnialności, do rysunku 4.6 sztucznie dodano paletę barw. Skorygowany termogram, przedstawiony w sekcji B rysunku 4.6, nie jest jeszcze w pełni wolny od niejednorodności (na rysunku 4.6 w prawej górnej części sekcji B powinien być widoczny budynek), jednak uzyskany wynik pozwala na znaczącą redukcję zakłóceń, których przyczyną są wzmacniacze kolumn. Zaproponowane w implementacji sprzętowej podejście, polegające na uśrednianiu wartości kolumn wydaje się słuszne, gdyż zakłócenie zachowuje stały charakter w długiej próbie, a uśrednione różnice pomiędzy wartościami kolumn pojedynczej klatki obrazu są wystarczającym estymatorem tego zakłócenia w badanej matrycy.

4.4. Wzorcowanie matrycy


Zastosowana matryca bolometryczna została przebadana z wykorzystaniem ciała czarnego i poprzez pomiar radiacji cieplnej ciała czarnego dla wielu punktów charakterystyki. W celu uzyskania danych kalibracyjnych kamery wykorzystano dwa ciała czarne, umożliwiające emisję radiacji podczerwonej dla temperatur w zakresach 0-50 i 20–100 stopni w skali Celsjusza. Pomiar przeprowadzono w stałych warunkach temperaturowych otoczenia kamery. Przykładowe wyniki, uzyskane na podstawie odpowiedzi 20000 sensorów matrycy, przedstawiono na rysunku:




Rys.4.7. Zbiór charakterystyk odpowiedzi 20000 sensorów.

Wśród zaprezentowanych na rysunku 4.7 wyników można spostrzec, że charakterystyki odpowiedzi mikrobolometrów, wchodzących w skład badanej matrycy, mają nieliniowy przebieg. Pozwala to na wysnucie wniosku o zasadności zastosowania nieliniowego podejścia, do estymacji charakterystyk odpowiedzi każdego z mikrobolometrów. Zgodnie z tym spostrzeżeniem przeanalizowano skuteczność zastosowania nieliniowego modelu charakterystyki mikrobolometru, dla analizowanej matrycy. Wyniki zaprezentowano na rysunkach:

Sprzętowa implementacja algorytmów korekcji niejednorodności matryc
bolometrycznych o wysokiej rozdzielczości



Rys.4.8. Charakterystyka odpowiedzi pojedynczego sensora matrycy




Rys.4.9. Średnie błędy korekcji niejednorodności wszystkich mikrobolometrów, w zależności od rodzaju przyjętego modelu charakterystyki mikrobolometru.

Wyznaczone charakterystyki odpowiedzi okazały się nieliniowe, natomiast ich estymacja wielomianem 2 stopnia pozwala na istotne ograniczenie błędów, wynikających z nieliniowości sensorów, wchodzących w skład badanej matrycy mikrobolometrycznej. Uzyskane wyniki pomiarów, przedstawione na rysunkach 4.8 i 4.9, potwierdzają zasadność stosowania nieliniowego podejścia w estymacji charakterystyki mikrobolometru.

4.5. Analiza wpływu ilości i jakości danych statystycznych


Kolejne doświadczenie miało na celu weryfikację ilości danych statystycznych, które pozwalają na relatywnie dobrą korekcję obrazu z wykorzystaniem metody CR-NUC. Metoda została zaimplementowana w formie opisanej przez twórców, z wykorzystaniem danych symulacyjnych, pochodzących z monochromatycznego filmu. Materiał wejściowy został dobrany w taki sposób, aby scena (a tym samym wartość wszystkich pikseli) uległa zmianie po około 600 klatkach filmu. Celem takiego doboru danych jest weryfikacja, czy skok wartości oczekiwanej i wariancji wpływa znacząco na jakość uzyskanych wyników. Ze względu na wykorzystanie w przetwarzaniu analizy wartości oczekiwanej i wariancji sygnału wejściowego, wynik metody CR-NUC powinien okazać się wrażliwy na gwałtowne zmiany wariancji szeregów czasowych, zawierających odczyty dla każdego piksela matrycy. Dane wejściowe zostały zniekształcone losowym, znanym zakłóceniem o stałej charakterystyce, przy założeniu liniowego modelu charakterystyki odpowiedzi mikrobolometru (zgodnie z założeniem autorów). Porównanie wykonano dla dwóch wariantów: z obecnym i nieobecnym zakłóceniem typu sól-pieprz. Ponadto, na potrzeby uzyskania danych symulacyjnych podobnych do danych, uzyskanych z kamery termowizyjnej znacznie pogorszony został kontrast w obrazie. Efekt uzyskano poprzez zmniejszenie głębi bitowej pikseli z 256 do 16 poziomów szarości. Tak uszkodzone kolejne klatki filmu były używane jako dane wejściowe implementacji metody CRNUC. Każda kolejna klatka obrazu zwiększała zbiór

wejściowy o jeden pomiar dla każdego z pikseli. Następnie wyniki były przeliczane ponownie na podstawie zwiększonego zbioru danych, obraz podlegał korekcji i był porównywany z danymi wejściowymi. Ze względu na możliwość porównania wyników z danymi przed zniekształceniem istnieje możliwość zastosowania wskaźnika jakości, pozwalającego na odniesienie jakości działania metody do obiektywnych danych referencyjnych. Jako miarę jakości wybrano pomiar pierwiastka błędu średniokwadratowego (RMSE). Miary błędów zostały opisane w dodatku D. Wyniki badania przedstawiono na rysunku:



Rys.4.10. Zależność wartości wskaźnika RMSE od liczby próbek

Uzyskane wyniki, przedstawione na rysunku 4.10, zaprezentowano także w formie porównania wizualnego, w formie przykładowej klatki z filmu, skorygowanej na podstawie danych z 64, 128, 256, 512 i 1024 klatek filmu (rysunek 4.9). Dobór liczebności prób jest nieprzypadkowy, ze względu na korzystne w rozwiązaniach sprzętowych zastosowanie potęg liczby dwa jako dzielników, podczas obliczania parametrów statystycznych.



Rys.4.11. Porównanie obrazu wejściowego (A), obrazu zniekształconego (B) oraz wyników uzyskanych na podstawie 64(C), 128(D), 256(E), 512(F) i 1024(G) próbek.

Na podstawie uzyskanych wyników, przedstawionych na rysunku 4.11, można wnioskować o skuteczności działania metody CR-NUC. Obraz wyjściowy staje się rozróżnialny już po zadaniu na wejściu kilkuset klatek obrazu, natomiast po 512 klatkach zaczyna dobrze przypominać pierwowzór. Wraz ze wzrostem ilości danych statystycznych, wartości błędu średniokwadratowego gwałtownie zmniejszają wartości, następnie utrzymując się poniżej wartości 0.25. Zgodnie z danymi, przedstawionymi na rysunku 4.10, minimum wartości RMSE osiągane jest po 1216 klatkach obrazu. Niższe wartości błędu są trudno osiągalne ze względu na znaczne pogorszenie rozdzielczości bitowej pikseli (pogorszenie kontrastu). Zakłócenie typu sól-pieprz nie wpłynęło znacząco na uzyskane wyniki, jednakże pogarsza je w całej długości próby. Zmiana sceny w filmie nie wpłynęła znacząco na pogorszenie uzyskanych wyników. Na podstawie uzyskanych wyników można wysnuć wniosek, że 1024 klatkowy horyzont obserwacji pozwala na dobrą estymację parametrów charakterystyk wszystkich mikrobolometrów, wchodzących w skład matrycy, w świetle założeń, że jest ona liniowa oraz nie ulega zmianie w całym horyzoncie obserwacji. Wartości te stanowią założenia ogólne, stawiane implementacji sprzętowej sterownika matrycy oraz wartości graniczne, w których parametry wzmocnienia i błędu zera charakterystyk mikrobolometrów powinny być stałe, żeby działanie metody okazało się skuteczne.

