

REDUKCJA EFEKTU PLAMKOWANIA NA OBRAZACH RADAROWYCH Z WYKORZYSTANIEM PROPAGACYJNO-SEPARACYJNEGO ALGORYTMU METODY NAJWIĘKSZEJ WIARYGODNOŚCI

DESPECKLING OF SYNTHETIC APERTURE RADAR IMAGES USING PROPAGATION-SEPARATION APPROACH FOR LOCAL LIKELIHOOD ESTIMATION

Jakub Kolecki, Monika Badurska

Katedra Geoinformacji, Fotogrametrii i Teledetekcji Środowiska,
Wydział Geodezji Górniczej Inżynierii Środowiska, AGH, Kraków

SŁOWA KLUCZOWE: SAR, *speckle*, filtry adaptacyjne, TerraSAR-X

STRESZCZENIE: Redukcja szumów na obrazach jest istotnym etapem wstępnego przetwarzania danych. Zagadnienie redukcji szumów było wielokrotnie poruszane w licznych publikacjach naukowych. Przygotowanie danych przed wykonaniem właściwych analiz jest szczególnie ważne w przypadku obrazów radarowych, charakteryzujących się specyficznym szumem (tzw. *speckle effect*), który jest główną przeszkodą w interpretacji i klasyfikacji obrazów radarowych. Do redukcji tego typu szumów zaproponowano w pracy, opublikowaną w roku 2006 przez J. Polzehl i V. Spokoiny, nieparametryczną metodę opartą na stałym, lokalnym wygładzaniu z adaptacyjnym wyborem wag dla każdej pary punktów na obrazie (*Adaptive Weights Smoothing – AWS*). Algorytm AWS nie został do tej pory szczegółowo sprawdzony na obrazach radarowych. Zaproponowana metodyka stosowania algorytmu AWS polega na scaleniu w końcowy wynik przetworzenia trzech obrazów: obrazu oryginalnego i dwóch obrazów stanowiących rezultat działania algorytmu. Do badań wykorzystano zobrazowania wysokorozdzielczego satelity TerraSAR-X, testując rezultaty proponowanego podejścia na obrazach radarowych pozyskanych w różnych trybach, o różnej rozdzielczości i przedstawiających teren o różnym zagospodarowaniu (pola uprawne, obszar miejski). Rezultaty działania badanego algorytmu porównano z wynikami redukcji efektu plamkowania przy użyciu popularnych filtrów adaptacyjnych (filtru Lee i filtru Frost). Otrzymane wyniki potwierdzają przydatność algorytmu AWS jako efektywnego narzędzia redukującego charakterystyczne szumy radarowe.

1. WSTĘP

Zobrazowania radarowe odgrywają ważną rolę w zbieraniu informacji na temat powierzchni ziemi, głównie za sprawą możliwości rejestracji obrazów niezależnie od oświetlenia słonecznego i warunków atmosferycznych. Niestety, obrazy pochodzące z systemów takich jak SAR (ang. *Synthetic Aperture Radar*) charakteryzują się specyficznym efektem plamkowania (tzw. *speckle effect*), który jest dużym ograniczeniem podczas wykonywania segmentacji, klasyfikacji, wykrywania krawędzi czy detekcji cech na tego typu zobrazowaniach. Efekt plamkowania objawia się jako przestrzenna zmienność jasności sąsiednich pikseli (tzw. sól i pieprz) i jest typowy dla

systemów koherentnych, gdzie wartość rejestrowanego sygnału jest wektorową sumą odbić od obiektów znajdujących się wewnątrz komórki rozdzielczości.

Efekt plamkowania można ograniczyć już w procesie tworzenia obrazu radarowego, w wyniku niekoherentnego uśrednienia kilku próbek sygnałów (tzw. *looks*). Proces ten, tzw. *multilooking*, znacznie poprawia rozdzielczość radiometryczną obrazu, ale dzieje się to niestety kosztem rozdzielczości przestrzennej. Im więcej pojedynczych próbek sygnałów (*looks*) zostanie wykorzystanych w procesie tworzenia obrazu SAR, tym stopień zaszumienia jest mniejszy, ale rozdzielczość przestrzenna ulega pogorszeniu. Poza procesem syntezy obrazów SAR, efekt plamkowania najczęściej minimalizowany jest przy pomocy przestrzennych filtrów, z których najpopularniejsze w przypadku obrazów radarowych są filtry adaptacyjne jak np. filtr Lee (Lee, 1980), filtr Frost (Frost et al., 1982), filtr Gamma, filtr Kuan, redukujące szумы i jednocześnie zachowujące krawędzie i cechy obrazu.

