

## Normalisasi Radiometrik Relatif Multi Sensor dan Multi Temporal Berbasis Ekstraksi Fitur Pseudo-invariant

Lino Garda Denaro,<sup>a,\*</sup> Muhammad Aldila Syariz,<sup>a</sup> Salwa Nabilah,<sup>a</sup> Dewinta Heriza,<sup>a</sup> Chao-Hung Lin,<sup>a</sup>

<sup>a</sup>Department of Geomatics, National Cheng Kung University (NCKU), Tainan, Taiwan, 70101

\* Korespondensi Penulis, E-mail: [p68077022@gs.ncku.edu.tw](mailto:p68077022@gs.ncku.edu.tw)



Dikirim: 1 Feb 2019;  
Diterima: 15 Feb 2019;  
Diterbitkan: 28 Feb 2019.

**Abstrak.** Perkembangan teknologi mendorong tersedianya data citra satelit multi-temporal dalam jumlah banyak. Di sisi lain, pemanfaatan data tersebut belum dilakukan secara optimal. Pemanfaatan citra satelit multi-temporal dengan metode deteksi perubahan sangat berguna untuk memodelkan dan memprediksi perubahan spasial dalam rentang waktu tertentu yang lebih panjang. Namun dalam pengaplikasiannya, perlu adanya koreksi radiometrik antara citra multi-temporal dan juga citra multi-sensor. Dalam penelitian ini, metode WRGCCA (analisis korelasi kanonikal generalisasi teratur dan terbobot) digunakan untuk menyeleksi fitur *invariant* atau PIFs (*pseudo-invariant features*) dengan perbedaan sensor dan temporal tertentu. Metode ini merupakan perkembangan dari metode MAD (deteksi perubahan multivarian) dengan mengadopsi algoritma CCA (analisis korelasi kanonikal) yang berguna untuk mendeteksi perubahan spasial secara bi-temporal dan dikembangkan menjadi GCCA (analisis korelasi kanonikal generalisasi) yang memanfaatkan citra multi-temporal sekaligus. Namun, masing-masing metode tersebut mempunyai keterbatasan dalam menyeleksi PIFs baik bi-temporal maupun multi-temporal yaitu sangat sensitif dengan perubahan spasial. Oleh karena itu, dengan menambahkan fungsi pembobotan dan regularisasi dalam algoritma tersebut, metode WRGCCA dengan bantuan IRMAD (deteksi perubahan multivarian terbobot iteratif), dapat menyeleksi *pseudo-invariant features* yang lebih akurat dengan penurunan RMSE (*root mean square error*) WRGCCA sebesar 10% hingga 50% dibandingkan dengan metode sebelumnya, GCCA. Peningkatan keakuratan ini sangat signifikan dan dapat dilihat dari hasil analisa kualitatif dan kuantitatif pada hasil normalisasi dari citra satelit multi-temporal.

**Kata kunci:** RRN; PIFs (*Pseudo-invariant features*); WRGCCA.

---

### Relative Radiometric Normalization for Multi-sensors and Multi-temporal based on Pseudo-invariant Feature Extraction

**Abstract.** Technology developments promote the abundance availability of multi-temporal satellite imagery data. Otherwise, the utilization of such satellite data have not been implemented optimally due to several limitation requirements. The utilization of the multi-temporal satellite images for change detection is advantageous for modelling and predicting spatial changes in particular period of time. However, in the implementation, the radiometric correction on either multi-temporal or also multi-sensors is required. In this research, weighted regularized generalized canonical correlation analysis (WRGCCA) is proposed to select invariant features or pseudo-invariant features (PIFs) for multi-sensors and multi-temporal images. The method is the improvement of

multivariate alteration detection (MAD) that adopts canonical correlation analysis (CCA) and its extension, generalized canonical correlation analysis (GCCA), to detect bitemporal and multi-temporal data respectively. However, each of the methods, CCA and GCCA, has the limitation on differentiating acceptable PIFs due to sensitive to spatial changes. Therefore, with the utilization of weighting and regularization functions to the algorithm, the proposed method WRGCCA with the aid of iterative reweighted multivariate alteration detection (IRMAD) can select reliable PIFs and yielding more accurate PIFs significantly to 10% - 50% determined from root mean square error (RMSE). The improved PIFs selection can be explained by qualitative and quantitative analysis based on the multi-temporal image normalization.

**Keywords:** RRN; PIFs; WRGCCA.

## I. PENDAHULUAN

Penginderaan jauh merupakan salah satu riset untuk menganalisa objek secara tidak langsung atau tidak bersentuhan dengan objek. Dalam bidang geodesi, penginderaan jauh dimaksudkan untuk menganalisa kondisi spasial bumi tanpa menyentuh objeknya secara langsung. Banyak satelit yang telah diluncurkan untuk mengobservasi kondisi geospasial bumi secara regional maupun global. Diantaranya, salah satu satelit yang paling lama beroperasi adalah satelit Landsat. Oleh karena itu, untuk peneliti yang memerlukan data citra lebih dari 20 tahun sebagai objek penelitian, citra Landsat sangat cocok untuk kasus seperti ini. Misalnya sebagai deteksi perubahan lahan, pengaruh lahan terhadap lingkungan, dan deteksi lahan hijau dengan data multi-temporal. Citra Landsat telah beroperasi selama 45 tahun sejak Landsat 1 diluncurkan tahun 1972 hingga Landsat 8 secara berkala tanpa ada kesenjangan data citra [1]. Lebih jauh lagi, dengan tujuan multi-temporal dengan resolusi spasial yang cocok dengan aktifitas manusia, satelit Landsat juga mempunyai konsistensi dalam kalibrasi dan stabilitas sensor dalam koreksi radiometriknya. Sehingga, hal ini membuat satelit Landsat semakin sukses dalam misi deteksi perubahan lahan, studi iklim secara global dengan perlakuan tertentu untuk menjaga kebutuhan dan keutuhan citra.

