

# Paweł Ksieniewicz

---

## Entropodynamiczny filtr percentylowy

---

Edukacja - Technika - Informatyka nr 2(24), 311-317

---

2018

Artykuł został opracowany do udostępnienia w internecie przez Muzeum Historii Polski w ramach prac podejmowanych na rzecz zapewnienia otwartego, powszechnego i trwałego dostępu do polskiego dorobku naukowego i kulturalnego. Artykuł jest umieszczony w kolekcji cyfrowej [bazhum.muzhp.pl](http://bazhum.muzhp.pl), gromadzącej zawartość polskich czasopism humanistycznych i społecznych.

Tekst jest udostępniony do wykorzystania w ramach dozwolonego użytku.



**PAWEŁ KSIENIEWICZ**

## **Entropodynamiczny filtr percentylowy**

---

### **Entropodynamic Percentile Filter**

Doktor inżynier, Politechnika Wroclawska, Wydział Elektroniki, Katedra Systemów i Sieci Komputerowych, Polska

#### **Streszczenie**

W pracy opisano implementację oraz analizę eksperymentalną algorytmu Entropodynamicznego Filtra Percentylowego, pozwalającego na detekcję szumu w obrazach o wielu składowych spektralnych. Kostka danych wizualnych jest przetwarzana tak, aby wygenerować, niezależnie dla każdej składowej spektralnej, mapę krawędzi, która pozwala na oszacowanie informacji o rozkładzie entropii w spektrum. Filtr percentylowy oddziela nośniki szumu od warstw wysoce informacyjnych. Jakość metody jest weryfikowana dzięki serii testów wykonanych dla zadania klasyfikacji.

**Słowa kluczowe:** obrazowanie nadwidelmowe, redukcja cech, uczenie maszyn, przetwarzanie obrazów, klasyfikacja

#### **Abstract**

Following work describes the implementation and experimental evaluation of the Entropodynamic Percentile Filter algorithm, allowing the detection of noise in images with many spectral components. The visual data block is processed to generate an edge map, independent of each spectral component, which makes possible the estimation of the information on the distribution of entropy in the spectrum. An appropriately constructed percentile filter separates noise carriers from highly informative layers. The quality of the method is verified with a series of experiments performed for the classification task.

**Keywords:** hyperspectral imaging, feature reduction, machine learning, image processing, classification

---

#### **Wstęp**

Dane obrazowe mogą być pozyskiwane w sposób przekraczający ograniczenia ludzkiego postrzegania. W ostatnim ćwierćwieczu XX w. nasiliły się badania w zakresie obrazowania wielo- oraz nadwidelmowego (Green, Eastwood, Sarture, Chrien, Aronsson, Chippendale i in., 1998). Dane tego typu generowane są przez sensory czułe w znacznie szerszym i gęściej próbkowanym widmie spektralnym niż rejestrowalne przez ludzkie oko (Wei, Bioucas-Dias, Dobigeon, Tournet,

2015). Jeden z najpopularniejszych, spektrometr AVIRIS, rejestruje obrazy o 224 pasmach, w zakresie 0,4–2,5  $\mu\text{m}$ . Czyni to z niego cyfrowe oko z ponad dwustoma odmianami fotoreceptorów, pokrywającymi ponad czternastokrotnie szersze pasmo promieniowania elektromagnetycznego niż to dostępne dla człowieka (Fauvel, Tarabalka, Benediktsson, Chanussot, Tilton, 2013). Odpowiednikiem wektora koloru w obrazach nadwidmowych są sygnatury spektralne. Pomimo zysków w rozszerzaniu informacji o prezentowanych scenach (Ertürk, 2016) akwizycja w tego typu danych jest silnie zaburzona przez wiele zanieczyszczeń.

Jeśli każde pasmo pozyskane przez spektrometr opisuje wąski zakres widmowy, każdy przypadek absorpcji fotonów przez cząsteczki wody może zredukować wartość informacji do zaledwie 15%. Podnosi to współczynnik sygnał-do-szumu powyżej poziomu rozróżnialności (Moses, Bowles, Lucke, Corson, 2012; Stumpf, Werdell, 2010). Należy także pamiętać o technice detekcji krawędzi (Aggarwal, Majumdar, 2016). Odrzucenie silnie mieszących klasy pikseli, znajdujących się na krawędziach obszarów, może mieć pozytywny wpływ na jakość metod rozpoznawania wzorców (Perona, Malik, 1990).