4.6. Porównanie działania różnych realizacji metody CR-NUC

Kolejna próba dotyczyła porównania działania różnych implementacji metody CR-NUC. Pierwsza wersja (CR-NUC-PC) była zrealizowana w formie zaproponowanej przez autorów metody. Ze względu na dostępność dużych zasobów pamięciowych komputera była ona zrealizowana tak, aby parametry korekcyjne były wyznaczane z użyciem całej próby. Druga i trzecia realizacja (CR-NUC-FPGA, NCR-NUC) zostały zrealizowane z wykorzystaniem układu FPGA, z uwzględnieniem ograniczeń sprzętowych układu. W ramach adaptacji

zastosowano filtry dolnoprzepustowe z oknem, malejącym w sposób eksponencjalny. Jako nastawę współczynnika zapominania α przyjęto wartość 1/1024. Trzecia realizacja (NCR-NUC) obejmuje proponowane rozwiązanie, pozwalające na uwzględnienie nieliniowości charakterystyk mikrobolometrów. Ze względu na konieczność udostępnienia obiektywnych danych porównawczych, badanie zostało przeprowadzone w oparciu o dane symulacyjne, pochodzące z filmu monochromatycznego. Dane wejściowe zostały zniekształcone losowo wygenerowanym zakłóceniem o stałej charakterystyce, przy założeniu nieliniowego modelu charakterystyki odpowiedzi mikrobolometru. Zakłócenie o stałej charakterystyce zostało wybrane według modelu nieliniowego, przedstawionego równaniem:

$$I_2(i, j) = \left(\frac{I_1(i, j)}{255} \right)^a * 255, \quad (4.1)$$


gdzie:

I_1 – intensywność obrazu wejściowego,

I_2 – intensywność obrazu wyjściowego,

i, j – współrzędne piksela w obrazie.

Rodzina charakterystyk według równania (4.1) została przedstawiona na rysunku:




Rys.4.12. Rodzina symulowanych charakterystyk nieliniowych.

Parametr a charakterystyki nieliniowej według równania (4.1) był wybierany losowo dla każdego piksela z osobna, z wykorzystaniem generatora liczb pseudolosowych. Generator działał zgodnie z rozkładem normalnym Gaussa, o wartości oczekiwanej równej a oraz odchyleniu standardowym równym $0.1 \cdot a$.

Jako wskaźniki porównawcze, ze względu na dostępność danych referencyjnych (dane wejściowe), wykorzystano wskaźniki: znormalizowany pierwiastek błędu średniokwadratowego oraz szczytowy stosunek sygnału do zakłócenia. Wskaźniki jakości zostały opisane w dodatku D.

Wyniki korekcji niejednorodności przeprowadzone z wykorzystaniem opisanych metod przedstawiono w tabelach:

Tabela 4.1. Porównanie realizacji i wariantów algorytmu CR-NUC.



Sprzętowa implementacja algorytmów korekcji niejednorodności matryc bolometrycznych o wysokiej rozdzielczości

Tabela 4.2. Porównanie realizacji i wariantów algorytmu CR-NUC.

	$a = 2$	$a = 0.33$
WEJŚCIE		
CRNUC-PC		
CRNUC-FPGA		
NCRNUC		

Otrzymane wyniki, przedstawione w tabelach 4.1 i 4.2, pozwalają na stwierdzenie, że w przypadku, gdy charakterystyka mikrobolometru jest nieliniowa, to zaproponowane podejście (NCR-NUC) może pozytywnie wpłynąć na jakość otrzymanych wyników korekcji.

Wyniki porównania liczbowego (tabela 4.1) wskazują, że błąd korekcji maleje wraz z ilością danych, wprowadzonych do algorytmu. Metoda NCR-NUC wydaje się osiągać korzystniejsze wartości wskaźnika znormalizowanego błędu średniokwadratowego niż CR-NUC-FPGA, a w przypadku $a=2$ osiąga wyniki lepsze niż metoda CR-NUC-PC, która była zrealizowana z użyciem komputera, nie obciążonego ograniczeniami, wynikającymi z implementacji sprzętowej sterownika kamery.

Wartości wskaźnika PSNR wskazują, że metoda NCR-NUC pozwala na maksymalizację jakości informacji przekazywanych przez obraz względem pozostałych implementacji.

Jako dodatkowy, pozytywny efekt, wynikający z podziału charakterystyki na mniejsze, liniowe fragmenty, warto wyróżnić znacznie zredukowane zjawisko powidoku, co jest wyraźnie widoczne na porównaniu wizualnym (ślad po budynku w górnej lewej części klatki). Redukcja powidoku wynika z faktu, że parametry, dotyczące poziomów szarości z innych części charakterystyki, estymowane charakterystyką liniową o innym nachyleniu i nie wpływają na jasny fragment nieba.


Ponadto należy wyróżnić, że wyniki, uzyskane z wykorzystaniem zaproponowanej metody NCR-NUC wykazują znacznie większy realizm względem pozostałych implementacji. Można to zauważyć na przykładowych klatkach obrazu po korekcji (tabela 4.2), gdzie w przypadku metod CR-NUC-PC i CR-NUC-FPGA wartości poziomów jasności nieba i ulicy są nienaturalnie zbliżone.

Negatywnym efektem, zauważalnym w wynikach działania metody NCR-NUC jest powstanie zakłóceń, związanych z nieciągłością poszczególnych

segmentów charakterystyki, wpływająca na powstawanie zakłócenia na przełączeniach fragmentów.

4.7. Efekty korekcji niejednorodności

Wyniki działania implementacji oraz efekt, wnoszony przez opisane fragmenty implementacji, przedstawiono na rysunku:




Rysunek 4.11. Efekty różnych etapów korekcji. A - obraz RAW, B – obraz po rozciągnięciu histogramu, C - obraz po korekcji zakłóceń kolumn, D - obraz po redukcji wpływu wzmacniacza kolumn i korekcji niejednorodności. Kolory są efektem dodania palety barw do nominalnie monochromatycznego termogramu

Na rysunku 4.11 przedstawiono zestawienie wyników działania poszczególnych etapów korekcji: korekcji zakłóceń kolumn (ang. *destriping*) oraz korekcji niejednorodności. Każdy z wymienionych etapów przetwarzania wprowadza istotną poprawę jakości uzyskanego termogramu. Na rysunku 4.11, w sekcji C, można dostrzec, że samo usuwanie pasów nie eliminuje wszystkich negatywnych efektów, ponieważ pozostają widoczne dalej występujące

zniekształcenia, jednak ich charakter wydaje się być dużo bardziej regularny i obraz już na tym etapie zaczyna być rozróżnialny. Niemniej usuwanie pasów pozwala wypracować korzystny punkt startowy metody NCR-NUC, gdyż dane są wolne od zakłócenia, którego geneza może mieć inne podłoże, a które zachowuje stały charakter na przestrzeni kolumn, w całym horyzoncie obserwacji. Jak pokazano w sekcji B rysunku 4.11, poprawa kontrastu posiada jedynie wymiar estetyczny, ponieważ w porównaniu do usuwania pasów oraz metody NCR-NUC nie pozwala na wydobyć dobrej jakości informacji z uzyskanego obrazu. Jedynym pozytywnym efektem w takim przypadku jest dopasowanie rozpiętości poziomów szarości termogramie do zdolności rejestracji oka ludzkiego, co jest efektem pożądanym, ale zasadnym dopiero po właściwej korekcji niejednorodności (rysunek 4.11, sekcja D). Należy pamiętać, że nominalnie termogramy są monochromatyczne – kolory w obrazach zostały dodane jedynie w celu zwiększenia rozróżnialności wynikowych ujęć.

Efekt końcowy działania implementacji sprzętowej sterownika matrycy przedstawiono na rysunkach:



Rys. 4.12. Porównanie obrazów przed (A, C) i po (B, D) korekcji niejednorodności. Kolory są efektem dodania palety barw do nominalnie monochromatycznego termogramu.



Rys 4.13. Przykładowy obraz po korekcji niejednorodności z wykorzystaniem sterownika matrycy bolometrycznej.

5. Podsumowanie

Jednym z celów rozprawy było opracowanie algorytmu korekcji niejednorodności, dedykowanego korekcji termogramów, uzyskanych przy pomocy niechłodzonej matrycy bolometrycznej, o relatywnie wysokiej rozdzielczości. W rozprawie sformułowano warunki brzegowe, postawione przed docelowym rozwiązaniem. Wśród nich szczególne znaczenie miały: zapewnienie adaptacyjności zaproponowanej metodologii, zachowanie wysokiej wydajności przetwarzania danych oraz uwzględnienie nieliniowości charakterystyk mikrobolometrów, wchodzących w skład matrycy. Zgodnie z analizą rozwiązań literaturowych, przedstawioną w rozdziale 2, adaptacyjność i relatywnie wysoką wydajność przetwarzania danych wykazywała statystyczna metoda CR-NUC, o którą oparto proponowane rozwiązanie. Ponadto, w pracy wskazano na celowość wstępnej eliminacji zakłóceń kolumn matrycy, będącej przedmiotem rozważań, zawartych w licznych dziełach literaturowych.

