

ハイパースペクトル画像圧縮符号化における 局所的重み付き予測の性能評価

上倉 一人^{†1}

清水 淳^{†2}

概要: ハイパースペクトル画像は波長分解能が高く高性能な解析が可能である反面、通常の画像に比べデータ量が多いためハイパースペクトル画像に適した高効率な圧縮符号化手法が望まれる。本稿ではハイパースペクトル画像に対してk平均法を用いた局所的重み付き予測を適用する際に、重み付き予測の精度、クラスタ数、ブロックサイズが予測性能に与える影響について評価する。

キーワード: 画像圧縮符号化, 重み付き予測, k平均法, ハイパースペクトル画像

Performance Evaluation of Local Weighted Prediction in Hyperspectral Image Compression

KAZUTO KAMIKURA^{†1}

ATSUSHI SHIMIZU^{†2}

Abstract: Hyperspectral images have been widely and vigorously used in the fields of remote sensing, agriculture, etc. Because a hyperspectral image has much amount of data, a compression technique to reduce the data size effectively is required. We have been shown that local Weighted Prediction (WP) technique is suitable for the characteristics of hyperspectral image data. In this paper, the influence of the various parameters related to the local WP using k-means clustering on prediction performance is evaluated.

Keywords: image compression, weighted prediction, k-means clustering, hyperspectral image

1. はじめに

ハイパースペクトル画像とは、光を数 nm 程度の波長間隔で数十～百以上のバンドに分解し、そのスペクトル強度を一画素毎に記録したデータである。我々が通常視聴しているカラー画像では各画素が RGB や YUV 等の 3 成分から成っているのに対し、ハイパースペクトル画像では図 1 に示すように各画素に対して数十～百以上のスペクトル強度情報が存在する。波長分解能が高く高精度の解析が可能であることから、近年ではリモートセンシングや農作物の生育管理などに利用されている[1]。しかしながらそのデータ量は通常の画像に比べて増大するため、その特性を生かした圧縮符号化方式に関する研究が行われている[2]。

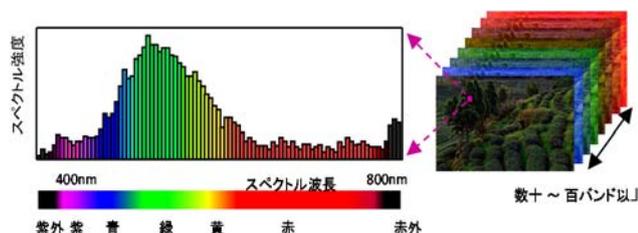


図 1 ハイパースペクトル画像データの例
Figure 1 Example of hyperspectral image data

筆者らは先に、ハイパースペクトル画像に対して HEVC や H.264 で採用されている重み付き予測 (Weighted Prediction: WP) を局所的に適用する手法を提案している[3]。本手法では画面をブロックに分割し、そのブロックを単位として、同程度のスペクトル強度変化が生じている複数領域にクラスタリングすることにより局所的な WP を実現している。その予測性能はブロックサイズやクラスタリング数によって変化すると考えられる。すなわち、ブロックサイズを小さくすると WP による予測性能は向上するが WP パラメータを表すための情報量が増加する。また、クラスタリング数を増やすと WP の種類が増加することにより予測性能は向上するが、やはり WP パラメータを表すための情報量が増加する。更に、WP パラメータ自体の精度を変えることによっても予測性能とそれに必要な情報量が変化する。そこで本稿では、これら各々の項目が予測性能に与える影響について評価実験を行い、適切な設定値について考察する。

2. ハイパースペクトル画像に対する局所的重み付き予測

ハイパースペクトル画像では、図 1 の例で示したように各画素のスペクトル強度が比較的緩やかに変化している。

^{†1} 東京工芸大学 工学部
Faculty of Engineering, Tokyo Polytechnic University
^{†2} 日本電信電話株式会社 NTT メディアインテリジェンス研究所
NTT Media Intelligence Laboratories, NTT Corporation