Dalam studi ini, yang paling penting adalah dengan menyamakan perbedaan radiometrik antar citra. Perbedaan radiometrik pada citra muncul karena berbagai factor seperti karena perbedaan sensor, perbedaan kondisi pengambilan citra termasuk atmosfer, dan kondisi penerangan yang berbeda [2]. Dengan menggunakan perbedaan sensor atau biasa dikenal dengan *cross-sensor*, ini akan membuat ketidak konsistenan pada pengambilan data citra karena perbedaan panjang gelombang yang digunakan. Hal ini juga telah dibahas dalam journal [1] dan [2] bahwa responsi spektral dari Landsat 8 OLI lebih sempit daripada Landsat 7 ETM+. Pada bagian pinggir responsi spektral Landsat 8 telah di perhalus untuk menghindari penyerapan atmosfer. Maksudnya adalah ketika kedua panjang gelombang tersebut mengenai objek

yang sama dan pada waktu yang sama, maka masing-masing panjang gelombang tersebut akan melaporkan hasil yang berbeda.

Ketidak konsistenan yang lain muncul pada saat pengambilan citra yang berbeda, hal ini memungkinkan kan terjadi pada sensor yang sama, adalah karena absorpsi atmosfer, pencahayaan, sudut pengambilan gambar, *scattering*, variasi topografi, model reflektan, kalibrasi sensor, dan kondisi spasial yang berubah – ubah setiap waktunya [3]. Sehingga, ada banyak rintangan dan hambatan jika kita menginginkan untuk mendeteksi lahan yang asli atau terbebas dari kesalahan atmosfer dari citra satelit tersebut.

Dengan keterbatasan yang telah disebutkan diatas, perbedaan – perbedaan tersebut dapat diatasi dengan koreksi radiometrik. Ada dua pendekatan yang umum yang dapat digunakan untuk koreksi radiometrik yaitu pendekatan absolut dan pendekatan relatif [4],[5]. Untuk selanjutnya, pendekatan relatif ini dikenal dengan RRN (normalisasi radiometrik relatif). Pendekatan dengan metode absolut perlu usaha yang lebih untuk mengkoreksi citra, yaitu dengan menambahkan data kalibrasi radiometrik, model atmosfer, dan target model reflektan [3].

Bagaimanapun, data tersebut perlu didapat pada saat pengambilan citra berlangsung, sehingga metode ini secara relatif sangat sulit untuk diimplementasikan. Metode yang lain yang sering digunakan adalah RRN yang tidak memerlukan data-data tambahan tersebut. Sehingga, RRN menjadi topik pembahasan dalam makalah ini yang menggunakan citra multi-temporal dan multi-sensor dalam area yang ditentukan.

RRN dalam riset ini menggunakan bi-temporal dari berpasangan berturut-turut citra multi-temporal yang dibagi menjadi dua kategori, citra target dan citra subjek. Dalam studi ini menggunakan 4 citra atau bisa lebih, 3 citra dikategorikan sebagai citra Subjek dan 1 citra dikategorikan dengan citra Target. Citra Subjek inilah yang akan ditransformasikan atau dinormalisasikan secara berurutan dari level radiometriknya terhadap citra Target. Transformasi ini dapat dilakukan terhadap sensor yang berbeda dengan syarat bahwa resolusi dan geometrik nya

telah terkoreksi. Metode cross-sensor dilakukan pada sensor yang berbeda dengan mempertimbangkan koreksi geometrik dan resolusinya dalam asumsi bahwa citra tersebut *homogeneous*, sehingga transformasi citra tersebut dapat dilakukan dengan cara pendekatan linear [6],[7],[8]. Metode ini menggunakan normalisasi digital number dari citra Subjek setiap kanalnya, dan dari setiap tanggal pengambilan citranya terhadap citra Target secara berurutan. Salah satu keuntungan dari metode ini adalah properti dari citra yang telah ternormalisasi disamakan terhadap citra Target [9]. Hal ini dimaksudkan bahwa kita telah mengasumsikan sensor kalibrasi, kondisi atmosfer dan pencahayaan telah disetarakan dalam level yang sama. Akhir-akhir ini, peneliti telah melakukan banyak usaha dalam menormalisasi citra dengan pemilihan piksel yang stabil PIFs (*pseudo-invariant feature*) dari citra bi-temporal menggunakan metode PCA (*principal component analysis*) [6],[10].

Salah satu metode yang diusulkan dalam mendeteksi PIFs adalah dengan metode MAD (deteksi perubahan multivarian) [7]. Namun, penyeleksian PIFs masih mengalami permasalahan. Permasalahan terjadi ketika citra bi-temporal mempunyai objek *variant* yang sama pada lokasi piksel yang sama, seperti awan, air, dan objek yang lain yang berubah sepanjang waktunya. Sehingga, objek tersebut akan diindikasikan sebagai PIFs, kenyataannya bahwa objek tersebut adalah objek yang ingin dieleminasi. Sehingga, proses inilah yang akan mengganggu dan menghasilkan nilai yang salah dalam proses normalisasi.

Oleh karena itu, untuk menanggulangi permasalahan ini, IRMAD (deteksi perubahan multivarian terbobot iteratif) diusulkan [11]. Metode ini memodifikasi algoritma MAD yang dapat digunakan tidak hanya pada citra bi-temporal, namun juga pada citra multi-temporal. IRMAD mengolah PIFs dengan cara iterasi untuk mencapai konvergensi dengan menambahkan dua pembobotan yang penting, yaitu pembobotan sudut spektral dan pembobotan temporal sebagai pembobotan awal dalam algoritma.

Prinsip dasarnya, MAD ataupun IRMAD adalah prosedur yang lebih jauh dari algoritma CCA (analisis korelasi kanonikal). CCA mengolah dan menganalisa hubungan antara dua citra yang terdiri dari kanal – kanal tertentu [12]. CCA dapat menemukan kombinasi linear dari citra orisinal. Berdasarkan pada artikel [11][12][15], CCA dapat diformulasikan ulang dalam bentuk kombinasi blok citra, yakni GCCA (analisis korelasi kanonikal generalisasi) dan RGCCA (analisis korelasi kanonikal generalisasi teratur) yang mana kedua metode ini memanfaatkan informasi citra multi-temporal. GCCA adalah metode yang berbasis pada blok citra untuk mencari korelasi linearnya dengan memaksimalkan jumlah fungsi korelasinya (SUMCOR) dan RGCCA

adalah metode untuk menghindari *overfitting* dalam menentukan korelasi citra dengan menambahkan koefisien regularisasinya dengan rentang nilai 0 – 1 [16],[13]. Untuk lebih detilnya, pembaca disarankan menuju pada Bab II yang membahas tentang penyeleksian PIFs.