Celem pracy nie jest szczegółowy opis działania algorytmu AWS, ale sprawdzenie możliwości jego wykorzystania w przypadku redukcji efektu plamkowania na obrazach radarowych. Ogólna charakterystyka algorytmu jest jednak konieczna do zrozumienia używanych w pracy określeń i oznaczeń Czytelnika pragnącego szerzej zaznajomić się z problematyką estymacji lokalnej przy użyciu algorytmu AWS, zachęcamy do lektury publikacji autorów metody (Polzehl i Spokoiny, 2000; Polzehl i Spokoiny, 2006; Polzehl i Tabelow, 2007).

Praktyczna realizacja badań stała się możliwa dzięki udostępnieniu w internecie biblioteki języka R – *adimpro* (CRAN).

2. OGÓLNA CHARAKTERYSTYKA PROPAGACYJNO-SEPARACYJNEGO PODEJŚCIA DO LOKALNEJ METODY NAJWIĘKSZEJ WIARYGODNOŚCI

Metody lokalnej estymacji stosuje się, jeżeli dana wielkość nie może być estymowana w oparciu o wszystkie dostępne dane, a jedynie w oparciu o pewną ich część, reprezentatywną w danym punkcie. W przypadku redukcji efektu plamkowania na obrazach radarowych, wielkością estymowaną jest jasność konkretnego piksela. Estymacja dokonywana jest na podstawie wartości jasności sąsiednich pikseli, a więc w sposób lokalny a nie globalny. Ważne jest również, aby estymator uwzględniał nieciągłości estymowanej funkcji jasności, biorąc pod uwagę obecność krawędzi.

Metoda adaptacyjnej redukcji szumu (Polzehl i Spokoiny, 2000) oparta jest na algorytmie AWS (ang. *Adaptive Weights Smoothing*). Głównym założeniem metody jest określenie dla każdego z pikseli sąsiedztwa, zawierającego dane, które mogą być wykorzystane do określenia parametrów rozkładu jasności w danym punkcie. Przykładowo, do sąsiedztwa piksela leżącego blisko krawędzi nie mogą być włączone piksele leżące po jej drugiej stronie, natomiast sąsiedztwo to może rozciągać się dużo dalej w przeciwnym kierunku. Zakładając normalny rozkład jasności, estymowany parametr będzie określał jego wartość przeciętną. Przynależność pikseli X_j do sąsiedztwa piksela X_i , którego jasność estymujemy, będzie określana poprzez podanie zestawu wag w_{ij} . AWS jest algorytmem iteracyjnym i podczas każdej iteracji wyznaczanych jest tyle zestawów wag ile pikseli posiada obraz. Estymowana jasność liczona jest jako średnia ważona. Z kolejnym krokiem iteracji zwiększa się sąsiedztwo

każdego z pikseli X_i , które definiowane jest przez podanie promienia. Jeżeli promień osiągnie wartość maksymalną, równą h^* , następuje zakończenie obliczeń. Propagacyjna natura algorytmu AWS wyraża się poprzez swobodę z jaką sąsiedztwo piksela X_i może się powiększać. Dobór wag w obrębie sąsiedztwa jest jednak uzależniony od różnic jasności, estymowanych w kolejnych etapach iteracji. Jest to przejaw separacyjnej natury algorytmu, która kontrolowana jest poprzez parametr λ . Im wyższa wartość λ , tym mniejsza wrażliwość na różnice w estymowanych jasnościach.

3. OBSZAR TESTOWY I DANE ŹRÓDŁOWE

Do przeprowadzenia badań wykorzystano zobrazenia wysokorozdzielczego satelity radarowego TerraSAR-X. Fragmenty obrazów, na których przeprowadzono testy, wybrano tak, aby w miarę możliwości reprezentowały obrazy pozyskane w różnych trybach obrazowania o różnej rozdzielczości przestrzennej i różnym zagospodarowaniu terenu.