すなわち隣接スペクトル間には強い相関があるため、スペクトル間で重み付き予測 (WP) を行うことにより効率的な圧縮が可能となる。WP は以下の手順で行う。

符号化対象である b_1 番目のスペクトル画像 P_{b_1} を、既に符号化された b_0 番目のスペクトル画像 P_{b_0} から予測する場合を考える。重み付き予測 (WP) では、画像 P_{b_0} における位置 (x, y) のスペクトル強度 $I(x, y, b_0)$ が、画像 P_{b_1} では式(1)に従って $I'(x, y, b_1)$ に変化すると仮定する。

$$I'(x, y, b_1) = c \cdot I(x, y, b_0) + d \quad (1)$$

ここで c および d は WP パラメータである。パラメータの推定方法として、ここでは最小二乗法を用いる。すなわち c および d は式(2)、式(3)で推定される。

$$c = \frac{N \cdot S - O \cdot Q}{N \cdot T - O^2} \quad (2)$$

$$d = \frac{T \cdot Q - O \cdot S}{N \cdot T - O^2} \quad (3)$$

ここで

$$O = \sum_{x, y \in R} I(x, y, r) \quad (4)$$

$$Q = \sum_{x, y \in R} I(x, y, c) \quad (5)$$

$$S = \sum_{x, y \in R} (I(x, y, r) \cdot I(x, y, c)) \quad (6)$$

$$T = \sum_{x, y \in R} I^2(x, y, r) \quad (7)$$

であり、 R は評価対象領域、 N は評価領域 R 内の全画素数である。

図 2 は稲苗が植えられた水田の風景をハイパースペクトルカメラで撮影した画像 (以後、画像「水田」と呼ぶ) で

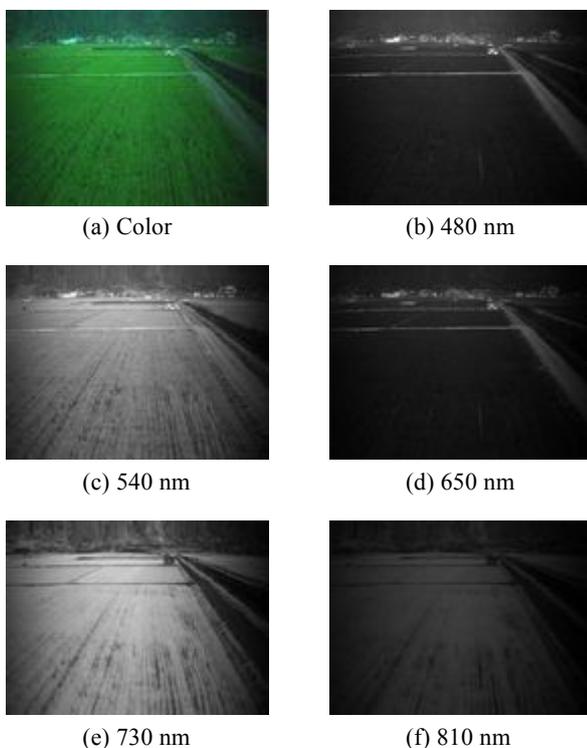


図 2 ハイパースペクトル画像「水田」
Figure 2 Hyperspectral image “paddy field”

あり、(a) はカラー表示したもの、(b)~(f) は各々波長が 480 nm、540 nm、650 nm、730 nm、810 nm のスペクトル画像を白黒表示したものである。(c) 540 nm では全体的にスペクトルが強いのにに対して、(b) 480 nm や (d) 650 nm では稲苗のスペクトルが弱く畦道や後景の建物などのスペクトルが強い。逆に (e) 730 nm では稲苗のスペクトルが強く畦道や後景の建物などのスペクトルは比較的弱くなっている。上記のようにスペクトル強度の変化は対象物などによって異なる。この強度変化の違いに対応するため、小領域に分割されたブロック毎に WP を行う。ただし WP パラメータすなわち式(2)の値 c および式(3)の値 d は復号処理の際に必要な情報であり、ブロックサイズを小さくすると WP パラメータを表すための情報量が多くなってしまふ。そこで k 平均法を用いて同程度のスペクトル強度変化が生じていると推定される領域、すなわち類似した WP パラメータでスペクトル強度が変化していると推定される領域に各ブロックを分類する。その手順を以下に示す。