Bagaimanapun, algoritma ini sangat sensitif terhadap perubahan dan tidak akurat dalam menghasilkan kualitas PIFs. Oleh karena itu, metode yang diusulkan dalam paper ini adalah modifikasi dari algoritma yang asli yang lebih akurat dalam mendeteksi PIFs yang kemudian diberi nama dengan WRGCCA (analisis korelasi kanonikal generalisasi teratur terbobot).

Untuk informasi yang lebih detil, dalam makalah ini disusun sebagai berikut; Bab II metodologi, Bab III hasil dan pembahasan, Bab IV Kesimpulan dan batasan.

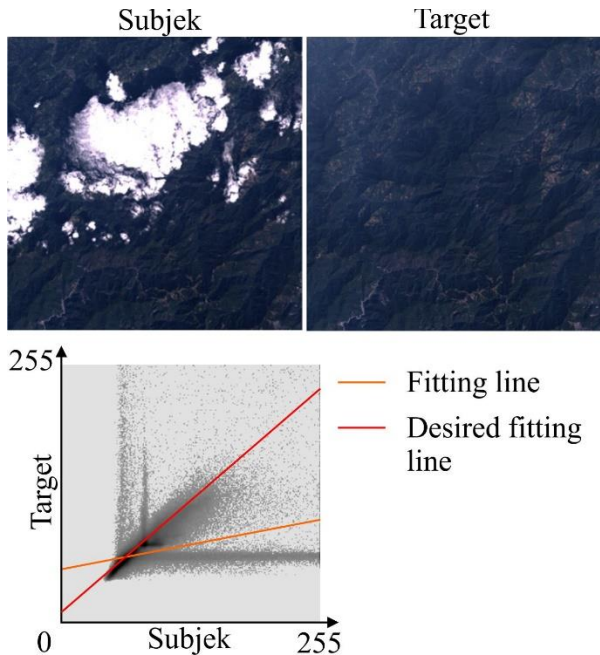
## II. METODOLOGI

### 2.1 Ulasan Normalisasi Radiometrik Relatif (RRN)

Ada berbagai metode dalam menentukan parameter normalisasi radiometrik relatif, khususnya dalam pendekatan linear dengan cara *ordinary least square*. Penggambaran metode ini dapat dengan mudah dilihat dalam Gambar 1, dimana citra Target dan Subjek ditentukan terlebih dahulu. Citra target disini didefinisikan sebagai citra *dependent*, dimana dalam *least square* menjadi variabel  $y$  dan citra Subjek sebagai variabel *independent*  $x$ . Sehingga dalam kedua citra ini dapat digambarkan scatterplot yang berada pada Gambar 1 (bagian bawah). Dengan demikian, fitting line dapat digambarkan dengan garis oranye yang diperoleh dari hasil regresi *linear* pada kedua citra tersebut. Singkatnya, gambar 1 dapat diekspresikan dengan rumus (1) dengan mengacu pada makalah [17],

$$y = \alpha x + \beta \quad (1)$$

dimana  $x$  adalah variabel *independent*,  $y$  adalah variabel *dependent*,  $\alpha$  adalah koefisien slope dan  $\beta$  adalah koefisien *intercept*. Kita dapat melihat dalam Gambar 1, bahwa kesalahan normalisasi bisa terjadi karena keberadaan variansi piksel (awan). Sehingga, hasil dari citra normalisasi tidak terkoreksi dengan baik, dan bahkan menjadi lebih buruk dari sebelumnya (*overfitting*). Sehingga, penyeleksian piksel yang berbeda dari citra bi-temporal ini menjadi dasar dalam melakukan normalisasi radiometrik relatif. Jika PIFs telah dapat diseleksi atau dengan kata lain bahwa outliers telah dihilangkan, maka desired fitting line yang berwarna merah pada Gambar 1 tersebut dapat tercapai. Pembahasan lebih detil tentang penyeleksian fitur ini akan dibahas mulai sub-bab 2.2.



Gambar 1. Normalisasi radiometrik relatif dengan menggunakan regresi linear (*slope* dan *intercept*) tanpa penyeleksian PIFs. (Area: Taiwan)

## 2.2 Ulasan penyeleksian pseudo-invariant features (PIFs)

Secara bertahun-tahun, normalisasi radiometrik menjadi sangat populer dan menjadi perhatian peneliti untuk mengoreksi kesalahan radiometrik berbagai citra yang diambil dari kondisi dan waktu yang berbeda. Metode pertama yang pernah berhasil dilakukan adalah dengan cara pendekatan visual pada pemandangan alam yang secara relatif tidak berubah selama akuisisi citra. Metode ini dilakukan oleh Hall pada tahun 1991 [18]. Pemilihan objek ini dilakukan secara subjektif yang didasarkan pada analisa *in-situ* seperti *ground-truth* diatas bendungan, struktur urban, area parkir dan jalan dalam sebuah citra. Bagaimanapun, metode ini sangat rentan dengan pemilihan teknis pengambilan data, memakan waktu, dan kondisi perilaku peneliti, yang mana jika diimplementasikan oleh peneliti yang lain akan menghasilkan hasil yang berbeda (subjektif).