W przypadku zobrażeń satelity TerraSAR-X, istnieją dwie strategie przetwarzania obrazów. Pierwsza grupa produktów oznaczona skrótem RE (ang. *Radiometrically Enhanced Product*) jest zoptymalizowana ze względu na rozdzielczość radiometryczną. W tym przypadku rozdzielczość przestrzenna jest celowo zmniejszona, aby znacznie zredukować występujący na obrazie efekt plamkowania przez uśrednienie około 6 próbek. Natomiast druga grupa produktów, oznaczona skrótem SE (ang. *Spatially Enhanced Product*) jest zoptymalizowana pod względem jak najlepszej rozdzielczości przestrzennej, ale kosztem dużej ziarnistości obrazu.

W celu przeprowadzenia doświadczeń wybrano fragmenty dwóch obrazów radarowych, różniących się trybem przetwarzania, rozdzielczością przestrzenną oraz zagospodarowaniem terenu. Pole testowe A przedstawia obszar miejski, natomiast pole testowe B pola uprawne. Szczegóły dotyczące poszczególnych fragmentów przedstawione są w tabeli 1.

Tabela 1. Charakterystyka pól testowych

Nazwa pola testowego	Wielkość pola testowego [ha]	Tryb obrazowania	Tryb przetwarzania	Rozdzielczość [m]	Wielkość piksela [m]
Test A (Rys. 1)	200	SL – SpotLight	SE	1.7	0.75
Test B (Rys. 2)	250	SM – StripMap	RE	9.4	4.0

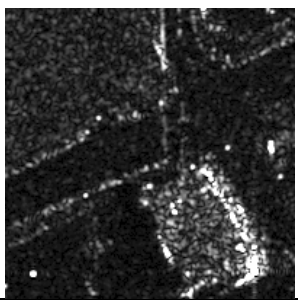
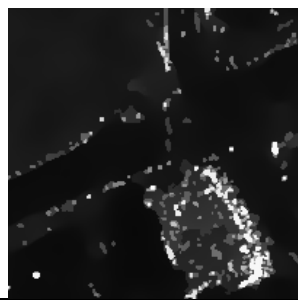
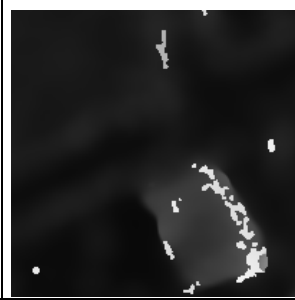
4. METODYKA STOSOWANIA ALGORYTMU AWS DO REDUKCJI EFEKTU PLAMKOWANIA

Jak wynika z opisu algorytmu AWS (Rozdz. 2), Kluczową rolę w procesie redukcji szumu odgrywają parametry h^* i λ . Obraz radarowy cechuje się wysokim stosunkiem szumu do sygnału, dlatego też metoda daje dobre wyniki przy większych wartościach parametru λ . Przy dużych wartościach parametru, zyskujemy mniejszą wrażliwość na będące efektem szumu, duże skoki jasności. Jeżeli przyjmujemy zbyt małą wartość λ , a jednocześnie przyjmujemy dużą wartość maksymalnego promienia sąsiedztwa (h^*),

sprawimy, że plamki szumu mogą zostać potraktowane jako fragmenty obrazu o stałej jasności, co doprowadzi to powstania sztucznych krawędzi.

Przyjmując wysoką wartość parametrów λ oraz h^* uzyskujemy obraz bardzo silnie wygładzony, na którym zachowane mogą być tylko wyraźne krawędzie. Zmniejszając parametr λ należy spodziewać się wychwycenia większej ilości krawędzi. Niektóre rozpoznane przez algorytm nieciągłości mogą wtedy stanowić odzwierciedlenie tekstury danego fragmentu obrazu. Proponowana metoda polega na scaleniu w końcowy wynik przetworzenia, trzech obrazów: α , β i γ . Obraz α to obraz oryginalny. Obraz β jest wynikiem redukcji szumu przy umiarkowanej wartości parametru λ . Obraz γ uzyskujemy przyjmując wysoką wartość λ . Tabela poniżej (Tabela 2) pokazuje przykładowe fragmenty każdego z obrazów α , β oraz γ , użyte do redukcji szumów na obrazie testowym A.