- 1) 画像 P_{b_1} に対し、 $(m \times m)$ 画素のブロック毎に乱数等を用いて $1 \sim k$ のラベルを付ける。言い換えると画像 P_{b_1} が k 個の領域に分類されたことになる。各領域を $U_1 \sim U_k$ とする。
- 2) $U_1 \sim U_k$ について、式(2)~(7)により WP パラメータを算出する。 $U_1 \sim U_k$ に対して得られたパラメータ c および d のセットを $W_1 \sim W_k$ とする。
- 3) 各ブロックに対して、 $W_1 \sim W_k$ により重み付き予測を行った際の予測誤差絶対値和が最小となるものを選択することで、各ブロックを再分類する。
- 4) あらかじめ定められた基準にしたがい、2) に戻って処理を反復するか、または処理を終了する。

3. 各種パラメータ値が予測性能に与える影響に関する評価実験

2 章で述べた手法において、設定が必要な各種パラメータを変化させた場合の予測性能を実験により比較し、各パラメータの適切値を導く。実験に使用した画像は図 2 に示した画像「水田」と、図 3 に示す画像「小松菜」である。両画像とも空間解像度は 640×480 画素であり、波長が 5 nm 間隔で 350 nm から 1050 nm まで合計 141 バンドのスペクトル画像からなっている。スペクトル強度のビット深度は 8 bit である。

WP パラメータ c および d の精度の違いが予測性能に与える影響について実験を行った。本実験においては、各バンドのスペクトル画像に対してブロックを分割せずに画像全体で 1 セットの WP パラメータを算出し、その精度を変化させた。WP パラメータのうち c については $1/1024$ 間隔から $1/8$ 間隔まで、 d については $1/32$ 間隔から 16 間隔まで、2 のべき乗単位で精度を変化させ予測誤差の平均二乗誤差 (Mean Squared Error: MSE) を測定した。パラメータ c の結

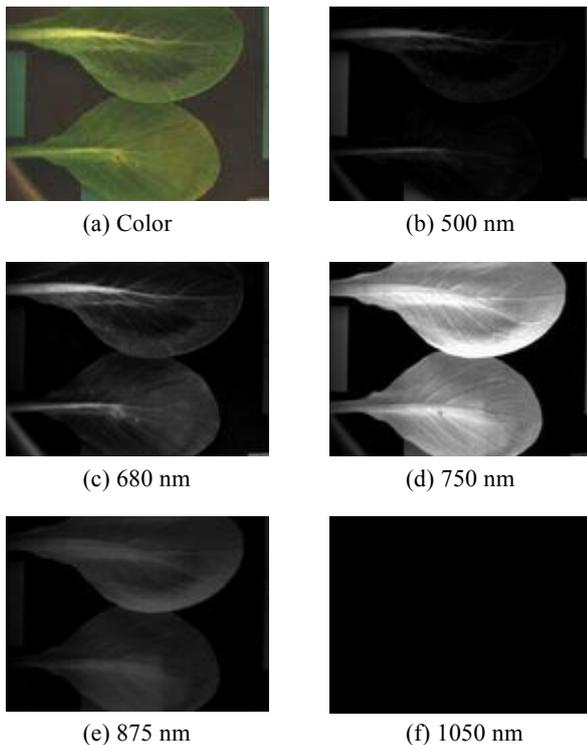
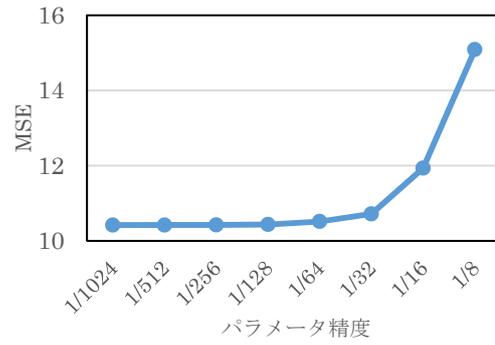