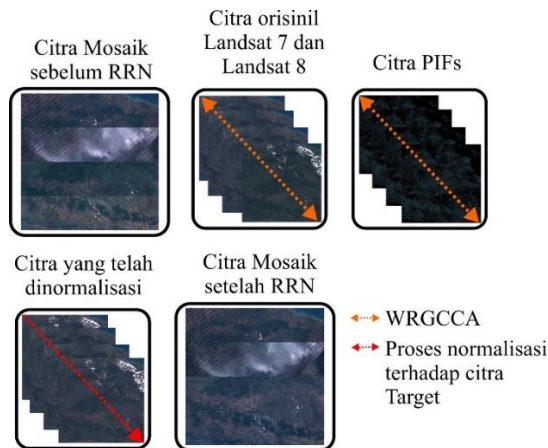
Berbagai metode telah diusulkan dalam penelitian ini, seperti dengan penyeleksian piksel yang berbeda dalam citra bi-temporal atau multi-temporal. Penyeleksian piksel ini dapat dibangun dengan menggunakan kombinasi linear untuk menemukan korelasi kedua citra. Salah satu metode yang dibangun dengan cara objektif adalah dengan menggunakan metode PCA (*principal component analysis*) untuk menentukan korelasi secara maksimal antara tiap kanal yang berbeda dari kedua citra bi-temporal [6]. Namun, metode ini mengalami keterbatasan dalam memperlakukan tiap-tiap kanal. Cara kerja PCA menjadi lebih sulit jika dilakukan dengan citra multi-temporal karena algoritma ini mengasilisasi yang

berbeda-beda pada setiap kanalnya dan secara teori kanal-kanal pada kedua citra bersifat *independent* dengan skala perkalian linear yang berbeda-beda. Sehingga pembatasan (*threshold*) dalam penyeleksian PIFs juga akan berbeda-beda pada tiap kanalnya, apalagi jika dilakukan dengan citra multi-temporal. Kemudian, algoritma ini dikembangkan oleh [10] dengan memberikan pembobotan pada spektral dan temporal. Namun, tetap saja algoritma ini memperlakukan setiap kanal adalah *independent* dari kanal lainnya.

Selanjutnya, metode baru datang dengan memanfaatkan kombinasi semua kanal bersamaan untuk mencari korelasi secara optimal antara citra bi-temporal. Metode ini memfasilitasi teknik deteksi perubahan yang biasa disebut MAD yang mana algoritma ini difasilitasi oleh CCA sebagai pencarian korelasi yang optimal [17]. Namun, metode ini mengalami batasan pada saat sebagian besar citra mempunyai fitur yang *variant* (awan). Sehingga, tidak ada pembatasan yang optimal dalam penyeleksian PIFs. Dan juga jika kedua citra mempunyai *variant* yang sama pada lokasi yang sama, maka *variant* tersebut akan tergolongkan dalam piksel yang *invariant* (PIFs). Sebagai contoh, jika awan berada pada kedua citra tersebut pada posisi piksel yang sama, maka awan tersebut tidak dapat diseleksi karena dianggap bahwa korelasi antara kedua piksel tersebut sangat dekat. Untuk mengatasi ini, maka perlu adanya pembobotan temporal selain dengan pembobotan sudut spektral. Pembobotan temporal ini bertujuan untuk menyeleksi piksel *variant* pada kedua citra dengan mempertimbangkan citra yang lain. Metode ini dikenal dengan WRGCCA dimana regularisasinya ditentukan untuk menghindari *overfitting*. Algoritma ini dibangun berlandaskan pada algoritma GCCA yang diusulkan oleh [13] tanpa pemberian pembobotan temporal dan spektral. Sehingga metode ini sangat rentan dengan perubahan variasi citra dan sehingga penyeleksian piksel menjadi sulit untuk ditentukan.

## 2.3 Bagan Alir prosedur RRN

Pada Gambar 2, proses RRN dilakukan pada citra Landsat 7 dan Landsat 8 secara bermasamaan. Dalam prakteknya, data citra yang digunakan ada empat citra. Satu citra yang terdiri dari Landsat 7 sebagai Target dan yang lainnya terdiri dari Landsat 8 sebagai Subjek yang akan dinormalisasi. Untuk mengetahui perbedaan antara citra yang telah dan belum dinormalisasi, dapat digambarkan pada Gambar 2 (pojok kiri atas) dimana empat citra mosaik tersebut terdapat garis lurus horisontal yang mengindikasikan perbedaan radiometrik. Sedangkan pada Gambar 2 (pojok kanan bawah) dapat terlihat antara ke empat citra tersebut mempunyai intensitas DN (*digital number*) yang hampir sama. Kemudian, pada Gambar 2, citra orisinal Landsat 7 dan Landsat 8 dan citra PIFs, merupakan urutan citra multi-temporal sesuai dengan urutan akuisisi citra. Sehingga, citra PIFs ditentukan dengan urutan akuisisi citra satelit tersebut.



Gambar 2. Bagan alir proses normalisasi. Urutan dari kiri ke kanan dan dilanjutkan dibawahnya. (Area: Jawa Tengah)

#### 2.4 Membangun algoritma multi-temporal

CCA sebagaimana yang dijelaskan oleh [19] menerangkan tentang hubungan linear antara dua set variabel atau citra dengan mencari titik optimalnya. Kemudian, algoritma ini dikembangkan oleh Tenenhaus [13] yang difasilitasi oleh pengelompokan multi-variabel. Istilah multi-variabel ini kemudian akan di kenal sebagai multi-temporal dalam data citra satelit. Tenenhaus mengembangkan metode ini yang kemudian diberi nama RGCCA. Metode ini juga menggunakan regularisasi untuk dapat mencapai multi-collinerity sehingga dapat menghilangkan efek *overfitting* pada data citra. Metode RGCCA bertujuan untuk mencari hubungan linear antara citra dengan mempertimbangkan koneksi (bersinggungan) antara citra; dengan cara menambahkan konstanta 1 pada citra yang bersinggungan dan 0 pada citra yang tidak bersinggungan.