Artykuł został wygłoszony jako referat w ramach konferencji kół studenckich STUKNUT, a wyniki zawarte w pracy są związane z realizacją projektów w ramach działalności Koła Naukowego Systemów Informatycznych i Sieci Komputerowych.

## **Konstrukcja przetwarzania**

### *Pasmowa detekcja krawędzi*

Zaproponowana procedura wykrywania krawędzi opiera się na analizie lokalnych odchyień pasm sygnatur (Davies, 2004). Każdy przekrój sześcienu HSI przekształcany jest w strukturę, mapy różnorodności lokalnej, gdzie każdy piksel reprezentowany jest jako rozstęp ćwiartkowy najbliższej okolicy, zakreślonej przez zadany element strukturalny ( $s$ ) (Dougherty, 1992).

$$\text{map}(x, y, b) = IQR(\{HSI(x', y', b) \mid (x', y') - (x, y) \in s\}),$$

gdzie  $(x, y)$  określa położenie przestrzenne punktu na mapie różnorodności,  $(x', y')$  jest lokalizacją porównywalnych punktów, a  $b$  określa pasmo widmowe.

Dla większości pasm mapa różnorodności prawidłowo rozpoznaje krawędzie separujące regiony. Wysoki lub niski lokalny kontrast może wskazywać, że widoczne granice zależą tylko od skali przemieszania sygnatury. Niektóre z pasm wydają się całkowicie bezużyteczne – zawierają głównie szum. Mapy utworzone dla wszystkich pasm są zbierane w trójwymiarowej macierzy, stosu różnorodności.

## **Entropodynamiczny Filtr Percentylowy**

Do wykrycia szumu w obrazie wielospektralnym można wykorzystać informację zawartą w mapach różnorodności. Te z przestrzenną dominacją białych

i czarnych linii zawierają wysoce uporządkowane dane, podczas gdy te zdominowane przez szarości to głównie obrazy szumu. Możemy założyć, że z każdej mapy można obliczyć entropię pasma. Propozycją miary entropii obrazu nadwzrostowego ( $H$ ) jest odległość pomiędzy medianą ( $Q_2(x)$ ) a zadanym percentylem ( $F^{-1}(x, p)$ )


$$H(b) = | Q_2(\text{map}(b)) - F^{-1}(\text{map}(b), p) |.$$

Większość zaszumionych zakresów została odpowiednio odseparowana, choć nachylenia wzgórz entropii nie są czasami wykrywane. W celu uodpornienia algorytmu na szybkie zmiany entropii obliczono również wektor pomocniczy zmiany entropii z pasma na pasmo ( $H'$ )

$$H'(b, i) = | H(b, i) - H(b, i - 1) |,$$

gdzie  $i$  jest indeksem pasma.

Końcowy filtr jest logiczną unią filtrów percentylowych entropii i jej dynamiki. Wykorzystanie go względem sygnatur spektralnych wszystkich klas obecnych w obrazie *Salinas* przedstawione zostało na rys. 1.



**Rysunek 1. Reprezentatywne sygnatury spektralne obrazu Salinas z filtrem EPF**

Źródło: opracowanie własne.

Zgodnie z ilustracją pasma, w których sygnatury klas były wysoce nieróżnialne (odległości między sygnaturami bliskie zero), zostały odfiltrowane. Algorytm usuwa wszystkie wyszarzone pasma z sześcianu danych, co skutkuje końcową, zredukowaną kolekcją cech.

### *Maksymalna mapa krawędzi*

Po prawidłowym filtrowaniu możemy zmierzyć się z problemem wyliczania mapy krawędzi dla całego obrazu. Proponowane były trzy podejścia, średnia, mediana i maksymalną wartość otrzymanego stosu różnorodności. Ich wersje, utworzone na stosie różnorodności zredukowanej kostki danych, pokazano na

rys. 2. Mapa maksymalnej wartości, wyciszczona z dominującego wpływu szumów, jest najbardziej kontrastującym i czytelnym wynikiem z rozważanych podejść.



