

KEUNGGULAN MATRIKS SPHERING DIBANDINGKAN MATRIKS EIGEN UNTUK MEREDUKSI DATA CITRA HIPERSPEKTRAL

Yurika Permanasari¹⁾ Aniati Murni²⁾
 Universitas Islam Bandung¹⁾ Universitas Indonesia²⁾
 yurika71@yahoo.com

ABSTRACT

Transformation in the form of reduction of dimensionis of multivariate data is needed in enhancing the remote sensing data. Since the technology is currently availablein collecting image data with high dimensions. The method commonly used for reducing data dimensions is transformation using eigen matrix. However, there is anothred way to conduct the process using sphering matrices. In this research, the method using eigen matrices is compared to that of sphering matrix. The result shows that the sphering matrix transformation performed better then the eigen matrix one.

Keywords: Remote Sensing, Transformation, Reduction, Sphering Matrics, Eigen Matrics

1. Pendahuluan

Remote Sensing merupakan suatu sistem yang digunakan untuk merekam data mengenai permukaan bumi berdasarkan pengukuran yang dilakukan dari jarak jauh, dengan tujuan agar dapat merekam data daerah bumi yang cukup luas. Alat untuk memperoleh informasi tentang objek adalah alat pengindra atau sensor tanpa kontak langsung terhadap objek. Gambaran yang terekam oleh sensor disebut sebagai citra yang selanjutnya disebut dengan citra.

Pengembangan yang terbaru sistem remote sensing memungkinkan pengukuran interval spektral yang lebih banyak dibanding sistem-sistem sebelumnya. Salah satu contoh teknologi ini adalah AVIRIS sistem, yang mengumpulkan data citra dalam 220 bands (dimensi). Teknologi ini disebut juga dengan teknologi hiperspektral. Kegunaan dari citra hiperspektral yaitu untuk mendeteksi dan memetakan materi-materi dengan varietas yang besar. Citra hiperspektral lebih mampu menunjukkan keberagaman mineral sehingga dapat memperlihatkan keberagaman objek dalam suatu wilayah.

Meskipun citra hiperspektral memiliki kelebihan-kelebihan, akan tetapi sifat ini tidak berarti citra hyperspectral tidak mempunyai kelemahan-kelemahan. Selain bahwa sebagian besar dari dimensi data adalah kosong juga sifat-sifat khusus yang dimiliki citra hiperspektral mengakibatkan timbulnya kesulitan-kesulitan dalam analisa dan penggunaan citra hiperspektral. Citra hiperspektral biasanya berukuran besar dan mengandung ratusan *frame* data, hal ini dikarenakan jumlah spektrum yang banyak dan kontinyu. Sehingga perlu adanya algoritma kompresi data yang efektif guna menyimpan data citra hiperspektral.

2. Landasan Teori

Pada aplikasi *remote sensing*, ekstraksi data menjadi mutlak dilakukan karena hasil sensor menjadikan data berdimensi tinggi. Sedangkan kemampuan pengolahan data, meskipun telah menggunakan komputer yang canggih masih sulit dilakukan, dan membutuhkan biaya pemrosesan yang sangat tinggi. Oleh karena itu, salah satu upaya untuk mengurangi biaya pemrosesan yang sangat tinggi ini adalah dengan merepresentasikan data citra ke dalam bentuk yang lebih kecil dimensinya^[5].

Metode reduksi data dengan menggunakan Matriks Eigen biasa dilakukan jika akan mentransformasikan data menggunakan *Principal Component Transform*(PCT). PCT efektif untuk mengkompres informasi dalam himpunan data multivariate. Kenyataan yang menunjukkan bahwa citra hyperspectral sebagian besar adalah kosong. Ini menyebabkan PCT lebih sulit dan membutuhkan biaya besar untuk digunakan. Bahkan untuk objek yang relative kecil dibandingkan dengan latar belakangnya, metode PCT memberikan kontribusi yang kecil terhadap keseluruhan variannya. Sehingga PCT sering kali gagal mengenali objek tersebut^[2].