Sebelum memahami penjelasan tentang RGCCA, algoritma CCA (*original CCA*) yang telah dijelaskan oleh [8], [11], [12], [16], [19]–[22] sangat dianjurkan untuk dipahami terlebih dahulu. Asumsikan bahwa  $N$  adalah vektor acak dari intensitas citra dan  $j$  adalah jumlah kanal yang diberikan sebagai:

$$\begin{aligned} x_j &= (x_{j1}, \dots, x_{jN})^T \\ x_k &= (x_{k1}, \dots, x_{kN})^T \end{aligned} \quad (2)$$

dimana  $x_j$  adalah variabel *zero-mean* dan  $j = k$ . Jika kita menggunakan empat citra, maka akan digunakan pula variabel  $x_l, x_m$  yang menerangkan ada empat data citra multi-temporal dengan jumlah kanal dan area yang sama. Sehingga akan dibentuk kombinasi linear dengan vektor  $\alpha_j = (\alpha_{j1}, \dots, \alpha_{jJ})^T$  adalah *Eigen vector* yang menyatakan  $J$  sesuai dengan jumlah kanal yang digunakan. Skema dari keempat citra multi-temporal tersebut, citra yang

bersinggungan didesain sebagai matrik  $C = \{C_{jk}\}$  dimana  $C_{jk} = 1$  dan  $C_{jk} = 0$  jika citra tidak bersinggungan.

Sebelum pada proses optimasi korelasi linear, kedua komponen  $\mu_j = \sum_h \alpha_{jh} x_{jh} = \alpha_j^T x_j$  dan  $\mu_k = \sum_h \alpha_{kh} x_{kh} = \alpha_k^T x_k$ , dimana variabel  $\mu_j$  dan  $\mu_k$  adalah *outer component* yang telah diketahui. Sehingga, proses optimasinya dapat dicapai dengan menggunakan formula (3),

$$\underset{\alpha_1, \dots, \alpha_J}{\text{maximize}} \sum_{j,k=1; j \neq k}^J C_{jk} g(\rho(\alpha_j^T x_j, \alpha_k^T x_k)) \quad (3)$$

dimana proses optimasinya dilakukan terhadap *constraints*  $Var\{\alpha_j^T x_j\} = 1$ , dimana  $j = 1, \dots, J$  menerangkan jumlah kanal. Proses optimasi algoritma (3) bisa disebut dengan GCCA. Pada algoritma (3), skema fungsi  $g$  menjelaskan tentang penggunaan istilah PLS (*partial least square*) yang dilakukan oleh *Horst scheme*, dimana fungsi  $g$  sesuai dengan matrik identitas. Sehingga algoritma (3) menjadi (4),

$$\underset{\alpha_1, \dots, \alpha_J}{\text{maximize}} \sum_{j,k=1; j \neq k}^J C_{jk} g(\alpha_j^T \Sigma_{jk} \alpha_k) = \frac{\alpha_j^T \Sigma_{jk} \alpha_k}{\sqrt{\alpha_j^T \Sigma_{jj} \alpha_j \alpha_k^T \Sigma_{kk} \alpha_k}} \quad (4)$$

dengan *constraint* terhadap  $\alpha_j^T \Sigma_{jj} \alpha_j = 1$ , dimana  $\Sigma_{jj} = \sum_1^N \frac{1}{N} (x_{jN} - \bar{x}_j)(x_{jN} - \bar{x}_j)^T$  dan  $\Sigma_{kk} = E(x_k x_k^T)$  adalah matrik *variant* dan  $\Sigma_{jk} = E(x_j x_k^T)$  adalah matrik *covariant*.

Setelah kita telah membuat skema optimasi korelasi anantara ke empat citra tersebut, maka dalam prakteknya memerlukan bantuan fungsi *Lagrangiang* sehingga algoritma (4) menjadi,

$$F(\alpha_1, \dots, \alpha_J, \lambda_1, \dots, \lambda_J) = \sum_{j,k=1; j \neq k}^n C_{jk} g(\alpha_j^T \Sigma_{jk} \alpha_k) - \varphi \sum_{j=1}^n \frac{\lambda_j}{2} (\alpha_j^T \Sigma_{jj} \alpha_j - 1) \quad (5)$$

dimana  $\lambda_1, \dots, \lambda_J$  adalah pengali *Lagrangiang* yang sesuai dengan  $\alpha_1, \dots, \alpha_J$  dari kombinasi linear vektor *outer weight*. Didalam skema *Horst*,  $\varphi$  sama dengan 1. Sehingga, pada algoritma (5), persamaan *stationary*-nya dapat dibentuk dengan menggunakan *cancelling derivative* terhadap  $\lambda_j$  dan  $\alpha_j$  sehingga menjadi,

$$\frac{1}{\varphi} \Sigma_{jj}^{-1} \sum_{j,k=1; j \neq k}^n C_{jk} g'(\alpha_j^T \Sigma_{jk} \alpha_k) \Sigma_{jk} \alpha_k = \lambda_j \alpha_j \quad (6)$$

Pada algoritma (6) ini tidak ada solusi analitik, cara lain untuk mendapatkan koefisien linearnya dengan menggunakan iterasi dimana nilai inisialnya ditentukan dengan cara acak, atau dengan cara pembobotan yang akan dibahas pada sub-bab berikutnya. Sebelum membahas kesana, pada algoritma (6), perlu adanya metode iterasi sehingga dapat tercapai *converge* untuk mendapatkan *Eigen vector*-nya. Untuk membangun ini, perlu tambahan algoritma dengan memanfaatkan PLS yang diadopsi dari [13]. PLS tersebut memberi kontribusi untuk menentukan *inner-component*  $V_j$  yang diformulakan,

$$V_j = \frac{1}{\varphi} \sum_{k=1; k \neq j}^J C_{jk} g'(\alpha_j^T \Sigma_{jk} \alpha_k) \alpha_k^T x_k \quad (7)$$

dimana  $w(x) = \frac{1}{\varphi} g'(x)$  dan  $w(x) = 1$  untuk skema Horst. Sehingga penggunaan *inner-component* ini, persamaan *stationary*-nya menjadi,

$$\begin{aligned} Cov(x_j, V_j) &= E \left( x_j \sum_{k=1; k \neq j}^n C_{jk} w(\alpha_j^T \Sigma_{jk} \alpha_k) \alpha_k^T x_k \right) \\ Cov(x_j, V_j) &= \sum_{k=1; k \neq j}^n C_{jk} w(\alpha_j^T \Sigma_{jk} \alpha_k) \Sigma_{jk} \alpha_k \\ Cov(x_j, V_j) &= \frac{1}{\varphi} \sum_{k=1; k \neq j}^n C_{jk} g'(\alpha_j^T \Sigma_{jk} \alpha_k) \Sigma_{jk} \alpha_k. \end{aligned} \quad (8)$$