**Rysunek 2. Końcowa, maksymalna mapa krawędzi po wygładzeniu i dylatacji**

Źródło: opracowanie własne.

### *Maska krawędzi*

Maska krawędzi jest dwuwymiarową tablicą logiczną odpowiadającą wymiarom przestrzennym kostki HSI. Aby ją otrzymać, wykorzystuje się próg warunku, wyznaczony jako wartość zadanego percentyla z mapy krawędzi oraz późniejsza jednostkowa dylatacja binarna.

## **Ewaluacja eksperymentalna**

*Eksperyment 1. Skala filtrowania w zależności od wielkości elementu strukturalnego oraz wybranego percentyla odcięcia*

Ocenę proponowanej metody zrealizowano w bibliotece *Weles*, wykorzystując klasyfikatory referencyjne, zgodnie z implementacją w *scikit-learn* (Pedregosa, Varoquaux, Gramfort, Michel, Thirion, Grisel i in., 2011).

W eksperymencie oblicza się skalę filtrowania w zależności od zadanego percentyla i rozmiaru elementu strukturalnego. Ponieważ zwiększenie rozmiaru elementów strukturalnych znacznie zwiększa czas obliczeniowy, pozwoli wybrać jego właściwą wartość dla dalszych eksperymentów.

*Obserwacje:* Istnieje ścisła zależność pomiędzy percentylem a skalą filtrowania, obserwowalna dla obrazów pochodzących z różnych spektrometrów. Skala filtrowania wydaje się niezależna od wielkości elementów strukturalnych. Dalsze eksperymenty powinny zostać zaprojektowane przy użyciu elementu strukturalnego 2x2.

*Eksperyment 2. Wpływ wybranego percentyla odcięcia na jakość klasyfikacji*

Odpowiednie filtrowanie zaszumionych pasm z sygatur spektralnych eliminuje zbędne cechy analizowanych próbek. Prowadzi to nie tylko do skrócenia czasu budowania modelu klasyfikatora, ale również może mieć wpływ na dokład-

ność klasyfikacji. Zbyt restrykcyjne odcinanie może także usunąć pasma zawierające informacje, zmniejszając zdolność dyskryminacyjną algorytmów. Istotą kalibracji EPF jest wybranie percentyla maksymalizującego skuteczność późniejszej klasyfikacji. Eksperymenty wyznaczają zbalansowaną dokładność referencyjnych algorytmów klasyfikacji przy obrazach filtrowanych dla wartości percentyla w zakresie 35–95.

*Obserwacje:* Najlepszym klasyfikatorem dla obrazów uzyskiwanych przy użyciu czujnika AVIRIS został k-NN, a dla spektrometru ROSIS wygrało GNB. MLP, podobnie do SVC, wydaje się nieskutecznym rozwiązaniem dla tego rodzaju danych, ale w przypadku obrazu *Salinas A*, dla  $p > 50$ , podnosi BAC o 20%. Właściwie skalibrowany EPF używany jako metoda redukcji cech zachowuje dokładność klasyfikacji, a w niektórych przypadkach może prowadzić do niewielkiej poprawy jej wyniku.

**Tabela 1. Skala filtrowania (po lewej) i wpływ wybranego percentyla na jakość klasyfikacji (po prawej) dla zbioru Salinas A**