Tabela 2. Fragment obrazu oryginalnego oraz obrazów po redukcji szumu metodą AWS wraz z podanymi parametrami algorytmu

		
α - obraz oryginalny	β - obraz przetworzony: $h^*=20, \lambda=4$	γ - obraz przetworzony: $h^*=20, \lambda=10$

Obraz γ posiada zachowane jedynie bardzo wyraźne krawędzie. Stanowi przybliżenie ogólnego rozkładu jasności na obrazie oryginalnym. Obraz β ma wyróżnioną większą ilość krawędzi. Niesie ponadto informację o wyraźniejszych elementach tekstury. Końcowy wynik przetworzenia otrzymujemy obliczając kombinację liniową wszystkich trzech obrazów:

$$\delta = \frac{g_{\alpha}\alpha + g_{\beta}\beta + g_{\gamma}\gamma}{g_{\alpha} + g_{\beta} + g_{\gamma}} \quad (1)$$

Do kombinacji tej włączany jest również obraz oryginalny, gdyż niesie on pełną informację o teksturze i krawędziach. Jego obecność we wzorze (1) pozwala uzyskać dobry efekt wizualny. Dobierając odpowiednie współczynniki g możemy modyfikować udział obrazów α , β i γ w końcowym wyniku (δ). Przykładowo, chcąc uzyskać obraz łagodnie wygładzony, o dobrze oddanej teksturze należy przyjąć większą wartość współczynnika g_{α} . Jeżeli zależy nam na silnym wygładzeniu obrazu, przyjmujemy wysoką wartość g_{γ} . Przykładowe rezultaty redukcji szumu na obrazie radarowym wyżej opisaną metodą przedstawiono w tabeli (Tabela 3).

Tabela 3. Rezultat redukcji efektu plamkowania na przykładzie fragmentu obrazu radarowego, przy zastosowaniu wzoru (1) w zależności od doboru współczynników g




Tabela 4 podaje wartości parametrów λ i h^* wykorzystane do utworzenia obrazów β , γ dla każdej z trzech próbek. Proponowany algorytm redukcji szumu opiera się na obliczeniu kombinacji liniowej obrazów przetworzonych z wykorzystaniem algorytmu AWS, dlatego w dalszej części będziemy go określać skrótem k.l. AWS (kombinacja liniowa AWS).

Tabela 4. Zestawienie wartości parametrów h^* i λ wykorzystanych do utworzenia obrazów β i γ dla każdej z próbek

	Próbka A		Próbka B	
	h^*	λ	h^*	λ
β	20	4.0	15	2.3
γ	20	10.0	20	3.0


5. KRYTERIA OCENY ALGORYTMU

5.1. Redukcja zjawiska *speckle*

Intensywność zjawiska *speckle* jest najczęściej charakteryzowana parametrem (*ENL Equivalent number of looks*), który wykorzystywany jest jako miara stopnia redukcji szumu. Im wyższa jest wartość *ENL*, tym silniejsze jest wygładzenie obrazu. *ENL* liczone jest jako stosunek kwadratu średniej do wariancji:

$$ENL = \frac{\mu^2}{\sigma^2} \quad (2)$$

Wartości *ENL* obliczono dla wyselekcjonowanych obszarów o jednolitej jasności, pozbawionych krawędzi. (Rys. 6).



Rys. 6. Obrazy testowe A (węzeł drogowy) oraz B (pola uprawne) wraz z wyselekcjonowanymi polami do badania współczynników ENL oraz NM

5.2. Zachowanie średnich wartości tonalnych

Podstawą dobrego filtru redukującego zjawisko *speckle* na obrazach radarowych jest zachowanie średniej wartości współczynnika wstecznego rozpraszania dla jednorodnych obszarów. Stopień zachowania średnich wartości tonalnych można scharakteryzować posługując się parametrem NM (ang. *Normal Mean*). NM jest stosunkiem średniej jasności pikseli dla obszaru jednorodnego, wyznaczonej dla obrazu przetworzonego i obrazu oryginalnego.

$$NM = \frac{\mu_{filtr}}{\mu_{oryginal}} \quad (3)$$

Wartość NM wyznaczano tylko dla wyselekcjonowanych obszarów o jednolitej jasności, pozbawionych krawędzi. (Rys. 6).

5.3. Zachowanie krawędzi

Ważną cechą każdej metody redukującej szum na obrazach radarowych jest jej zdolność do zachowywania naturalnych skoków intensywności w obrębie krawędzi. Rozmywanie krawędzi jest cechą niepożądaną. Stopień zachowania krawędzi (*Edge Preservation – EP*) został określony dla każdej z testowanych metod. Jego miarą był średni stosunek wartości gradientu dla pikseli należących do krawędzi, po i przed redukcją szumów. W celu określenia współczynnika EP wyselekcjonowano na oryginalnych obrazach piksele należące do kilku krawędzi.