Alternatif lain yang untuk melakukan transformasi adalah menggunakan matriks *sphering* seperti yang diperkenalkan oleh Friedman dan Tukey. Ide transformasi ini adalah untuk memproyeksikan himpunan data berdimensi tinggi menjadi ruang data berdimensi rendah dengan tetap menyimpan informasi yang diinginkan. *Projection Pursuit* (PP) secara otomatis memilih “interesting” proyeksi yang lebih rendah dari dimensi data yang tinggi dengan memaksimalkan atau meminimalkan fungsi *Projection Indeks* tergantung dari kasus yang diamati. Banyak sekali fungsi *Projection Indeks* yang digunakan dalam berbagai kasus sejak sukses diperkenalkan pertama kali oleh Friedman dan Tukey. Salah satunya adalah *skewness*:

$$I_{\text{skewness}}(\mathbf{a}) = H_1(\mathbf{a}^T \mathbf{X})$$

2.1 Matriks Sphering

Transformasi data untuk mendapatkan data baru yang dimensinya lebih rendah dalam PP dilakukan dengan menggunakan pendekatan berikut^[4]; diasumsikan terdapat N data points $\{x_n\}_{n=1}^N$, masing-masing berdimensi K, $X = [x_1 \ x_2 \ \dots \ x_n]$ adalah matriks data berukuran K x N, dan a adalah vector kolom berdimensi K, untuk proyeksi yang diinginkan. Kemudian $a^T X$ merepresentasikan suatu vector baris berdimensi N yang merupakan proyeksi orthogonal dari semua titik data dari sample yang dipetakan pada (onto) arah a. T merupakan transpose dari matriks. Misalkan H(.) adalah suatu fungsi yang mengukur derajat “interestingness” pada proyeksi $a^T X$, maka untuk suatu fixed data matrix X, suatu projection index didefinisikan sebagai berikut^[3].

“ Suatu projection index (PI) adalah suatu fungsi yang bernilai real dari a, $I(a) : R^K \rightarrow R$ yang didefinisikan dengan:

$$I(a) = H(a^T X) \quad (1)$$

Untuk suatu proyeksi orthogonal pada suatu ruang berdimensi J yang lebih besar dari satu, a digantikan oleh suatu matriks A yang berukuran K x J. $A = [a_1 \ a_2 \ \dots \ a_j]$ adalah matriks arah proyeksi berukuran K x J.

Jadi $A^T X$ adalah matriks berukuran J x N. Dalam hal ini, kolom dari matriks A bukan hanya merupakan suatu unit panjang, tetapi juga saling orthogonal. H merupakan ukuran “interestingness” untuk J-variasi sample. *Projection Index* yang bersesuaian juga merupakan fungsi bernilai real $I(A) : R^{K \times J} \rightarrow R$ yang diberikan oleh:

$$I(A) = H(A^T X) \quad (2)$$

Matriks A inilah yang disebut sebagai matriks sphering. Untuk mencari matriks transformasi $A = Q\Lambda^{-1/2}$ digunakan dekomposisi $Q^T \Sigma Q = \Lambda$

Data yang akan ditransformasi terlebih dahulu melalui tahap pemusatan data yaitu dengan menggunakan transformasi berikut:

$$Y = X(I - (1/N) \mathbf{1}\mathbf{1}^T) \quad (3)$$

dimana I adalah matriks identitas N x N, dan $\mathbf{1} = (1, 1, \dots, 1)^T$ adalah vector kolom dimensi N dengan seluruh komponennya bernilai 1.

Persamaan matriks (3) di atas akan sama dengan $Y = x_i - 1/N \sum x_i = x_i - \bar{x}$

Matriks Sphering yang dimaksud di sini adalah matriks transformasi yang akan digunakan dalam mencari matriks hasil transformasinya. Asumsikan bahwa $\{\lambda_i\}_{i=1}^p$ adalah nilai eigen untuk matriks kovarian Σ , dan $\{v_i\}_{i=1}^p$ adalah vector eigen yang bersesuaian. Dengan Σ definite non negatif, semua nilai eigen adalah nonnegative dan terdapat matriks Q dimana Σ dapat didekomposisikan sebagai berikut:

$$Q^T \Sigma Q = \Lambda \quad (4)$$

dimana $Q = [v_1, v_2, \dots, v_p]$ adalah matriks yang terdiri dari vector eigen $\{v_i\}_{i=1}^p$ dan $\Lambda = \text{diag}\{\lambda_i\}_{i=1}^p$ adalah matriks diagonal dengan $\{\lambda_i\}_{i=1}^p$ pada garis diagonalnya.