W celu rozwoju znanych rozwiązań z dziedziny, w rozdziale 3 zaproponowano metodę NCR-NUC, pozwalającą uwzględnić nieliniowości charakterystyk mikrobolometrów, wchodzących w skład matrycy. Zgodnie z propozycją, uwzględnienie nieliniowości mikrobolometrów zostało zrealizowane z wykorzystaniem częściowo liniowego modelu charakterystyki mikrobolometru. Propozycja została zoptymalizowana pod kątem zastosowania rozwiązania w implementacji sprzętowej sterownika matrycy.

Do korekcji niejednorodności zaproponowano dwuetapową realizację zadania. Etapy przetwarzania obejmowały: redukcję zakłóceń kolumn oraz korekcję niejednorodności, wynikającej z nieidentycznych charakterystyk mikrobolometrów matrycy, realizowaną z uwzględnieniem ich nieliniowości.

Rozdział 4 zawiera wyniki badań doświadczalnych, przeprowadzonych z wykorzystaniem stanowiska laboratoryjnego, obejmującego niechłodzoną kamerę termowizyjną, o relatywnie wysokiej rozdzielczości i częstotliwości

uzyskanych termogramów. Stanowisko laboratoryjne oparto o matrycę bolometryczną, cechującą się rozdzielczością 1024x768 pikseli oraz układ FPGA, w którym zrealizowano dedykowaną implementację sprzętową sterownika matrycy.

W celu zapewnienia adaptacyjności metody, a także w celu optymalizacji zużycia pamięci RAM, do wyliczania parametrów statystycznych, używanych podczas obliczeń, wykorzystano filtry dolnoprzepustowe z oknem, malejącym w sposób eksponentialny. Dzięki temu podejściu zaproponowane algorytmy pozwalają na adaptację rozwiązania do zmiennych warunków otoczenia. W szczególności dotyczy to kompensacji dryfu temperaturowego parametrów charakterystyk mikrobolometrów. Umożliwia to eliminację układu chłodzącego z kamery. Uzyskane wyniki potwierdzają słuszność pierwszej tezy rozprawy:

***Teza 1.** Możliwe jest stworzenie i sprzętowa implementacja adaptacyjnego algorytmu, którego zadaniem jest estymacja i korekcja zakłócenia o stałej charakterystyce, występującego w strumieniach wideo, uzyskanych przy pomocy matrycy mikrobolometrycznej o wysokiej rozdzielczości.*

Rozwiązanie było w stanie realizować zadanie aktualizacji parametrów korekcyjnych z częstotliwością akwizycji danych pomiarowych z matrycy (30 klatek na sekundę) i nie wymagało do działania zewnętrznych urządzeń (np. komputera). Uzyskane wyniki potwierdzają słuszność drugiej tezy rozprawy:

***Teza 2.** Możliwa jest realizacja algorytmu korekcji niejednorodności według tezy 1, realizowanego w czasie zbliżonym do rzeczywistego, determinowanym szybkością akwizycji danych pomiarowych, dedykowanego dla matryc mikrobolometrycznych o wysokiej rozdzielczości.*

W wyniku badania odpowiedzi matrycy na znaną radiację cieplną, stwierdzono, że charakterystyka odpowiedzi większości mikrobolometrów, wchodzących w skład badanej matrycy nie jest liniowa. Zgodnie z wynikami, przedstawionymi w rozdziale 4, zaproponowane rozwiązanie pozwalało na kompensację negatywnych efektów wynikających z nieliniowości

charakterystyki odpowiedzi mikrobolometru. Wraz ze zwiększaniem ilości danych pomiarowych rosła skuteczność działania metody NCR-NUC. Uwzględnienie nieliniowości mikrobolometrów pozwalało także na częściową kompensację efektu powidoku (ang. *ghosting*), spowodowanego przez niechcianą redukcję statycznych obiektów w sekwencji wideo. Uzyskane wyniki potwierdzają słuszność trzeciej tezy rozprawy:

Teza 3. *Możliwa jest sprzętowa implementacja adaptacyjnego algorytmu korekcji niejednorodności według tez 1 i 2, pozwalającego na uwzględnienie nieliniowości charakterystyk odpowiedzi mikrobolometrów, wchodzących w skład matrycy mikrobolometrycznej o wysokiej rozdzielczości, na radiację podczerwoną, emitowaną przez obiekty w obserwowanej scenie.*

Ponadto, badania pozwoliły na wyodrębnienie szeregu wniosków, dotyczących rozwiązania. Testy wykazały nieskuteczność zastosowania algorytmu poprawy kontrastu do korekcji termogramów, uzyskanych z matrycy. Potwierdzona tym samym została konieczność wykorzystania algorytmu korekcji niejednorodności. Wartości oczekiwane różnic wartości pikseli z sąsiadujących kolumn można było uznać za niezmiennie, w kilkudziesięciosekundowym horyzoncie obserwacji. Zaproponowana metoda korekcji zakłóceń kolumn w widoczny sposób poprawiała jakość termogramu. Zastosowanie wstępnej redukcji zakłóceń kolumn nie uwalniało w pełni uzyskanego obrazu od niejednorodności. Jednak, uzyskany obraz był wolny od zakłóceń, wynikających z toru pomiarowego, spełniając tym samym założenia, dotyczące kolejnego etapu przetwarzania (metody NCR-NUC).

Efektem przeprowadzonych prac jest adaptacyjna metodologia korekcji niejednorodności, zoptymalizowana pod kątem implementacji w rozwiązaniach sprzętowych, pozwalająca na uwzględnienie nieliniowości mikrobolometrów matrycy, będąca integralną częścią sterownika niechłodzonej kamery termowizyjnej o wysokiej rozdzielczości.

6. Literatura

- [1] Seo, S., Jeon, J. (2021). *Real-time scene-based nonuniformity correction using feature pattern matching. 15th International Conference on Ubiquitous Information Management and Communication (IMCOM)* (pp. 1-6).
- [2] Cheng, K., Zhou, H., Qin, H., Zhao, D., Qian, K., Rong, S. (2018). *An improved non-uniformity correction algorithm and its GPU parallel implementation. Infrared Physics & Technology* (vol. 90, pp. 156-163).
- [3] Kudinov, I. A., Kholopov, I. S. (2021). *Rows Permutation Based Non-uniformity Correction Algorithm for Video Sequences. 2021 10th Mediterranean Conference on Embedded Computing (MECO)* (pp. 1-4).
- [4] Li, Y., Liu, N., Xu, J. (2021). *Infrared scene-based non-uniformity correction based on deep learning model. Optik* (vol. 227).
- [5] Njuguna, J. C., Alabay, E., Çelebi, A. (2021). *Field Programmable Logic Arrays Implementation of Scene-Based Nonuniformity Correction Algorithm. 2021 8th International Conference on Electrical and Electronics Engineering (ICEEE)* (pp. 6-9).
- [6] Liu, Q., Wang, H., Bian, H., Wang, H. (2021). *Dual Mode High Speed Uncooled Short Wave Infrared Camera Based on FPGA. Journal of Physics: Conference Series* (vol. 1952).
- [7] Qian, W., Chen, Q., Gu, G. (2010). *Space low-pass and temporal high-pass nonuniformity correction algorithm. Optical review* (vol. 17, pp. 24-29).
- [8] Liu, C., Sui, X., Liu, Y., Kuang, X., Gu, G. (2019). *FPN estimation based nonuniformity correction for infrared imaging system. Infrared Physics & Technology* (vol. 96, pp. 22-29).
- [9] Li, T., Zhao, Y., Li, Y., Zhou, G. (2021). *Non-Uniformity Correction of Infrared Images Based on Improved CNN With Long-Short Connections. IEEE Photonics Journal* (vol. 13(3), pp. 1-13).

- [10] Song, S., Zhai, X. (2020). *Research on non-uniformity correction based on blackbody calibration. 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)* (vol. 1, pp. 2146-2150).
- [11] Guan, J., Lai, R., Xiong, A., Liu, Z., Gu, L. (2020). *Fixed pattern noise reduction for infrared images based on cascade residual attention CNN. Neurocomputing* (vol. 377, pp. 301-313).
- [12] Zeng, X., Xu, J., Gao, X. (2020). *A Potential Method for the Nonuniformity Correction and Noise Removal of Infrared Thermal Image. Acta Physica Polonica* (vol. 137(6)).
- [13] Fan, F., Ma, Y., Huang, J., Liu, Z., Liu, C. (2015). *A combined temporal and spatial deghosting technique in scene based nonuniformity correction. Infrared Physics & Technology* (vol. 71, pp. 408-415).
- [14] Chang, S., Li, Z. (2019). *Single-reference-based solution for two-point nonuniformity correction of infrared focal plane arrays. Infrared Physics & Technology* (vol. 101, pp. 96-104).
- [15] Santos, A. C. G., Vieira, G. S., Castro, R. M. (2018). *Non uniformity correction in a Long Wave Infrared Focal Plane Array as a function of the higher calibration temperature. 2018 33rd Symposium on Microelectronics Technology and Devices (SBMicro)* (pp. 1-5).
- [16] Cao, X., Zhu, B., Wang, S., Yong, Y., Huo, Y., Huo, J. (2019). *Nonuniformity Correction Algorithm for TEC-less Uncooled Infrared Imaging System. 2019 IEEE 5th International Conference on Computer and Communications (ICCC)* (pp. 214-219).
- [17] Zhou, B., Luo, Y., Chen, B., Wang, M., Peng, L., Liang, K. (2019). *Local spatial correlation-based stripe non-uniformity correction algorithm for single infrared images. Signal Processing: Image Communication* (vol. 72, pp. 47-57).