6. WYNIKI

W celu oceny przydatności algorytmu AWS do redukcji efektu plamkowania na obrazach radarowych, przetworzono obrazy testowe używając wybranych filtrów

wyglądających, algorytmu AWS oraz k.l. AWS. Następnie dla wyselekcjonowanych pól (Rys. 6) obliczono współczynniki ENL i NM . Dla krawędzi testowych obliczono współczynnik EP . Z powodu ograniczonego miejsca w tabelach pokazano tylko niewielkie fragmenty przetworzonych obrazów testowych (Tabela 5, Tabela 6). Fragmenty te ukazują charakterystyczne różnice pomiędzy obrazami przetworzonymi przy użyciu metody filtracji dającej dobre dla danego fragmentu obrazu efekty (filtr Lee), oraz z wykorzystaniem k. l. AWS.

Tabela 5. Porównanie wyników redukcji szumu z użyciem filtru Lee oraz k.l. AWS dla fragmentu testu A. Strzałki pokazują miejsca o różnym stopniu redukcji zjawiska *speckle*





Tabela 6. Porównanie wyników redukcji szumu z użyciem filtru Lee oraz k.l. AWS dla fragmentu testu B. Strzałki ilustrują różnice w ostrości krawędzi

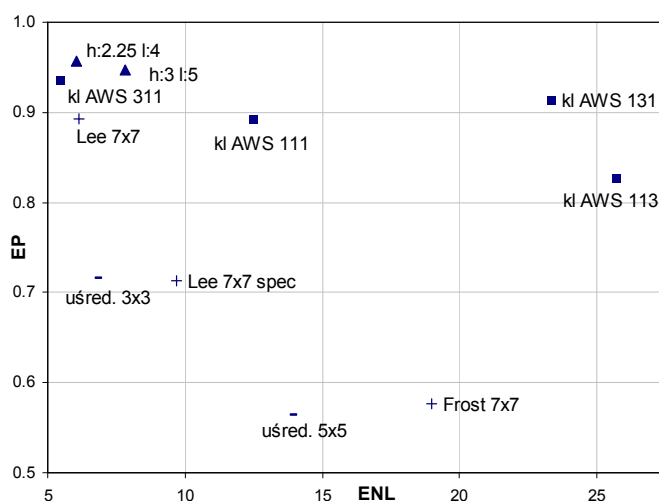


Zestawienie wartości współczynnika NM wraz ze średnią wartością jasności wyselekcjonowanych pól (Rys. 1) zostały przedstawione w tabeli (Tabela 7). Natomiast uzyskane wartości współczynników EP oraz ENL zaprezentowano w formie wykresów (Rys. 2, Rys. 3), gdzie wartości ENL podano jako średnie ze wszystkich pól danej próbki a wartości EP są średnimi dla wszystkich krawędzi testowych poszczególnych próbek.

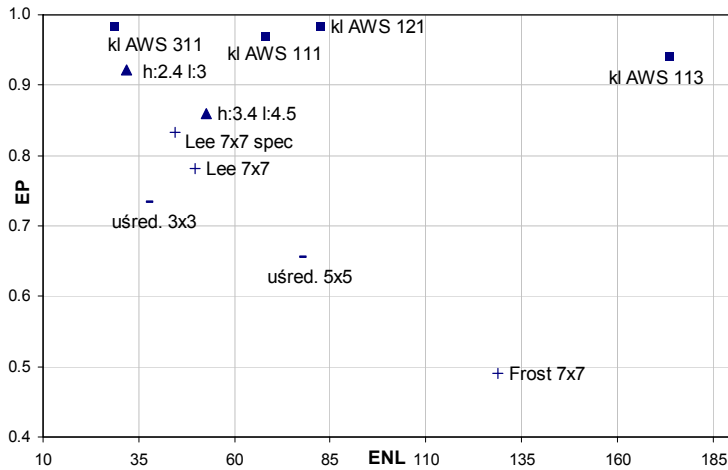
Tabela 7. Wartości współczynnika NM dla każdego z pól testowych przy zastosowaniu różnych metod wygładzenia obrazu. Dla kombinacji liniowej AWS trzycyfrową liczbę należy rozumieć następująco: pierwsza cyfra oznacza współczynnik g_α , druga g_β , trzecia g_γ , tak jak we wzorze (1). Średnie jasności podano jako znormalizowane