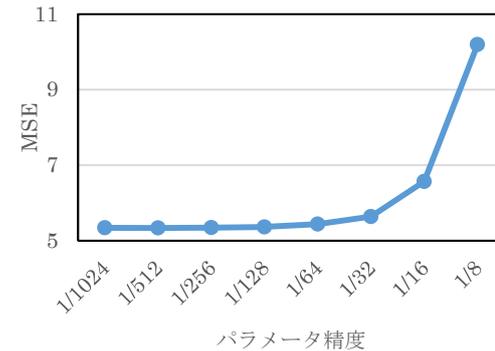
図3 ハイパースペクトル画像「小松菜」
Figure 3 Hyperspectral image “komatuna”

果を図4に、パラメータ d の結果を図5に示す。パラメータ c については、図4より1/128間隔まで精度を下げても予測性能はほとんど低下しないことが分かる。したがって1/128間隔の精度が適切と考えられる。パラメータ d については、画像「水田」では図5(a)より1/2間隔よりも精度が下がると予測性能が低下し始めることが分かる。一方、画像「小松菜」では図5(b)より16間隔まで精度を下げても予測性能にほとんど変化がみられない。両者の結果を考慮すると、パラメータ d の精度は1/2間隔が適切と考えられる。

本手法では、 k 個のクラス毎にWPパラメータの情報が必要となり、 $(m \times m)$ 画素のブロック毎にどのクラスに属するかという情報が必要となる。すなわちクラス数 k を増やせば予測性能は向上するがWPパラメータ情報が増加する、またブロックサイズを小さくすれば予測性能は向上するが、ブロック毎に必要なクラス選択情報が増加する。そこで、これらのトレードオフを調べるために実験を行った。具体的には、クラス数 k を1, 2, 4, 8, 16、ブロックサイズ m を4, 8, 16, 32と変化させ、各々の場合の予測誤差エントロピーを算出した。その際のWPパラメータについては、パラメータ c が0/128から255/128まで1/128間隔、パラメータ d が-128/2から127/2まで1/2間隔とした。したがってクラス毎に各々8ビット、計16ビットの情報が付加される。またブロック毎にクラス選択情報が付加される。例えば $k=2$ の時は1bit/ブロック、 $k=4$ の時は2bit/ブロックが付加情報となる。結果を表1および表2に示す。表中のエントロピーは、上述した付加情報を含んでい