Percentyl	Wielkość elementu strukturalnego					Percentyl	Klasyfikator				
	(2, 2)	(3, 3)	(4, 4)	(5, 5)	(6, 6)		KNN	GNB	DTC	MLP	SVC
35 <sup>th</sup>	12.9%	14.3%	15.2%	17.0%	15.6%	35 <sup>12%</sup>	0.904	0.851	0.895	0.500	0.679
45 <sup>th</sup>	19.2%	22.3%	24.1%	25.9%	25.0%	45 <sup>19%</sup>	0.908	0.857	0.888	0.539	0.643
55 <sup>th</sup>	32.6%	42.4%	37.5%	40.6%	39.7%	55 <sup>32%</sup>	<b>0.913</b>	0.829	0.891	0.691	0.631
65 <sup>th</sup>	49.6%	53.6%	54.5%	54.9%	51.3%	65 <sup>49%</sup>	<b>0.913</b>	0.853	0.885	0.769	0.620
75 <sup>th</sup>	65.2%	63.8%	66.5%	66.1%	65.2%	75 <sup>65%</sup>	<b>0.911</b>	0.857	0.890	0.655	0.622
85 <sup>th</sup>	75.0%	79.9%	79.5%	79.9%	79.0%	85 <sup>75%</sup>	<b>0.914</b>	0.859	0.897	0.530	0.629
95 <sup>th</sup>	89.7%	91.5%	91.1%	92.0%	91.1%	95 <sup>89%</sup>	<b>0.916</b>	0.861	0.889	0.500	0.626
99 <sup>th</sup>	97.3%	97.8%	97.3%	97.8%	97.8%	—	0.908	0.862	0.898	0.593	0.639

Źródło: opracowanie własne.

**Tabela 1. Skala filtrowania (po lewej) i wpływ wybranego percentyla na jakość klasyfikacji (po prawej) dla zbioru Salinas**

Percentyl	Wielkość elementu strukturalnego					Percentyl	Klasyfikator				
	(2, 2)	(3, 3)	(4, 4)	(5, 5)	(6, 6)		KNN	GNB	DTC	MLP	SVC
35 <sup>th</sup>	13.8%	15.6%	16.5%	13.8%	15.2%	35 <sup>13%</sup>	0.848	0.859	0.812	0.550	0.500
45 <sup>th</sup>	18.8%	23.7%	24.6%	26.8%	28.6%	45 <sup>18%</sup>	0.877	0.864	0.825	0.577	0.500
55 <sup>th</sup>	32.6%	32.6%	36.6%	34.4%	32.1%	55 <sup>32%</sup>	0.812	<b>0.892</b>	0.834	0.562	0.500
65 <sup>th</sup>	43.3%	47.8%	50.9%	49.6%	50.4%	65 <sup>43%</sup>	0.788	0.879	0.824	0.500	0.500
75 <sup>th</sup>	58.0%	61.6%	62.5%	62.1%	64.3%	75 <sup>58%</sup>	0.795	0.888	0.820	0.500	0.500
85 <sup>th</sup>	75.0%	78.6%	79.0%	79.0%	78.6%	85 <sup>75%</sup>	0.878	<b>0.897</b>	0.847	0.561	0.500
95 <sup>th</sup>	90.2%	92.4%	91.5%	91.5%	90.6%	95 <sup>90%</sup>	0.793	<b>0.890</b>	0.833	0.508	0.500
99 <sup>th</sup>	97.3%	97.3%	97.8%	97.3%	98.2%	—	0.783	0.891	0.819	0.508	0.500

Źródło: opracowanie własne.

**Tabela 1. Skala filtrowania (po lewej) i wpływ wybranego percentyla na jakość klasyfikacji (po prawej) dla zbioru Pavia**

Percentyl	Wielkość elementu strukturalnego					Percentyl	Klasyfikator				
	(2, 2)	(3, 3)	(4, 4)	(5, 5)	(6, 6)		KNN	GNB	DTC	MLP	SVC
35 <sup>th</sup>	9.7%	14.6%	14.6%	14.6%	16.5%	35 <sup>9%</sup>	0.576	0.736	0.624	0.511	0.500
45 <sup>th</sup>	28.2%	22.3%	18.4%	20.4%	21.4%	45 <sup>28%</sup>	0.591	0.741	0.618	0.506	0.500
55 <sup>th</sup>	41.7%	35.0%	37.9%	41.7%	37.9%	55 <sup>41%</sup>	0.594	0.730	0.618	0.500	0.500
65 <sup>th</sup>	54.4%	48.5%	49.5%	50.5%	48.5%	65 <sup>54%</sup>	0.589	0.738	0.617	0.500	0.500
75 <sup>th</sup>	58.3%	62.1%	60.2%	58.3%	59.2%	75 <sup>58%</sup>	0.590	0.734	0.607	0.505	0.500
85 <sup>th</sup>	70.9%	73.8%	70.9%	69.9%	71.8%	85 <sup>70%</sup>	0.604	0.742	0.634	0.500	0.500
95 <sup>th</sup>	89.3%	90.3%	89.3%	88.3%	89.3%	95 <sup>89%</sup>	0.603	<b>0.772</b>	0.625	0.500	0.500
99 <sup>th</sup>	96.1%	97.1%	96.1%	96.1%	96.1%	—	0.594	0.760	0.626	0.502	0.500