próbka A		filtr uśred. 3x3	AWS $h^* = 3 \lambda = 5$	Lee	Frost	k.l. AWS 111	k.l. AWS 311	k.l. AWS 113
nr pola	śr. jasn.							
1	0.10	1.00	0.98	1.00	0.98	0.85	0.89	0.81
2	0.04	1.00	0.95	1.00	0.95	0.62	0.72	0.53
3	0.19	1.00	0.98	1.00	0.99	0.92	0.94	0.91
4	0.09	1.00	0.98	1.00	0.98	0.84	0.88	0.81

próbka B		filtr uśred. 3x3	AWS $h^* = 2.4 \lambda = 3$	Lee	Frost	k.l. AWS 111	k.l. AWS 311	k.l. AWS 113
nr pola	śr. jasn.							
1	0.57	1.00	1.00	1.01	1.02	0.97	0.93	0.99
2	0.57	1.00	1.00	1.01	1.01	0.96	0.92	0.98
3	0.29	1.00	0.97	1.01	1.02	0.87	0.81	0.91



Rys. 7. Średnie współczynniki ENL oraz EP uzyskane dla próbki A przy różnych metodach filtracji: "-" – filtry uśredniające, "+" – filtry adaptacyjne, "■" – k. l. AWS (pierwsza cyfra oznacza współczynnik g_α , druga g_β , trzecia g_γ), "▲" – AWS (podano wartości współczynników h^* oraz λ)



Rys. 8. Średnie współczynniki ENL oraz EP uzyskane dla próbki B przy różnych metodach filtracji: "-" – filtry uśredniające, "+" – filtry adaptacyjne, "■" – k. l. AWS (pierwsza cyfra oznacza współczynnik g_α , druga g_β , trzecia g_γ), "▲" – AWS (podano wartości współczynników h^* oraz λ)

7. PODSUMOWANIE

Analiza wartości pokazanych na rysunkach 2 i 3 pozwala stwierdzić, że dla punktów reprezentujących daną grupę metod redukcji szumu, wraz ze wzrostem wartości parametru ENL maleje wartość EP . Oznacza to, że podczas redukcji zjawiska *speckle* nie udaje się uniknąć efektu rozmycia krawędzi. Metodą dającą dużą odporność przed tym niepożądanym efektem jest kombinacja liniowa AWS. W przypadku próbki B (Rys. 3), udało się utrzymać współczynnik EP na poziomie powyżej 0.9 mimo bardzo wysokich wartości współczynnika ENL . Tendencję spadkową można uznać w tym przypadku za znikomą. Analizując wyniki dla próbki A, również widać dużą przewagę k.l. AWS. Efekt rozmycia krawędzi przez filtr adaptacyjny Lee pokazano za pomocą strzałek na obrazach (Tabela 6). Obrazy zamieszczone w tabeli (Tabela 5) pokazują skuteczniejszą redukcję szumu poprzez algorytm k.l. AWS (strzałka). Na wykresach (Rys. 2, Rys. 3) widać również wpływ przyjęcia różnych wartości współczynników g . Wysoki współczynnik g_γ pozwala uzyskać wysokie wartości ENL .

Wykonując redukcję szumu samym algorytmem AWS, bez uwzględniania kombinacji liniowej, również zaznacza się przewaga nad filtrami adaptacyjnymi oraz uśredniającymi. Tu należy jednak zaznaczyć, że wizualne porównanie wyników przemawia na korzyść filtrów adaptacyjnych. Kiedy zjawisko *speckle* jest bardzo silne, poszczególne „plamki” mogą być potraktowane przez algorytm AWS jako pola o jednakowej jasności co prowadzi do ich uwypuklenia. Zjawisko to można wyeliminować zwiększając współczynnik λ . Algorytm AWS daje dobre rezultaty w przypadku obrazów dla których zjawisko *speckle* zostało już zredukowane podczas syntezy obrazów SAR, w wyniku niekoherentnego uśrednienia większej liczby próbek sygnału (produkt RE, próbka B). Podobnie jak k.l. AWS, samo przetwarzanie metodą AWS pozwala dobrze zachować krawędzie. Dotyczy to szczególnie krawędzi o dużej

wartości gradientu. Krawędzie o małej wartości gradientu są bardziej podatne na rozmywanie. Wynika to wprost z propagacyjno-separacyjnej natury algorytmu AWS.