Dan dari persamaan ini, dapat dibuat ulang *outer-weight* vektor  $\alpha_j$  dengan mensubstitusikan terhadap *inner-component* (7) dan (4) dan kemudian *stationary*-nya menjadi (8),

$$\begin{aligned} \alpha_j &= \frac{1}{\lambda_j} \Sigma_{jj}^{-1} \frac{1}{\varphi} \sum_{k=1; k \neq j}^n C_{jk} g'(\alpha_j^T \Sigma_{jk} \alpha_k) \Sigma_{jk} \alpha_k \\ &= \frac{1}{\lambda_j} \Sigma_{jj}^{-1} Cov(x_j, V_j) \\ &= [Cov(x_j, V_j)]^T \Sigma_{jj}^{-1} Cov(x_j, V_j)]^{-\frac{1}{2}} \Sigma_{jj}^{-1} Cov(x_j, V_j). \end{aligned} \quad (8)$$

Persamaan (8) disebut dengan GCCA. Jika data citra mengalami *multi-collinearity*, maka dalam pemrosesan optimasinya juga akan mengalami *overfitting*. Artinya, penyeleksian PIFs pada citra tidak menghasilkan hasil yang baik. Sehingga untuk mengatasinya, penggunaan parameter regularisasi sangat dibutuhkan dalam metode RGCCA. Sehingga dengan penggunaan parameter regularisasi, RGCCA dapat dibangun untuk menghindari *over-* atau *under-fitting*. Penggunaan parameter ini dapat disisipkan pada variabel matrik *variant*  $\Sigma_{jj}$ . Sehingga matrik *variant* tersebut menjadi,

$$S_{jj} = \tau_j I + (1 - \tau_j) \frac{1}{n} X_j^T X_j \quad (9)$$

Sehingga muncul algoritma baru menjadi,

$$\begin{aligned} &\text{maximize}_{\alpha_1, \dots, \alpha_J} \sum_{j,k=1; j \neq k}^J C_{jk} g(\alpha_j^T \Sigma_{jk} \alpha_k) \\ &\text{constraint } \alpha_j^T \left[ \tau_j I + (1 - \tau_j) \frac{1}{N} X_j^T X_j \right] \alpha_j = 1 \end{aligned} \quad (10)$$

dimana  $S_{jk} = \frac{1}{n} X_j^T X_k$ ,  $X_j$  dan  $X_k$  adalah variabel zero-mean, dan  $N$  adalah jumlah vektor acak atau jumlah intensitas pada citra. Dari algoritma (10), maka dapat diulang kembali dari proses (3) sampai dengan (8) sehingga mejadi (11),

$$\frac{1}{\varphi} [\tau_j I + (1 - \tau_j) S_{jj}]^{-1} \sum_{j,k=1; j \neq k}^n C_{jk} g'(\alpha_j^T \Sigma_{jk} \alpha_k) \Sigma_{jk} \alpha_k = \lambda_j \alpha_j \quad (11)$$

dimana  $\varphi = 1$ . Ingat bahwa bentuk persamaan (11) hampir sama dengan persamaan (6), yang membedakannya adalah bentuk matrik *variant* dan *covariant*.

Untuk memperjelas symbol yang digunakan, maka Tabel 1 dapat dilihat sebagai berikut,

TABEL 1. PERBANDINGAN DARI GCCA DAN RGCCA DALAM TERMINOLOGY PLS (*PARTIAL LEAST SQUARE*)

	GCCA	RGCCA
Outer weight vektors	$\alpha_j$	$a_j$
Outer components	$\mu_j$ $\mu_j = \alpha^T X_j$ dan $\mu_k = \alpha^T X_k$	$y_j$ $y_j = X_j a_j$ dan $y_k = X_k a_k$
Inner components (Skema Horst)	$V_j$ $V_j = \sum_{k=1; k \neq j}^J C_{jk} \alpha_k^T x_k$	$Z_j$ $Z_j = \sum_{k=1; k \neq j}^J C_{jk} y_k$

Sehingga, dengan kombinasi kovarian dengan *Inner-component*, maka algoritma untuk mencari *outer-component* dapat dibentuk menjadi (12),

$$\begin{aligned} Cov(x_j, Z_j) &= E(x_j Z_j) = E \left( X_j \frac{1}{\varphi} \sum_{k=1; k \neq j}^n C_{jk} g'(\alpha_j^T \Sigma_{jk} \alpha_k) X_k a_k \right) \\ Cov(x_j, Z_j) &= \frac{1}{\varphi} \sum_{k=1; k \neq j}^n C_{jk} g'(\alpha_j^T \Sigma_{jk} \alpha_k) \frac{1}{n} X_j^T X_k a_k \end{aligned} \quad (12)$$

Vektor *outer-weight*, dapat dibuat ulang menjadi (13),

$$a_j = \frac{1}{\lambda_j} [\tau_j I + (1 - \tau_j) S_{jj}]^{-1} Cov(x_j, Z_j), \quad (13)$$

dimana

$$\lambda_j = [Cov(x_j, Z_j)]^T (\tau_j I + (1 - \tau_j) S_{jj})^{-1} Cov(x_j, Z_j)]^{\frac{1}{2}}.$$