Źródło: opracowanie własne.

## Podsumowanie

Algorytm EPF może znaleźć zastosowanie w usuwaniu zakłóconych pasm z danych obrazowych, takich jak obrazy wielo- i nadwidmowe. Można go wykorzystać w procesie preprocessingu innych algorytmów, zapewniając czytelność informacji przenoszonych przez widmo lub przygotowując początkową separację danych przestrzennych. Wreszcie, możemy użyć informacji o entropii jako dostępnej w czasie rzeczywistym informacji zwrotnej dla operatorów czujników HSI, mierząc użyteczność i przejrzystość zbieranych danych.

## Podziękowania

Praca została sfinansowana ze środków statutowych Katedry Systemów i Sieci Komputerowych Wydziału Elektroniki Politechniki Wrocławskiej.

## Literatura

- Aggarwal, H.K., Majumdar, A. (2016). Hyperspectral Image Denoising Using Spatio-Spectral Total Variation. *IEEE Geoscience and Remote Sensing Letters*, 13 (3), 442–446.
- Davies, E.R. (2004). *Machine Vision*. Amsterdam: Elsevier.
- Dougherty, E.R. (1992). *An Introduction to Morphological Image Processing*. Bellingham: Society of Photo Optical.
- Ertürk, A. (2016). Sparse Unmixing Based Denoising for Hyperspectral Images. W: *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* (p. 7006–7009). Beijing.
- Fauvel, M., Tarabalka, Y., Benediktsson, J.A., Chanussot, J., Tilton, J.C. (2013). Advances in Spectral-Spatial Classification of Hyperspectral Images. *Proceedings of the IEEE*, 101 (3), 652–675. Pobrane z: <http://doi.org/10.1109/JPROC.2012.2197589> (20.12.2017).
- Green, R.O., Eastwood, M.L., Sarture, C.M., Chrien, T.G., Aronsson, M., Chippendale, B.J. i in. (1998). Imaging Spectroscopy and the Airborne Visible/Infrared Imaging Spectrometer (AVIRIS). *Remote Sensing of Environment*, 65 (3), 227–248.
- Moses, W.J., Bowles, J.H., Lucke, R.L., Corson, M.R. (2012). Impact of Signal-to-noise Ratio in a Hyperspectral Sensor on the Accuracy of Biophysical Parameter Estimation in Case II Waters. *Optics Express*, 20 (4), 4309–4330. Pobrane z: <http://doi.org/10.1364/OE.20.004309> (20.12.2017).
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O. i in. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.

- Perona, P., Malik, J. (1990). Scale-space and Edge Detection Using Anisotropic Diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12 (7), 629–639. Pobrane z: <http://doi.org/10.1109/34.56205> (20.12.2017).
- Stumpf, R.P., Werdell, P.J. (2010). Adjustment of Ocean Color Sensor Calibration Through Multi-band Statistics. *Optics Express*, 18 (2), 401–412. Pobrane z: <http://doi.org/10.1364/OE.18.000401> (20.12.2017).
- Wei, Q., Bioucas-Dias, J.M., Dobigeon, N., Tourneret, J.-Y. (2015). Hyperspectral and Multispectral Image Fusion Based on a Sparse Representation. *IEEE Trans. Geoscience and Remote Sensing*, 53 (7), 3658–3668. Pobrane z: <http://doi.org/10.1109/TGRS.2014.2381272> (20.12.2017).