Przetwarzając obrazy radarowe z wykorzystaniem linowej kombinacji AWS otrzymano słabsze wartości współczynnika NM niż w przypadku pozostałych algorytmów, gdzie jego wartość w praktyce uznać można za równą jedności. Małe wartości współczynnika NM w przypadku k.l. AWS występują dla obszarów ciemniejszych. Dla takich rejonów nawet niewielka zmiana jasności powoduje gwałtowny skok wartości NM . Gorsze wyniki odnotowano także przyjmując wysoki współczynnik g_r .

Metoda redukcji szumów na obrazach polegająca na obliczeniu kombinacji liniowej z wyników działania algorytmu AWS pozwala w łatwy sposób kontrolować zamierzony efekt. Jako wynik otrzymujemy obraz o zredukowanym zjawisku *spec kle* a przede wszystkim o bardzo dobrze zachowanych krawędziach. Należy się jednak liczyć ze zmianą średniej jasności poszczególnych obszarów. Stosowanie k.l. AWS jest skomplikowane z praktycznego punktu widzenia gdyż w pierwszej kolejności wymaga przetworzenia obrazu algorytmem AWS, który posiada dwa parametry wejściowe. Obliczenie k.l. wymaga sprecyzowania dalszych trzech parametrów. Proponowaną metodę należy polecać w przypadkach, kiedy bardzo ważny jest aspekt zachowania krawędzi przy jednoczesnym zredukowaniu zjawiska *speckle*.

Praca została wykonana w ramach badań statutowych AGH nr 11.11.150.949.

8. LITERATURA

Lee J. S., 1980. Digital Image Enhancement and Noise Filtering by Use of Local Statistics. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. PAMI-2, s. 165-168

Frost V. S., Stiles J. A., Shanmugan K. S., Holtzman J.C., 1982. A Model for Radar Images and Its Application to Adaptive Digital Filtering of Multiplicative Noise. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. PAMI-4, s.157-166

Polzehl J., Spokoiny V. G., 2000. Adaptive weights smoothing with applications to image restoration. *Journal of the Royal Statistical Society*, B 62, Part 2, s. 335-354

Polzehl J., Spokoiny V. G., 2006. Propagation-Separation Approach for Local Likelihood Estimation. *Probability Theory and Related Fields*, 135, s. 335-362.

Polzehl J., Tabelow K., 2007. Adaptive Smoothing of Digital Images: The R Package *adimpro*. *Journal of Statistical Software*, Vol. 19.

Xiao J., Li J., Moody A., 2003. A detail preserving and flexible adaptive filter for speckle suppression in SAR imagery. *INT. J. Remote Sensing*, Vol. 24, No. 12, 2451-2465, Taylor&Francis

CRAN – The Comprehensive R Archive Network: <http://cran.rakanu.com/>

DESPECKLING OF SYNTHETIC APERTURE RADAR IMAGES USING PROPAGATION-SEPARATION APPROACH FOR LOCAL LIKELIHOOD ESTIMATION

KEY WORDS: SAR, speckle, adaptive filter, TerraSAR-X

Summary

Solving the problem of image smoothing is regarded as an essential stage in preparing digital images for further processing. It was tackled by a number of studies. The presence of speckle noise in SAR images is the major obstacle in interpreting, classifying, and analyzing SAR images. The main problem in many remote sensing applications is the extraction and interpretation of information about the objects which are present on SAR images. This makes the speckle noise reduction a very important task. The reduction of speckles was performed by applying the nonparametric method, described by J. Polsehl and V. Spokoiny in 2006; the method is based on locally constant smoothing with an adaptive choice for every pair of data points (Adaptive Weights Smoothing – AWS). The AWS algorithm has never been tested in detail on SAR data. This paper describes the methodology of using the AWS algorithm by integrating three images: one original image and two images determining the result of the algorithm processed. The performance of the proposed method was tested on high-resolution X-band synthetic aperture radar TerraSAR-X images and was compared with popular adaptive filters (Lee, Frost). The method presented was tested on two samples extracted from images captured in different imaging modes, with different geometric resolution and showing various land use and land cover. The results confirm the utility of the propagation-separation approach for radar image smoothing.

mgr inż. Jakub Kolecki
e-mail: kolecki@agh.edu.pl
tel. 012 617 39 93

mgr inż. Monika Badurska
e-mail: monika.badurska@gmail.com
tel. 012 617 39 93