- [18] Kwiatkowski, J. (2018). *Projekt i wykonanie stanowiska badawczego sensora dalekiej podczerwieni. Automatyzacja procesów dyskretnych: Teoria i zastosowania* (pp. 131–138).
- [19] Kwiatkowski, J., Daniec, K., Jędrasiak, K., Sobel, D., Domżał, M., Nawrat, A. (2016). *Real Time Thermogram Enhancement by FPGA-Based Contrast Stretching. 8th Asian Conference on Intelligent Information and Database Systems (ACIIDS)* (pp. 487-496).
- [20] Jiang, H., Miao, R., Chen, J., Zhang, C., Hu, X., Ouyang, J., Lu, J. (2019). *A resource-efficient parallel architecture for infrared image stripe noise removal based on the most stable window. Infrared Physics & Technology* (vol. 97, pp. 258-269).
- [21] Zuo, C., Chen, Q., Gu, G., Sui, X. (2011). *Scene-based nonuniformity correction algorithm based on interframe registration. Journal Of The Optical Society Of America A (JOSA A)* (vol. 28(6), pp. 1164-1176).
- [22] Lv, B., Tong, S., Liu, Q., Sun, H. (2019). *Statistical scene-based non-uniformity correction method with interframe registration. Sensors* (vol. 19(24), p. 5395).
- [23] Chang, Y., Yan, L., Liu, L., Fang, H., Zhong, S. (2019). *Infrared aerothermal nonuniform correction via deep multiscale residual network. IEEE geoscience and remote sensing letters* (vol. 16(7), pp. 1120-1124).
- [24] Wang, E., Jiang, P., Hou, X., Zhu, Y., Peng, L. (2019). *Infrared stripe correction algorithm based on wavelet analysis and gradient equalization. Applied Sciences* (vol. 9(10), p. 1993).
- [25] Lingxiao, L., Qi, L., Huajun, F., Zhihai, X., Yueting, C. (2019). *A Novel Infrared Focal Plane Non-Uniformity Correction Method Based on Co-Occurrence Filter and Adaptive Learning Rate. IEEE Access* (vol. 7, pp. 40941-40950).
- [26] Jin, M., Jin, W., Li, Y., Li, S. (2015). *Temporal high-pass non-uniformity correction algorithm based on grayscale mapping and hardware*

- implementation. 2015 International Conference on Optical Instruments and Technology: Optoelectronic Imaging and Processing Technology* (vol. 9622, pp. 277-284).
- [27] Bai, J., Chang, C., Liu, W. (2017). *Stripe Noise Correction for Infrared Imaging System Using Neural Network Theory. Advances in Computer Science and Ubiquitous Computing* (pp. 677-682).
- [28] Liu, C., Sui, X., Gu, G., Chen, Q. (2018). *Shutterless non-uniformity correction for the long-term stability of an uncooled long-wave infrared camera. Measurement Science and Technology* (vol. 29(2)).
- [29] Kuang, X., Sui, X., Liu, Y., Liu, C., Chen, Q., Gu, G. (2018). *Robust destriping method based on data-driven learning. Infrared Physics & Technology* (vol. 94, pp. 142-150).
- [30] He, K., Sun, J., Tang, X. (2012). *Guided image filtering. IEEE transactions on pattern analysis and machine intelligence* (vol. 35, pp. 1397-1409).
- [31] Rong, S., Zhou, H., Zhao, D., Cheng, K., Qian, K., Qin, H. (2018). *Infrared fix pattern noise reduction method based on shearlet transform. Infrared Physics & Technology* (vol. 91, pp. 243-249).
- [32] Liu, R., Wang, D., Jia, P., Che, X. (2018). *Gradient sky scene based nonuniformity correction and local weighted filter based denoising. Optik* (vol. 174, pp. 748-756).
- [33] Zuo, C., Chen, Q., Gu, G., Qian, W. (2011). *New temporal high-pass filter nonuniformity correction based on bilateral filter. Optical Review* (vol. 18, pp. 197-202).
- [34] Calik, R. C., Tunali, E., Ercan, B., Öz, S. (2018). *A Study on Calibration Methods for Infrared Focal Plane Array Cameras. International Joint Conference on Computer Vision, Imaging and Computer Graphics (VISIGRAPP)* (pp. 219-226).
-

- [35] Cao, Y., Li, Y. (2015). *Strip non-uniformity correction in uncooled long-wave infrared focal plane array based on noise source characterization. Optics Communications* (vol. 339, pp. 236-242).
 - [36] Lai, R., Guan, J., Yang, Y., Xiong, A. (2018). *Spatiotemporal adaptive nonuniformity correction based on BTV regularization. IEEE Access* (vol. 7, pp. 753-762).
 - [37] Jian, X., Lv, C., Wang, R. (2018). *Nonuniformity Correction of Single Infrared Images Based on Deep Filter Neural Network. Symmetry* (vol. 10(11), p. 612).
 - [38] Torres, S. N., Hayat, M. M., Armstrong, E. E., Yasuda, B. J. (2000). *Kalman-filtering approach for nonuniformity correction in focal plane array sensors. Infrared Imaging Systems: Design, Analysis, Modeling, and Testing* (vol. 4030, pp. 196-205).
 - [39] Sheng, Y., Dun, X., Jin, W., Zhou, F., Wang, X., Mi, F., Xiao, S. (2018). *The on-orbit non-uniformity correction method with modulated internal calibration sources for infrared remote sensing systems. Remote Sensing* (vol. 10(6), p. 830).
 - [40] Lai, R., Yue, G., Zhang, G. (2018). *Total variation based neural network regression for nonuniformity correction of infrared images. Symmetry* (vol. 10(5), p. 157).
 - [41] Bhan, R.K., Saxena, R.S., Jalwani, C.R. Lomash, S.K. (2009). *Uncooled infrared microbolometer arrays and their characterisation techniques. Defence Science Journal* (vol. 59(6), p. 580).
 - [42] Li, Y., Jin, W., Zhu, J., Zhang, X., Li, S. (2018). *An adaptive deghosting method in neural network-based infrared detectors nonuniformity correction. Sensors* (vol. 18(1), p. 211).
 - [43] Chen, N., Zhang, J., Zhong, S., Ji, Z., Yao, L. (2018). *Nonuniformity Correction for Variable-Integration-Time Infrared Camera. IEEE Photonics Journal*, (vol. 10(6), pp. 1-11).
-

- [44] Li, Y., Jin, W., Liu, Z. (2018). *Interior radiation noise reduction method based on multiframe processing in infrared focal plane arrays imaging system. IEEE Photonics Journal* (vol. 10(5), pp. 1-12).
- [45] Cao, S., Li, Y., Jiang, C., Jia, G. (2017). *Statistical non-uniformity correction for paddlebroom thermal infrared image. 2017 2nd International Conference on Multimedia and Image Processing (ICMIP)* (pp. 141-145).
- [46] Khare, S., Kaushik, B. K., Singh, M., Purohit, M., Singh, H. (2017). *Reconfigurable architecture-based implementation of non-uniformity correction for long wave IR sensors. Proceedings of International Conference on Computer Vision and Image Processing: CVIP 2016* (vol. 1, pp. 23-34).
- [47] Zhou, D., Yang, L. (2017). *Nonuniformity correction method with dual gradient scenes for unmanned aerial vehicles. 2017 IEEE International Conference on Unmanned Systems (ICUS)* (pp. 429-433).
- [48] Hardie, R. C., Baxley, F., Brys, B., Hytla, P. (2009). *Scene-based nonuniformity correction with reduced ghosting using a gated LMS algorithm. Optics express* (vol. 17(17), pp. 14918-14933).
- [49] Li, Z., Yu, Y., Tian, Q. J., Chang, S. T., He, F. Y., Yin, Y. H., Qiao, Y. F. (2017). *High-efficiency non-uniformity correction for wide dynamic linear infrared radiometry system. Infrared Physics & Technology* (vol. 85, pp. 395-402).
- [50] Rong, S., Zhou, H., Wen, Z., Qin, H., Qian, K., Cheng, K. (2017). *An improved non-uniformity correction algorithm and its hardware implementation on FPGA. Infrared physics & technology* (vol. 85, pp. 410-420).
- [51] Hu, B. L., Hao, S. J., Sun, D. X., Liu, Y. N. (2017). *A novel scene-based non-uniformity correction method for SWIR push-broom hyperspectral sensors. ISPRS Journal of Photogrammetry and Remote Sensing* (vol. 131, pp. 160-169).