Jika dimisalkan $\Lambda^{1/2} = \text{diag}\{\sqrt{\lambda_i}\}_{i=1}^p$, dan mengalikannya pada kedua sisi persamaan (4) akan didapat:

$$\Lambda^{1/2} Q^T \Sigma Q \Lambda^{1/2} = I \quad (5)$$

juga didapat sphering matriks A sebagai berikut:

$$A = Q \Lambda^{1/2} \quad (6)$$

Citra hasil transformasi didapat dari persamaan berikut:

$$\text{Citra Baru} = A^T * Y$$

2.2 Matriks Eigen

Transformasi data menggunakan matriks eigen dilakukan berdasarkan matriks kovariansi dari citra-citra asli, dengan himpunan citra ciri yaitu X yang mengandung D ciri (D band), dan masing-masing ciri mempunyai N piksel (N observasi), yang mana datanya diperoleh dari konversi citra analog ke citra digital, sehingga masing-masing piksel mempunyai nilai bulat tidak negatif, yaitu antara 0 sampai 255, yang menyatakan tingkat keabuan atau sering disebut juga dengan tingkat kecerahan (*gray level*) dari piksel yang bersangkutan. Dari D ciri yang ada tersebut, akan dipilih d ciri terbaik, yaitu yang mempunyai kontribusi ciri paling tinggi. Adapun langkah-langkahnya adalah sebagai berikut^[1]:

- Menghitung vektor-vektor eigen dari D citra asli
- Menentukan matriks Matriks Transformasi
- Menghitung Citra Baru sebagai berikut :

$$Y = T * X^T$$

dimana :

- Y = Citra baru
- T = Matriks transformasi
- X = Matriks dari citra asli
- Memilih himpunan data baru
Memilih d ciri dari D citra baru yang tersedia ($d < D$), dengan melihat kontribusi dari setiap citra ciri terhadap variansi dari citra sebagai berikut :

$$\begin{aligned} \text{Kontribusi dari ciri 1} &= \frac{\lambda_1}{\lambda_1 + \lambda_2 + \lambda_3 + \dots + \lambda_D} = L_1 \\ \text{Kontribusi dari ciri 2} &= \frac{\lambda_2}{\lambda_1 + \lambda_2 + \lambda_3 + \dots + \lambda_D} = L_2 \\ \text{Kontribusi dari ciri 3} &= \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3 + \dots + \lambda_D} = L_3 \\ \text{Kontribusi dari ciri ke-}D &= \frac{\lambda_D}{\lambda_1 + \lambda_2 + \lambda_3 + \dots + \lambda_D} = L_D \end{aligned}$$

Untuk memilih d ciri terbaik, maka urutkan D bilangan $L_1, L_2, L_3, \dots, L_D$ dari yang paling besar sampai yang paling kecil atau mengurutkan D nilai eigen dari yang paling besar sampai yang paling kecil. Selanjutnya pilih d bilangan dari urutan terbesar pertama sampai terbesar ke- d . Ciri-ciri yang berkaitan dengan d bilangan yang dipilih merupakan d ciri terbaik yang diambil.

3. Eksperimen dan Hasil

Eksperimen dilakukan untuk mengetahui band-band terpilih dalam proses reduksi data yang terjadi dan mengetahui citra hasil reduksi dengan mengamati *false color composite display* citra hasil transformasi. Untuk penampilan visual citra dibutuhkan 3 band yang akan menjadi kombinasi layar RGB (*Red Green Blue*). Oleh karena itu dari citra baru hasil transformasi dihitung *projection indexnya* dari kombinasi 3 band untuk transformasi menggunakan matriks *sphering* dan dihitung nilai nilai *eigen* untuk transformasi dengan matriks *eigen*, kemudian nilai tersebut diurut berdasarkan besar nilai yang diperoleh. Kombinasi *band* terpilih adalah yang mempunyai nilai terbesar.

Data eksperimen menggunakan citra Bogor yang didapat dari LAPAN. Data Bogor yang dicatat dalam 12 Bands ini disebut dengan data CASI, terdiri dari tiga buah gambar yaitu G5_1, G5_2, dan G5_3. Berikut adalah data eksperimen hasil reduksi.