Kemudian, tahapan akhir dari algoritma RGCCA adalah dapat diformulakan sebagai berikut,

$$\begin{aligned} a_j &= n^{\frac{1}{2}} \left[ Z_j^T X_j [\tau_j I + (1 - \tau_j) X_j^T X_j]^{-1} X_j^T Z_j \right]^{-\frac{1}{2}} [\tau_j I + \\ &(1 - \tau_j) X_j^T X_j]^{-1} X_j^T Z_j, \end{aligned} \quad (14)$$

dimana

$$\begin{aligned} Z_j^s &= \sum_{k < j; k \neq j}^J C_{jk} w[Cov(X_j a_j^s, X_k a_k^{s+1})] X_k a_k^{s+1} + \dots \\ &\dots \sum_{k > j; k \neq j}^J C_{jk} w[Cov(X_j a_j^s, X_k a_k^s)] X_k a_k^s. \end{aligned}$$

Pada algoritma (14),  $w[Cov(X_j a_j^s, X_k a_k^{s+1})] = 1$  pada skema *Horst*. Jika kita menginginkan untuk mencari korelasi pada citra multi-temporal, maka parameter regularisasinya  $\tau_j$  harus ditentukan dengan nilai yang rendah atau sama dengan 0. Sebaliknya, jika kita ingin mencari hubungan covariannya, maka parameter regularisasinya sama dengan 1.

Dengan demikian, algoritma RGCCA dapat dibentuk untuk mencari korelasi yang maksimum antara data citra multi-temporal. Namun, kontribusi utama dalam makalah ini akan dijelaskan dengan pemberian teknik pembobotan yang sesuai dengan spektral dan temporalnya. Bab bahasan ini akan dijelaskan pada sub-bab 2.5.

2.5 Metode yang diusulkan: skema pembobotan multi-temporal (IRMAD)

Dengan penggunaan metode RGCCA yang telah dijelaskan diatas, perlakuan setiap piksel dianggap sama, sehingga untuk mencari korelasi yang optimal, RGCCA masih sangat sensitif dengan perubahan dan tidak berhasil memisahkan antara PIFs dan Non-PIFs. Metode yang diusulkan ini menekankan pada pengaturan pembobotan secara sudut spektral dan temporal dengan konsep yang telah diaplikasikan pada [10]. Pembobotan secara spektral kemudian disebut dengan SA (*spektral angle*). Dengan aturan bahwa citra yang bersinggungan sama dengan  $C = \{C_{jk}\}$ , maka SA dapat ditentukan sebagai,

$$SA = \cos^{-1} \left( \frac{\sum_{n=1}^N v_n^a v_n^b}{\sqrt{\sum_{n=1}^N (v_n^a)^2 \sum_{n=1}^N (v_n^b)^2}} \right) \quad (15)$$

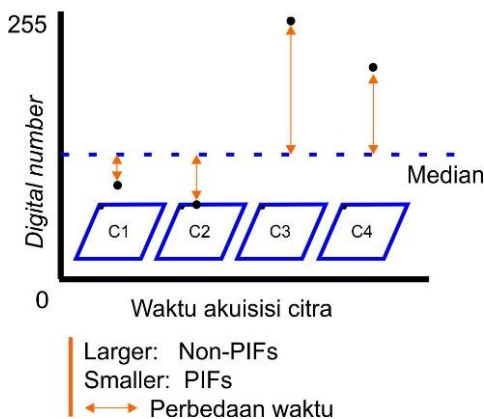
dimana  $v$  adalah vektor acak antara dua citra yang bersinggungan, sebut citra a dan citra b, dan  $N$  adalah jumlah piksel. Pada pembobotan initial, SA sangat penting dalam mendiskripsikan citra, bi-temporal. Pembonotan ini kemudian dapat membentuk WM (*weighted-mean*) (16), (WC) *weighted-covarian* (17), (WV) *weighted-varian* (18) secara berurutan.

$$WM = \frac{\sum_{j=1}^N w_j X_{ji}}{\sum_{j=1}^N w_j} \quad (16)$$

$$WC = \frac{\sum_{j=1}^N w_j (X_{jk} - \bar{X}_k)(X_{jl} - \bar{X}_l)}{(N-1) \sum_{j=1}^N w_j / N} \quad (17)$$

$$WV = \frac{\sum_{j=1}^N w_j (X_{jk} - \bar{X}_k)^2}{(N-1) \sum_{j=1}^N w_j / N} \quad (18)$$

Kemudian untuk iterasi selanjutnya, penggunaan bobot temporal dan nilai NMAD (deteksi perubahan multivarian normalisasi) harus ditambahkan dalam algoritma pembobotan yang digambarkan pada Tabel 2.



Gambar 3. Pembobotan temporal menggunakan perbedaan waktu. Metode ini menggunakan setiap pikselnya pada citra multi-temporal untuk mencari nilai mediannya.

Kemudian, untuk memperjelas skema pembobotan temporal dapat dilihat pada Gambar 3. Dalam gambar ini


dijelaskan bahwa pemberian bobot yang besar diaplikasikan pada citra *invariant* atau yang bebas dari awan, sebaliknya pada pemberian bobot pada fitur *variant* akan diberikan nilai yang kecil. Sehingga, dapat disimpulkan bahwa jika pada citra multi-temporal tersebut, kondisi awan yang sedikit akan memberikan hasil PIFs yang lebih akurat daripada pada citra dengan kondisi awan yang banyak.

Untuk mendapatkan nilai NMAD, yaitu dengan system perkalian menggunakan Eigen vector yang diperoleh dari WGCCA, *outer-weight*  $\alpha_1, \dots, \alpha_j$ . Eigen vector ini akan dikalikan dengan variabel *zero-mean*  $X_j$  yang dideskripsikan sebagai berikut,

$$U_j = \alpha_j^T X_j, \quad j = 1, \dots, J \quad (19)$$

$$Var(U_j - U_k) = Var(U_j) + Var(U_k) - 2Cov(U, V), \quad \text{maximum} \quad (20)$$

$$MAD_{jk} = \sum_{j < k, k=2; j \neq k}^J C_{jk} (U_j - U_k) \quad (21)$$



Gambar 4. Contoh penggunaan empat citra yang diperoleh dari waktu akuisisi yang berdekatan (dalam rentang satu tahun), C1, C2, C3 dan C4.  $SA_{12}$ ,  $SA_{23}$ ,  $SA_{34}$  adalah SA yang diperoleh dari citra yang bersinggungan. Begitu juga pada  $NMAD_{12}$ ,  $NMAD_{23}$ ,  $NMAD_{34}$  dibuat dengan mempertimbangkan citra yang bersinggungan.