- [52] Li, Y., Jin, W., Li, S., Zhang, X., Zhu, J. (2017). *A method of sky ripple residual nonuniformity reduction for a cooled infrared imager and hardware implementation*. *Sensors* (vol. 17(5), p. 1070).
- [53] Liu, Z., Ma, Y., Fan, F., Ma, J. (2018). *Nonuniformity correction based on adaptive sparse representation using joint local and global constraints based learning rate*. *IEEE Access* (vol. 6, pp. 10822-10839).
- [54] Zhou, D., Wang, D., Huo, L., Liu, R., Jia, P. (2017). *Scene-based nonuniformity correction for airborne point target detection systems*. *Optics Express* (vol. 25(13), pp. 14210-14226).
- [55] Ness, G., Oved, A., Kakon, I. (2017). *Derivative based focal plane array nonuniformity correction*. *arXiv preprint arXiv:1702.06118*.
- [56] Cao, Y., He, Z., Yang, J., Cao, Y., Yang, M. Y. (2017). *Spatially adaptive column fixed-pattern noise correction in infrared imaging system using 1D horizontal differential statistics*. *IEEE photonics journal* (vol. 9(5), pp. 1-13).
- [57] Kuang, X., Sui, X., Liu, Y., Chen, Q., Guohua, G. U. (2017). *Single infrared image optical noise removal using a deep convolutional neural network*. *IEEE photonics Journal* (vol. 10(2), pp. 1-15).
- [58] Wang, S. P. (2016). *Stripe noise removal for infrared image by minimizing difference between columns*. *Infrared Physics & Technology* (vol. 77, pp. 58-64).
- [59] Li, Z., Shen, T., Lou, S. (2016). *Scene-based nonuniformity correction based on bilateral filter with reduced ghosting*. *Infrared Physics & Technology* (vol. 77, pp. 360-365).
- [60] Cao, Y., Yang, M. Y., Tisse, C. L. (2015). *Effective strip noise removal for low-textured infrared images based on 1-D guided filtering*. *IEEE transactions on circuits and systems for video technology* (vol. 26(12), pp. 2176-2188).

- [61] Isoz, W., Svensson, T., Renhorn, I. (2005). *Nonuniformity correction of infrared focal plane arrays*. *Infrared Technology and Applications* (vol. 5783, pp. 949-960).
- [62] Redlich, R., Figueroa, M., Torres, S. N., Pezoa, J. E. (2015). *Embedded nonuniformity correction in infrared focal plane arrays using the Constant Range algorithm*. *Infrared Physics & Technology* (vol. 69, pp. 164-173).
- [63] Qian, W., Chen, Q., Gu, G. (2011). *Minimum mean square error method for stripe nonuniformity correction*. *Chinese Optics Letters* (vol. 9(5), p. 51003).
- [64] Maggioni, M., Sánchez-Monge, E., Foi, A. (2014). *Joint removal of random and fixed-pattern noise through spatiotemporal video filtering*. *IEEE Transactions on Image Processing* (vol. 23(10), pp. 4282-4296).
- [65] Liu, N., Qiu, H. (2014). *A novel scene based non-uniformity correction technology based on projection-based registration*. *2014 International Conference on Information Science, Electronics and Electrical Engineering* (vol. 1, pp. 33-37).
- [66] Li, J., Cao, X., Zhu, B., Yang, G. (2013). *Scene-based nonuniformity correction with adaptively adjusting integration time*. *2013 IEEE Third International Conference on Information Science and Technology (ICIST)* (pp. 1288-1291).
- [67] Tendero, Y., Landeau, S., Gilles, J. (2012). *Non-uniformity correction of infrared images by midway equalization*. *Image Processing On Line* (vol. 2, pp. 134-146).
- [68] Ren, J., Chen, Q., Qian, W., Zuo, C. (2012). *Scene-based nonuniformity correction with multiframe registration*. *2012 Symposium on Photonics and Optoelectronics* (pp. 1-4).
- [69] Celedon, N., Redlich, R., Figueroa, M. (2012). *FPGA-based neural network for nonuniformity correction on infrared focal plane arrays*. *2012 15th Euromicro Conference on Digital System Design* (pp. 193-200).

- [70] Scribner, D. A., Sarkady, K. A., Kruer, M. R., Caulfield, J. T., Hunt, J. D., Herman, C. (1991). *Adaptive nonuniformity correction for IR focal-plane arrays using neural networks. Infrared Sensors: Detectors, Electronics, and Signal Processing* (vol. 1541, pp. 100-109).
- [71] Zhang, T., Shi, Y. (2006). *Edge-directed adaptive nonuniformity correction for staring infrared focal plane arrays. Optical Engineering* (vol. 45(1), p. 16402).
- [72] Ning, Z., Jian, L., Yun, Z., Heran, W., Ning, J., Yadong, J. (2011). *Research on infrared imaging system of UIRFPA based on virtual instrument. IEEE 2011 10th International Conference on Electronic Measurement & Instruments* (vol. 2, pp. 117-120).
- [73] Mou, X., Cui, Q., Zhang, G., Hu, R., Zhou, X. (2010). *Background modeling for adaptive nonuniformity correction in IRFPA. 2010 International Conference on Optics, Photonics and Energy Engineering (OPEE)* (vol. 1, pp. 84-87).
- [74] Redlich, R., Carvajal, G., Figueroa, M. (2011). *An fpga-based real-time nonuniformity correction system for infrared focal plane arrays. ASAP 2011-22nd IEEE International Conference on Application-specific Systems, Architectures and Processors* (pp. 202-208).
- [75] Mou, X., Jia, J., Zhang, G., Hu, R., Zhou, X. (2010). *Adaptive nonuniformity correction in IRFPA using maximum likelihood estimation. 2010 IEEE International Conference on Mechatronics and Automation* (pp. 1665-1668).
- [76] Sosnowski, T., Bieszczad, G., Kastek, M., Madura, H. (2010). *Processing of the image from infrared focal plane array using FPGA-based system. Proceedings of the 17th International Conference Mixed Design of Integrated Circuits and Systems-MIXDES 2010* (pp. 581-586).

- [77] Rossi, A., Diani, M., Corsini, G. (2010). *Temporal statistics de-ghosting for adaptive non-uniformity correction in infrared focal plane arrays*. *Electronics letters* (vol. 46(5), pp. 348-349).
- [78] Dupont, B., Dupret, A., Belhaire, E., & Villard, P. (2009). *FPN sources in bolometric infrared detectors*. *IEEE Sensors Journal* (vol. 9(8), pp. 944-952).
- [79] Wang, B. J., Wang, D. B., Lai, R., Bai, L. P. (2008). *An improved non-uniformity correction algorithm for IRFPA based on neural network*. *2008 Congress on Image and Signal Processing* (vol. 3, pp. 547-551).
- [80] Rossi, A., Diani, M., Corsini, G. (2010). *Bilateral filter-based adaptive nonuniformity correction for infrared focal-plane array systems*. *Optical Engineering*, (vol. 49(5), p. 57003).
- [81] Kumar, A., Sarkar, S., Agarwal, R. P. (2007). *A novel algorithm and FPGA based adaptable architecture for correcting sensor non-uniformities in infrared system*. *Microprocessors and Microsystems* (vol. 31(6), pp. 402-407).
- [82] Zhou, H. X., Qin, H. L., Lai, R., Liu, S. Q. (2007). *Adaptive filtering for nonuniformity correction in infrared focal plane arrays*. *2007 Joint 32nd International Conference on Infrared and Millimeter Waves and the 15th International Conference on Terahertz Electronics* (pp. 510-511).
- [83] Scribner, D. A., Sarkady, K. A., Caulfield, J. T., Kruer, M. R., Katz, G., Gridley, C. J., Herman, C. (1990). *Nonuniformity correction for staring IR focal plane arrays using scene-based techniques*. *Infrared Detectors and Focal Plane Arrays* (vol. 1308, pp. 224-233).
- [84] Kumar, A., Sarkar, S., Agarwal, R. P. (2006). *Correcting infrared focal plane array sensor non uniformities based upon adaptive filter*. *2006 International Conference on Image Processing* (pp. 1537-1540).