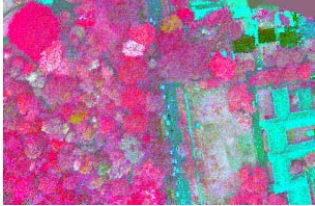
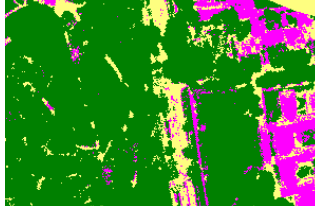
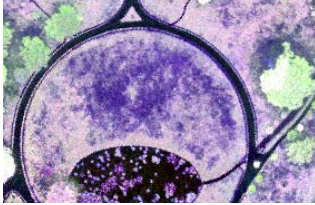
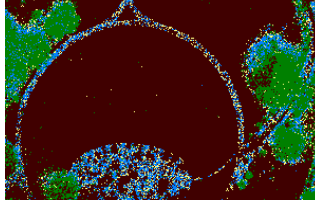
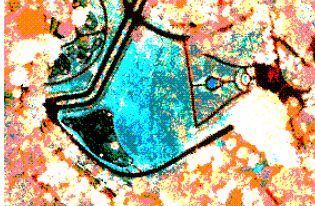
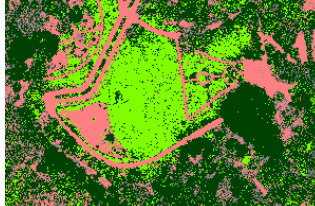
Tabel 1. Hasil Reduksi Data Menggunakan Transformasi Matriks Sphering

Citra Eksperimen	Band Terpilih			PI
G5 1	1	5	7	2.3655
G5 2	1	2	12	2.0881
G5 3	1	3	8	3.3324

Tabel 2. Hasil Reduksi Data Menggunakan Transformasi Matriks Eigen

Citra Eksperimen	Band Terpilih	Nilai Eigen
G5-1	1 2 3	5,4282
G5-2	1 2 3	4,8811
G5-3	1 2 3	5,8634

Berikut ini adalah citra hasil reduksi data dengan PP, yang merupakan RGB dari komposisi terbaik band-band terpilih.

Eksperimen	Transformasi Matriks Sphering	Transformasi Matriks Eigen
G5-1		
G5-2		
G5-3		

Perbandingan tampilan *false color composite display* diamati secara subyektif semua hasil uji coba transformasi yang digunakan dan *Quicklook* RGB. Setelah didapat band terpilih hasil reduksi masing-masing metode, maka band-band akan digunakan pada *false color composite display*. Dari hasil eksperimen, terlihat bahwa citra reduksi data hasil transformasi menggunakan *matriks sphering* lebih baik dibandingkan dengan hasil transformasi menggunakan matriks eigen.

3. Kesimpulan dan Statistika

Citra hyperspectral adalah citra yang memiliki saluran hingga 224 band (dimensi). Kegunaan dari citra hiperspektral yaitu untuk mendeteksi dan memetakan materi-materi dengan varietas yang besar. Berdasarkan studi mengenai citra hyperspectral diketahui bahwa ruang berdimensi tinggi sebenarnya sebagian besarnya adalah kosong dan diasumsikan bahwa banyak sekali data yang redundant. Dengan mentransformasikannya didapat matriks baru yang akan digunakan untuk proses pengenalan objek selanjutnya dan tidak saling redundant.

Pada penelitian ini data yang digunakan hanya sebagian, hal ini dikarenakan tidak cukupnya memori komputer yang digunakan untuk eksperimen. Penggunaan komputer dengan memori yang lebih besar diperlukan agar data untuk eksperimen dapat digunakan seluruhnya

Sesuai dengan paper rujukan, penelitian selanjutnya dapat menggunakan informasi hasil transformasi ini untuk penelitian deteksi target.

Daftar Pustaka

- [1] Anton, Howard., *Elementary Linear Algebra*, 5e, John Wiley & Sons Inc
- [2] C.M. Bachmann and T. F. Donato, 2000, "An Information theoretic comparison of projection pursuit and principal component features for classification of Landsat TM imagery of central Colorado," *INT.J. Remote Sensing*, vol. 21, No. 15, "pp. 2927-2935"
- [3] Shao-Shan Chiang, Chein-I Chang, 2001, "Unsupervised Target Detection in Hyperspectral Images Using Projection Pursuit", *IEEE Trans. Geosc. And Remote Sensing*, vol.39, No. 7, "pp.1380-1391", July.
- [4] J.H. Friedman and J. W. Tukey, Sept.1974, "A Projection pursuit algorithm for exploratory data analysis," *IEEE Trans. Comput.* Vol. C-23, "pp.881-889",
- [5] Gonzales, R.C. and Woods, R. E., 1993, *Digital Image Processing*, Addison-Wesley Publishing Company, Inc.