



PAWEŁ KSIIENIEWICZ

Entropodynamiczny filtr percentylowy

Entropodynamic Percentile Filter

Doktor inżynier, Politechnika Wrocławska, 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 nadwiedmowe, 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 nadwiedmowego (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 μm . 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 nadwzmownych 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 odchylen 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 nadwiedmowego (H) jest odległość pomiędzy medianą ($Q_2(x)$) a zadany 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 nierozróżnialne (odległości między sygnaturami bliskie zera), zostały odfiltrowane. Algorytm usuwa wszystkie wyszarzone pasma z sześciennu 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 wygładzaniu 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 sygnałów 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 th	12.9%	14.3%	15.2%	17.0%	15.6%	35 ^{12%}	0.904	0.851	0.895	0.500	0.679
45 th	19.2%	22.3%	24.1%	25.9%	25.0%	45 ^{19%}	0.908	0.857	0.888	0.539	0.643
55 th	32.6%	42.4%	37.5%	40.6%	39.7%	55 ^{32%}	0.913	0.829	0.891	0.691	0.631
65 th	49.6%	53.6%	54.5%	54.9%	51.3%	65 ^{49%}	0.913	0.853	0.885	0.769	0.620
75 th	65.2%	63.8%	66.5%	66.1%	65.2%	75 ^{65%}	0.911	0.857	0.890	0.655	0.622
85 th	75.0%	79.9%	79.5%	79.9%	79.0%	85 ^{75%}	0.914	0.859	0.897	0.530	0.629
95 th	89.7%	91.5%	91.1%	92.0%	91.1%	95 ^{89%}	0.916	0.861	0.889	0.500	0.626
99 th	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 th	13.8%	15.6%	16.5%	13.8%	15.2%	35 ^{13%}	0.848	0.859	0.812	0.550	0.500
45 th	18.8%	23.7%	24.6%	26.8%	28.6%	45 ^{18%}	0.877	0.864	0.825	0.577	0.500
55 th	32.6%	32.6%	36.6%	34.4%	32.1%	55 ^{32%}	0.812	0.892	0.834	0.562	0.500
65 th	43.3%	47.8%	50.9%	49.6%	50.4%	65 ^{43%}	0.788	0.879	0.824	0.500	0.500
75 th	58.0%	61.6%	62.5%	62.1%	64.3%	75 ^{58%}	0.795	0.888	0.820	0.500	0.500
85 th	75.0%	78.6%	79.0%	79.0%	78.6%	85 ^{75%}	0.878	0.897	0.847	0.561	0.500
95 th	90.2%	92.4%	91.5%	91.5%	90.6%	95 ^{90%}	0.793	0.890	0.833	0.508	0.500
99 th	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 th	9.7%	14.6%	14.6%	14.6%	16.5%	35 ^{9%}	0.576	0.736	0.624	0.511	0.500
45 th	28.2%	22.3%	18.4%	20.4%	21.4%	45 ^{28%}	0.591	0.741	0.618	0.506	0.500
55 th	41.7%	35.0%	37.9%	41.7%	37.9%	55 ^{41%}	0.594	0.730	0.618	0.500	0.500
65 th	54.4%	48.5%	49.5%	50.5%	48.5%	65 ^{54%}	0.589	0.738	0.617	0.500	0.500
75 th	58.3%	62.1%	60.2%	58.3%	59.2%	75 ^{58%}	0.590	0.734	0.607	0.505	0.500
85 th	70.9%	73.8%	70.9%	69.9%	71.8%	85 ^{70%}	0.604	0.742	0.634	0.500	0.500
95 th	89.3%	90.3%	89.3%	88.3%	89.3%	95 ^{89%}	0.603	0.772	0.625	0.500	0.500
99 th	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., Tournet, 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).