- [85] Jian, X. Z., Lu, R. Z., Guo, Q., Wang, G. P. (2016). *Single image non-uniformity correction using compressive sensing. Infrared Physics & Technology* (vol. 76, pp. 360-364).
- [86] Kumar, A., Sarkar, S., Agarwal, R. P. (2007). *A novel algorithm and hardware implementation for correcting sensor non-uniformities in infrared focal plane array based staring system. Infrared physics & technology* (vol. 50(1), pp. 9-13).
- [87] Jian, Y., Ruan, S., Zhou, H., Liu, C. (2006). *An improved nonuniformity correction algorithm for infrared focal plane arrays. 2006 6th World Congress on Intelligent Control and Automation* (vol. 2, pp. 10328-10331).
- [88] Pezoa, J. E., Torres, S. N., Córdova, J. P., Reeves, R. A. (2004). *An enhancement to the constant range method for nonuniformity correction of infrared image sequences. Progress in Pattern Recognition, Image Analysis and Applications: 9th Iberoamerican Congress on Pattern Recognition, (CIARP)* (pp. 525-532).
- [89] Torres, S. N., Vera, E. M., Reeves, R. A., Sobarzo, S. K. (2003). *Adaptive scene-based nonuniformity correction method for infrared-focal plane arrays. Infrared Imaging Systems: Design, Analysis, Modeling, and Testing* (vol. 5076, pp. 130-139).
- [90] Harris, J. G., Chiang, Y. M. (1999). *Nonuniformity correction of infrared image sequences using the constant-statistics constraint. IEEE Transactions on image processing* (vol. 8(8), pp. 1148-1151).
- [91] Scribner, D. A., Sarkady, K. A., Kruer, M. R., Caulfield, J. T., Hunt, J. D., Colbert, M., Descour, M. (1993). *Adaptive retina-like preprocessing for imaging detector arrays. IEEE International Conference on Neural Networks* (pp. 1955-1960).
- [92] Scribner, D. A., Kruer, M. R., Killiany, J. M. (1991). *Infrared focal plane array technology. Proceedings of the IEEE* (vol. 79(1), pp. 66-85).

- [93] Alderson, T., Tener, G. D. (2005). *Scene-based non-uniformity Correction for detector arrays*. U.S. Patent No. US 6,901,173 B2. U.S. Patent and Trademark Office.
- [94] Houchin, J. S., Parulski, K. A. (1991). *Method and apparatus for pixel non-uniformity correction*. U.S. Patent No. US 5,047,861. U.S. Patent and Trademark Office.
- [95] Hara, K., Kubo, H. (2010). *Solid-state imaging device with column amplifier*. U.S. Patent No. US 7,723,661 B2. U.S. Patent and Trademark Office.
- [96] Narendra, P. M. (1980). *Reference-free nonuniformity compensation for IR imaging arrays*. *Smart Sensors* (vol. 252, pp. 10-17).
- [97] Höglund, L., Asplund, C., von Würtemberg, R. M., Kataria, H., Gamfeldt, A., Smuk, S., Costard, E. (2017). *Manufacturability of type-II InAs/GaSb superlattice detectors for infrared imaging*. *Infrared Physics & Technology* (vol. 84, pp. 28-32).
- [98] Teng, Y., Hao, X., Zhu, H., Zhu, H., Liu, J., Huai, Y., Huang, Y. (2021). *Demonstration of MOCVD-grown long-wavelength infrared InAs/GaSb superlattice focal plane array*. *IEEE Access* (vol. 9, pp. 60689-60694).
- [99] Sui, X., Chen, Q., Gu, G. (2013). *Nonuniformity correction of infrared images based on infrared radiation and working time of thermal imager*. *Optik* (vol. 124(4), pp. 352-356).
- [100] Źródła Internetowe: *FLIR LEPTON® Engineering Datasheet* [Online]. https://cdn.sparkfun.com/assets/f/6/3/4/c/Lepton_Engineering_Datasheet_Rev200.pdf

Dodatek A – Układy logiki programowalnej z rodziny FPGA

Układy FPGA stanowią grupę rekonfigurowalnych układów logiki programowalnej (ang. *Programmable Logic Device, PLD*). Ich przemysłowe zastosowanie obejmuje głównie projektowanie układów scalonych. W odróżnieniu od procesorów, implementacje sprzętowe w układach FPGA nie muszą mieć uniwersalnego zastosowania, natomiast mogą być one dedykowane realizacji ściśle określonej funkcjonalności. Wynika to z budowy układów FPGA i sposobu implementacji zadanej struktury logicznej.

Układy FPGA składają się z szeregu konfigurowalnych bloków logicznych (ang. *Configurable Logic Block, CLB*), których zadaniem jest realizacja prostych komponentów logicznych, takich jak multipleksery, bramki logiczne, przerzutniki itp. Bloki CLB są połączone ze sobą siecią magistral, sterowanych przez układy przełączające. Wszystkie bloki logiczne mogą być taktowane dowolnym wejściem, co umożliwia przetwarzanie asynchroniczne, natomiast infrastruktura magistral połączeniowych pozwala na tworzenie niezależnych równoległych ścieżek logicznych. Dzięki temu w układach FPGA możliwe jest przetwarzanie asynchroniczne i równoległe. Schemat układu FPGA przedstawiono na rysunku:



Rys. A.1. Schemat układu FPGA, wraz z przykładowymi ścieżkami propagacji sygnału (żółty, czerwony).

Ponadto, jak wspomniano, struktura logiczna rozwiązania może być dedykowana konkretnemu zastosowaniu, dzięki czemu minimalizowana jest ścieżka propagacji sygnału logicznego oraz ilość komponentów scalonych, przez które musi on być propagowany. Sprawia to, że czas przetwarzania jest znacznie krótszy niż dla procesora lub mikrokontrolera, które są zaprojektowane do pełnienia wielu zgeneralizowanych zadań, a dla których występuje także konieczność rywalizacji o zasoby (np. pamięć tymczasowa), co w układach FPGA może być rozwiązywane w sposób deterministyczny. Można więc uznać, że implementacja sprzętowa w układzie FPGA stanowi rozwiązanie zbliżone optymalnemu, ze względu na czas przetwarzania. Wymienione cechy stanowią o korzystnym zastosowaniu układów FPGA w projektowaniu dedykowanych układów scalonych – rekonfigurowalność układu pozwala na eliminację błędów na etapie projektowania, natomiast wypracowana struktura logiczna może zostać zrealizowana w technologii krzemowej.

Układy FPGA znajdują zastosowanie podczas akceleracji sprzętowej i prototypowaniu implementacji sprzętowych algorytmów przetwarzania strumieni wideo. Odnosi się to także do zagadnień związanych z korekcją niejednorodności matryc bolometrycznych.

Dodatek B – Filtr bilateralny

Filtr bilateralny służy redukcji zakłóceń obszarów jednorodnych obrazu, przy zachowaniu minimalizacji rozmycia krawędzi obiektów. Filtracja jest realizowana poprzez splot cyfrowy obrazu z maską. Wartości wag maski filtru bilateralnego zależą iloczynu dwóch funkcji, natomiast wartość uśrednionego piksela jest wyrażana równaniem:

$$\hat{Y}_{ij} = \frac{\sum_{kl \in \Omega_{ij}} Y_{kl} f(\|Y_{kl} - Y_{ij}\|) g(\|kl - ij\|)}{\sum_{kl \in \Omega_{ij}} f(\|Y_{kl} - Y_{ij}\|) g(\|kl - ij\|)}, \quad (B.1)$$

gdzie:

ij – indeks badanego piksela,

Y – obraz wejściowy,

kl – indeks piksela w należącego do otoczenia wokół piksela ij ,

Ω_{ij} – otoczenie piksela ij ,

$f(\cdot)$ – współczynnik wygładzania zależny od różnicy wartości pikseli,

$g(\cdot)$ – współczynnik wygładzania zależny od odległości piksela względem środka maski.