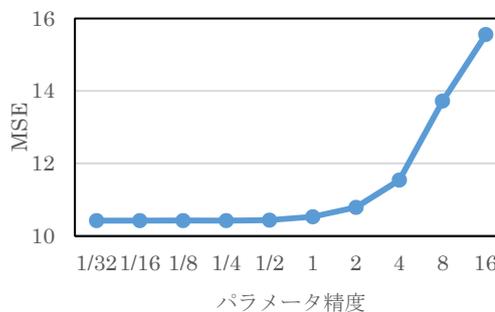
(a) 画像「水田」



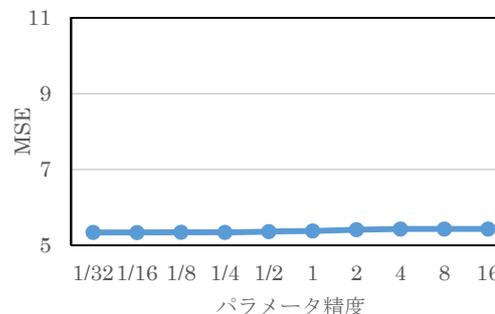
(b) 画像「小松菜」

図4 パラメータ c とMSEの関係

Figure 4 Relation between accuracy of “ c ” and MSE



(a) 画像「水田」



(b) 画像「小松菜」

図5 パラメータ d とMSEの関係

Figure 5 Relation between accuracy of “ d ” and MSE

る。クラスタ数 k については画像「水田」(表1)では $k=2$ まで、画像「小松菜」(表2)では $k=4$ まで増やすことによりエントロピーの明確な低減が認められるが、それ以上としても大きな低減が認められない。したがって $k=4$ が適切値と考えられる。ブロックサイズ m についてはエントロピーに与える影響は全体的に小さいが、画像「水田」(表1)によると $m=8$ または $m=16$ が適切値と考えられる。

図6はクラスタ数 $k=4$ 、ブロックサイズ $m=8$ とした時に、各ブロックが選択されたクラスタの分布をあらわしたものである。図6(a)の画像「水田」は波長540nm、図6(b)の画像「小松菜」は波長750nmのスペクトル画像に対する結果であり、各画像において同一濃度であらわした部分が同一クラスタに属している。図6(a)では水田部分と背景部分、図6(b)では小松菜の中心と周辺、背景部分などに分類されていることが分かる。

4. おわりに

ハイパースペクトル画像に対する局所的重み付き予測において、予測のための各種パラメータの値や精度が予測性能に与える影響について評価実験を行い、適切な設定値を求めた。

今後の課題として、本手法をH.265/HEVC等に適用した場合の有効性の確認、WPパラメータ変動の近似手法に関する検討などが挙げられる。

謝辞

実験に使用した画像データは、北海道衛星株式会社様から提供いただいた。

参考文献

- [1] 佐鳥, 三橋, 佐々木, 伊藤, 竹内: “圃場遠隔計測システム—農業衛星リモートセンシング実現に向けて”, 平成26年度電気・情報関係学会北海道支部連合大会, Oct. 2014.
- [2] Sanjith S, and Ganeasn R: “A Review on Hyperspectral Image Compression,” Proc. ICCICCT2014, pp.1159-1163, Kanyakumari, July 2014.
- [3] 上倉, 清水: “複数の重み付き予測パラメータセットを用いたハイパースペクトル画像圧縮符号化”, Picture Symposium of Japan 2015, P-2-10, pp.46-47, Nov. 2015.

表1 画像「水田」のエントロピー (bit/pixel)

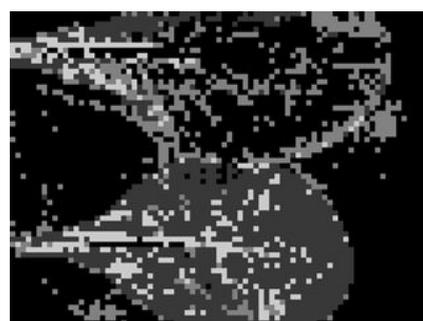
		ブロックサイズ m			
		4	8	16	32
クラス 数 k	1	3.54	3.54	3.54	3.54
	2	3.47	3.44	3.45	3.43
	4	3.47	3.41	3.39	3.39
	8	3.48	3.39	3.37	3.37
	16	3.50	3.38	3.35	3.35

表2 画像「小松菜」のエントロピー (bit/pixel)

		ブロックサイズ m			
		4	8	16	32
クラス 数 k	1	2.92	2.92	2.92	2.92
	2	2.73	2.73	2.71	2.73
	4	2.69	2.64	2.63	2.65
	8	2.69	2.61	2.60	2.61
	16	2.71	2.59	2.58	2.59



(a) 画像「水田」



(b) 画像「小松菜」

図6 クラスタ分類結果
Figure 6 Results of clustering