Funkcje $f(\cdot)$ i $g(\cdot)$, zawarte w równaniu (B.1), określają poziom istotności piksela z otoczenia, uwzględniając dwie wielkości: odległość badanego piksela od środka maski (uśrednianego piksela), mierzona na płaszczyźnie obrazowej oraz różnica intensywności piksela uśrednianego i piksela z otoczenia. Odpowiedni dobór obu funkcji pozwala na zwiększenie poziomu uśredniania w obszarach jednorodnych (o zbliżonych intensywnościach) i zmniejszenie poziomu rozmycia krawędzi.

Dodatek C – Filtr Guided Filter

Filtr GF został zaproponowany w pracy [30], jako alternatywa filtru bilateralnego. Oba filtry cechują się redukcją zakłóceń obszarów jednorodnych, przy zachowaniu wysokiego poziomu szczegółowości obiektów, poprzez redukcję rozmycia krawędzi obiektów. Filtracja jest realizowana poprzez splot cyfrowy obrazu z maską.

Zgodnie z założeniami metody, przyjmuje się, że dodatkową informacją, uwzględnianą przy doborze wag filtracji jest obraz prowadzący (ang. *guidance image*). Zgodnie z pracą [30], przyjmuje się, że w pewnym otoczeniu istnieje liniowa zależność pomiędzy obrazem prowadzącym, a obrazem wynikowym:

$$\hat{Y}_{ij} = AI_{ij} + B, \forall ij \in \Omega_{ij}, \quad (C.1)$$

gdzie:

ij – indeks badanego piksela,

Ω_{ij} – otoczenie piksela ij ,

Y – obraz wejściowy,

I – obraz prowadzący,

A, B – współczynniki równania liniowego, wyrażającego zależność obrazu po filtracji i obrazu prowadzącego, w otoczeniu Ω_{ij} .

Obraz wynikowy jest przyrównywany do obrazu wejściowego filtru, po eliminacji zakłóceń:

$$\hat{Y}_{ij} = Y_{ij} - n_{ij}, \forall ij \in \Omega_{ij}, \quad (C.2)$$

gdzie:

ij – indeks badanego piksela,

Ω_{ij} – otoczenie piksela ij ,

Y – obraz wejściowy,

I – obraz prowadzący,

A, B – współczynniki równania liniowego, wyrażającego zależność obrazu po filtracji i obrazu prowadzącego, w otoczeniu Ω_{ij} .

Przyrównując do siebie równania (2.37 i 2.38) autorzy rozwiązania wyprowadzili model zakłócenia:

$$n_{ij} = Y_{ij} - AI_{ij} - B, \forall ij \in \Omega_{ij}, \quad (C.2)$$

gdzie:

ij – indeks badanego piksela,

Ω_{ij} – otoczenie piksela ij ,

Y_{ij} – wartość piksela obrazu wejściowego,

I_{ij} – wartość piksela obrazu prowadzącego,

A, B – współczynniki równania liniowego, wyrażającego zależność obrazu po filtracji i obrazu prowadzącego, w otoczeniu Ω_{ij} .

Model zakłócenia, opisany równaniem (C.2), stanowi podstawę formuły funkcji kosztów:

$$E(A, B) = \sum_{ij \in \Omega_{ij}} \left((AI_{ij} + B - Y_{ij})^2 + \eta A^2 \right), \quad (C.3)$$

gdzie:

ij – indeks badanego piksela,

Ω_{ij} – otoczenie piksela ij ,

Y_{ij} – wartość piksela obrazu wejściowego,

I_{ij} – wartość piksela obrazu prowadzącego,

A, B – współczynniki równania liniowego, wyrażającego zależność obrazu po filtracji i obrazu prowadzącego, w otoczeniu Ω_{ij} ,

η – parametr ograniczający uzyskiwanie zbyt wysokich wzmocnień.

Funkcja kosztów, opisana równaniem (C.3), ma na celu minimalizację sumarycznego zakłócenia n_{ij} w obserwowanym otoczeniu. Parametr η został

wprowadzony celem zabezpieczenia przed uzyskiwaniem wysokich wartości wzmocnień.

Wynikiem rozwiązania zadania minimalizacji funkcji kosztów metodą regresji liniowej są współczynniki A i B :

$$A = \frac{\frac{1}{|\Omega_{ij}|} \sum_{ij \in \Omega_{ij}} I_{ij} Y_{ij} - \mu \frac{1}{|\Omega_{ij}|} \sum_{ij \in \Omega_{ij}} Y_{ij}}{\sigma^2 + \eta}, \quad (C.4)$$

$$B = \frac{1}{|\Omega_{ij}|} \sum_{ij \in \Omega_{ij}} Y_{ij} - A \mu_k, \quad (C.5)$$

gdzie:

ij – indeks badanego piksela,

Y_{ij} – wartość piksela obrazu wejściowego,

I_{ij} – wartość piksela obrazu prowadzącego,

Ω_{ij} – otoczenie piksela ij ,

A, B – współczynniki równania liniowego, wyrażającego zależność obrazu po filtracji i obrazu prowadzącego, w otoczeniu Ω_{ij} ,

μ – wartość oczekiwana obrazu prowadzącego w otoczeniu Ω_{ij} ,

σ^2 – wariancja obrazu prowadzącego w otoczeniu Ω_{ij} ,

$|\Omega_{ij}|$ - liczba pikseli w otoczeniu Ω_{ij}

η – parametr ograniczający uzyskiwanie zbyt wysokich wzmocnień.

Wynik filtracji jest zależny od przyjętego parametru η (równanie (C.5)) oraz od postaci obrazu prowadzącego I . Jeżeli obrazem prowadzącym jest obraz wejściowy, to usuwane z obrazu są zakłócenia w obszarach jednorodnych, przy zachowaniu ostrości krawędzi obiektów. Parametr η odpowiada za przesunięcie wariancji w celu zmniejszenia wartości parametru wzmocnienia A . Jego zwiększanie powoduje zwiększenie rozmycia jednorodnych obszarów w obrazie wyjściowym.

Dodatek D – Wskaźniki jakości działania metod

Obiektywne podsumowanie wyników wymaga zastosowania wskaźników jakości, które pozwoliłyby na wiarygodne porównanie uzyskanych efektów z efektami, uzyskanymi przez innych badaczy tematyki. W wyniku analizy istniejących rozwiązań można wyróżnić szereg często stosowanych wskaźników jakości. Zdarza się, że możliwość ich zastosowania jest determinowana dostępnością obiektywnych danych porównawczych. Ze względu na ograniczone możliwości ich uzyskania (np. konieczności kalibracji kamery) nie każdy wskaźnik jakości jest użyteczny w tym samym momencie. W podpunktach przytoczono używane w literaturze miary jakości:

D.1. Średni błąd bezwzględny

- Średni błąd bezwzględny, zastosowany w pracach [11], [14], [16], [17], [24], [26] – wymagająca danych referencyjnych miara jakości, określona wartością oczekiwaną wartości bezwzględnej różnic pomiędzy odpowiadającymi sobie pikselami z dwóch obrazów [17], wyrażona równaniem:

$$MAE(I_1, I_2) = \frac{\sum_{i=1}^N \sum_{j=1}^M |I_1(i, j) - I_2(i, j)|}{N * M}, \quad (D.1)$$

gdzie:

I_1, I_2 – porównywane obrazy,

N, M – wymiary obrazów,

i, j – indeks piksela.

D.2. Szorstkość

- Szorstkość (ang. *roughness*), zastosowana w pracach [11], [14], [16], [17], [24], [26] – niewymagająca danych referencyjnych miara jakości, polegająca na wyznaczeniu średniego błędu bezwzględnego pomiędzy obrazem rozmytym i obrazem badanym:

$$S_a = MAE(I_1, I_2), \quad (D.2)$$

gdzie:

MAE – średni błąd bezwzględny,

I_1 – obraz wejściowy,

I_2 – rozmyty obraz wejściowy.

Im mniejsza wartość błędu, tym obraz jest gładszy, jednak należy zaznaczyć, że wartość 0 jest osiągana dla obrazów jednolitych, które nie przekazują praktycznie żadnej informacji o otoczeniu, co nie zawsze jest pożądanym efektem działania algorytmu.

D.3. Podobieństwo strukturalne

- Podobieństwo strukturalne, zastosowane w pracach: [2], [7], [9], [21], [23], [24] – wymagająca danych referencyjnych miara podobieństwa obrazu referencyjnego i obrazu badanego, bazująca na analizie parametrów statystycznych obu obrazów, obejmujące wariancje pikseli w obu obrazach i ich kowariancję, wyrażona równaniem:

$$SSIM(I_1, I_2) = \frac{(2I_1(i, j)I_2(i, j) + C_1)(2\sigma_{I_1 I_2} + C_2)}{(I_1(i, j)^2 + I_2(i, j)^2 + C_1)(\sigma_{I_1}^2 + \sigma_{I_2}^2 + C_2)}, \quad (D.3)$$

gdzie:

I_1, I_2 – porównywane obrazy,

$\sigma_{I_1}^2$ – wariancja obrazu I_1 ,

$\sigma_{I_2}^2$ – wariancja obrazu I_2 ,

$\sigma_{I_1 I_2}^2$ – kowariancja obrazów I_1 i I_2 ,

i, j – indeks piksela,

C_1, C_2 – stałe, zapobiegające dzieleniu przez 0.

D.4. Błąd średniokwadratowy

- Błąd średniokwadratowy, zastosowany w pracach [2], [17] - wymagająca danych referencyjnych miara jakości, określona wartością oczekiwaną

kwadratów różnic pomiędzy odpowiadającymi sobie pikselami z dwóch obrazów, wyrażona równaniem:

$$MSE(I_1, I_2) = \frac{1}{N * M} \sum_{i=1}^N \sum_{j=1}^M (I_1(i, j) - I_2(i, j))^2, \quad (D.4)$$

gdzie:

I_1, I_2 – porównywane obrazy,

N, M – wymiary obrazów,

i, j – indeks piksela.

W literaturze można spotkać się także z wariacjami wskaźnika błędu średniokwadratowego (równanie (D.4)), opisanymi równaniami:

$$RMSE(I_1, I_2) = \sqrt{MSE(I_1, I_2)}, \quad (D.5)$$

$$NRMSE(I_1, I_2) = \frac{1}{I_{MAX}} \sqrt{MSE(I_1, I_2)}, \quad (D.6)$$

gdzie:

$MSE(I_1, I_2)$ – błąd średniokwadratowy,

I_{MAX} – maksymalna możliwa wartość piksela.

Równania (D.5) i (D.6) opisują stosowane pierwiastek błędu średniokwadratowego (równanie (D.5)) oraz znormalizowany pierwiastek błędu średniokwadratowego (równanie (D.6)), przyjmujący wartości z zakresu [0, 1].

D.5. Szczytowy stosunek sygnału do zakłócenia

- Szczytowy stosunek sygnału do zakłócenia, zastosowany w pracach: [1], [2], [7], [9], [14], [17], [21], [23], [24] – wymagająca danych referencyjnych miara określająca na określenie maksymalnej mocy sygnału w relacji do mocy szumu zakłócającego sygnał. Wyrażana w decybelach. Wartość parametru zależy od maksymalnej wartości poziomu szarości w obrazie oraz od błędu średniokwadratowego, wyznaczonego z różnic, pomiędzy

kolejnymi odpowiadającymi sobie pikselami z dwóch obrazów i jest wyrażana zależnością:

$$PSNR(I_1, I_2) = 10 * \log_{10} \frac{I_{MAX}^2}{MSE}, \quad (D.7)$$

gdzie:

MSE – błąd średniokwadratowy,

I_1, I_2 – porównywane obrazy,

I_{MAX} – maksymalna możliwa intensywność piksela.

D.6. Piksele na sekundę

Piksele na sekundę – w literaturze można się spotkać z różnymi sposobami określania przepływności bitowej implementacji, często jest to ilość przetworzonych przez rozwiązanie klatek w ciągu jednej sekundy lub czas przetwarzania pojedynczej klatki obrazu, użyty w pracach: [20], [50], [52], [62], [69] i [74]. Jednak, jednoznaczne porównanie różnych przypadków testowych, przeprowadzanych dla matryc mikrobolometrycznych o różnych rozdzielczościach, stwarza potrzebę unifikacji pomiarów. Proponowaną miarą przepływności implementacji sprzętowej jest częstotliwość uzyskiwania skorygowanych pikseli kolejnych klatek strumienia wideo, wyrażona w hercach, zgodnie z zależnością:

$$PPS = FPS * N * M = \frac{1}{T_f} * N * M, \quad (D.8)$$

gdzie:

N, M – wymiary klatki,


FPS – średnia ilość klatek, przetwarzanych w ciągu jednej sekundy,

T_f – średni czas przetwarzania jednej klatki.

Dodatek E – Wyznaczanie przedziałów przynależności danych na podstawie analizy histogramu

Metoda polega na analizie rozkładów gęstości prawdopodobieństwa zmiennych losowych, na które składają się równoodległe próbkowane dane, uzyskane z każdego mikrobolometru, wchodzącego w skład matrycy. Każdy z mikrobolometrów, wchodzących w skład matrycy posiada własną charakterystykę, dlatego estymacja parametrów charakterystyki jest przeprowadzana dla każdego z nich z osobna. Numerycznym odpowiednikiem rozkładu prawdopodobieństwa takiej zmiennej losowej może być znormalizowany histogram wartości każdego z analizowanych szeregów czasowych.

Rozwiązanie jest oparte o założenie, że sygnał mierzony przez sensor, jest zmienną losową o rozkładzie jednostajnym. Sygnał wejściowy jest przetwarzany z wykorzystaniem pewnej charakterystyki sensora. W przypadku, gdy ta charakterystyka jest liniowa, to otrzymany wynikowy szereg czasowy powinien się także cechować rozkładem jednostajnym. Jeżeli jednak charakterystyka odpowiedzi sensora nie jest liniowa, to rozkład gęstości prawdopodobieństwa badanej zmiennej losowej, uzyskanych po przekształceniu sygnału tą charakterystyką, powinien utracić cechy rozkładu jednostajnego. Przypadek ten został przedstawiony w przykładzie na rysunku:




Rys. E.1. Wpływ przekształcenia zmiennej losowej o rozkładzie jednostajnym ($X \sim U[0,1]$) (A) nieliniową charakterystyką (B). Histogram uzyskanych wyników (C).

Przykład, przedstawiony na rysunku E.1, prezentuje utratę cech rozkładu jednostajnego, na skutek przekształcenia jej wartości z wykorzystaniem nieliniowej charakterystyki.

Należy przy tym pamiętać, że podczas realizacji korekcji niejednorodności metodą statystyczną, bazującą na analizie sceny, niemożliwe jest określenie wartości prawdziwej promieniowania, ze względu na brak odniesienia do rzeczywistej wartości kalibracyjnej. Dlatego całość wnioskowania względem charakterystyki odpowiedzi każdego mikrobolometru musi obejmować jedynie analizę wyjścia sensora, obarczonego zakłóceniami. Analiza odpowiedzi mikrobolometru jest więc jedynym sposobem na uzyskanie informacji o sygnale wejściowym.

Analizując dystrybuantę sygnału wyjściowego można spostrzec, że dla wielkości wejściowych w postaci zmiennej losowej o rozkładzie jednostajnym, jej postać koresponduje z postacią charakterystyki nieliniowej:




Rys. E.2. Zależność pomiędzy dystrybuantą zmiennej losowej (B), powstałej z przekształcenia zmiennej losowej o rozkładzie jednostajnym wybraną nieliniową charakterystyką, a tą charakterystyką (A).

Pełen zakres obserwowanych wartości zmiennej losowej, przedstawionej na rysunku E.2, podzielono na cztery równe części. Nieliniowość charakterystyki powoduje nierównomierną ilość pomiarów, trafiających do poszczególnych przedziałów. Taka sytuacja nie miałaby miejsca w przypadku, gdyby charakterystyka odpowiedzi sensora byłaby liniowa – wtedy do każdego

z przedziałów powinna trafić podobna ilość danych pomiarowych. W przykładzie na rysunku E.2 zobrazowano, jak przy założeniu, że promieniowanie padające na sensor, jest zmienną losową o rozkładzie jednostajnym, prawdopodobieństwo, że pomiar z mikrobolometru trafi do wybranego przedziału odpowiada procentowi charakterystyki, który za pomocą tego przedziału mierzonych próbek można estymować. Takie prawdopodobieństwo może być z powodzeniem liczone w czasie akwizycji obrazu z kamery, jako iloraz liczby próbek, mieszczących się w wybranym przedziale i liczby wszystkich zliczonych próbek.

Porównanie wyników działania metody CR-NUC z podejściem, obejmującym częściowo liniową fragmentaryzację charakterystyki, przedstawiono na rysunku:



Rys. E.3. Analiza graficzna (A) i liczbowa (B) skuteczności zaproponowanego podejścia.

Metody CR-NUC i NCR-NUC, porównane na rysunku E.3, zostały zrealizowane w oparciu o analizę danych, uzyskanych z przekształcenia danych symulowanych, zgodnie z charakterystyką z sekcji B rysunku E.1. Porównanie jakości dopasowania wskazuje na skuteczność proponowanej metody.