Berdasarkan pada [17], korelasi positif antara  $U_j$  dan  $U_k$  harus di minimalkan. Kemudian intensitas dari citra yang berdekatan dimaksimalkan pada keseluruhan piksel dengan cara mengurangi variabel  $U_j - U_k$ . Dengan pengurangan ini, korelasi pada kedua citra tersebut akan meningkat. Metode ini disebut dengan MAD. Kemudian, untuk menormalisasikan MAD ini, proses ini akan sempurna untuk mencari korelasi secara maksimal dengan mengaplikasikan NMAD sebagai berikut,

$$\sum_{j=1}^J \left( \frac{MAD_j}{\sigma_{MAD_j}} \right)^2 > \text{threshold} \quad (22)$$

$$NMAD = \frac{\sum_{j,k=1; j \neq k}^N C_{jk} W_{jk} NMAD_{jk}}{\sum_{j,k=1; j \neq k}^N W_{jk}} \quad (23)$$

dimana  $W_{jk}$  = koefisien dari korelasi, artinya bahwa jika NMAD mempunyai nilai yang tinggi, maka piksel tersebut mengindikasikan bahwa korelasi antar kedua citra adalah tinggi, begitu juga sebaliknya. Korelasi yang tinggi mengindikasikan bahwa piksel tersebut merupakan termasuk PIFs yang akurat.

Dari algoritma MAD (21), maka IRMAD dapat dibangun dengan penggunaan pembobotan dari skema Tabel 2, dengan perulangan secara iteratif untuk mencari

hasil yang maksimal (*converge*). Dari Tabel 2, untuk lebih jelasnya dapat ekspresikan dengan Gambar 4.

TABEL 2. SKEMA PEMBOBOTAN PADA SAAT ITERASI PERTAMA DAN SETELAHNYA.

Skema pembobotan	
Pembobotan awal	Setelahnya
SA ( <i>Spectral angle</i> )	Nilai NMAD x Perbedaan waktu

### III. HASIL DAN PEMBAHASAN

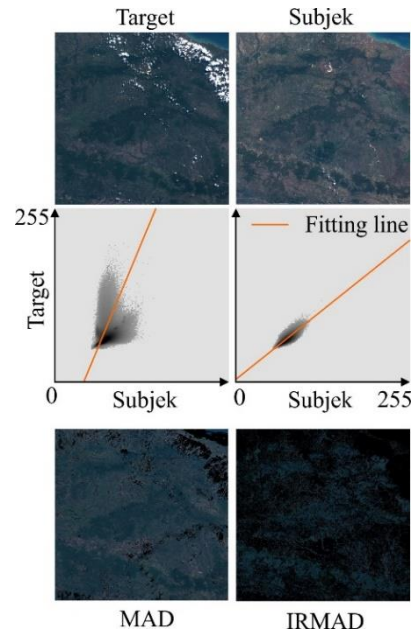
Untuk melakukan evaluasi dari algoritma ini, WRGCCA, maka perlu adanya penyediaan data yang signifikan sehingga dapat menjelaskan tentang keakuratan algoritma yang telah dibangun. Sehingga pada proses evaluasi ini, disediakan data yang banyak mengandung fitur *variant* (awan) hingga pada fitur yang *invariant*. Data tersebut digolongkan dalam berbagai area yaitu di Jawa Tengah sebagai dataset I, Jawa Timur sebagai dataset II, dan Taiwan sebagai dataset III. Untuk melakukan evaluasi algoritma ini, tidak terbatas pada data lokasi yang disebutkan, namun bisa data dari area yang berbeda, sensor yang berbeda, namun dalam kondisi resolusi spasial dan resolusi intensitas *digital number* yang sama. Ingat bahwa metode ini tidak dapat di implementasikan pada data citra yang resolusinya berbeda, perlu adanya penyetaraan resolusi dan koreksi geometric (*registration*) sebelum pengolahan data dilakukan.

Untuk mengevaluasi kemampuan penyeleksian PIFs, maka perbandingan MAD yang diperoleh dari algoritma GCCA dan IRMAD yang diperoleh dari algoritma WRGCCA telah dilakukan. Pada Gambar 5 (bagian atas) adalah citra Target dan citra Subjek secara bi-temporal, gambar bagian tengah menjelaskan hasil penyeleksian PIFs yang dilakukan oleh MAD dan IRMAD terlihat sangat berbeda secara signifikan, dan gambar bagian bawah menjelaskan tentang citra yang terdiri dari PIFs, dimana warna hitam adalah area yang merupakan fitur *variant* atau piksel yang berubah dan warna *true color* merupakan hasil ekstraksi dari PIFs.

Pada Gambar 6, menjelaskan implementasi GCCA dan WRGCCA dengan menggunakan empat citra sekaligus. Pada Gambar 6 (bagian atas) menjelaskan citra mosaik yang disusun berdasarkan tanggal yang berurutan, dari Citra-1 hingga Citra-4. Citra yang bersinggungan merupakan Citra 1-2, Citra 2-3, dan Citra 3-4. Dari Gambar 6 (atas), dapat dilihat bahwa garis lurus horizontal antara citra yang bersinggungan terlihat sangat jelas disebabkan karena perbedaan radiometrik yang terjadi pada setiap akuisisi citra. Perbedaan ini akan menghilang ketika prosedur normalisasi dilakukan sebagaimana yang telah digambarkan pada Gambar 6 (bagian bawah). Hampir jelas bahwa perbedaan radiometrik telah tereduksi

hingga pada level yang sama terhadap citra Target (Citra-1).

Untuk mengevaluasi hasil pengaplikasian algoritma GCCA dan WRGCCA, sangat sulit dengan menggunakan visualisasi. Sebagai contoh pada Gambar 5 dan Gambar 6 (bagian tengah), terdapat hasil *scatterplot* ekstraksi PIFs. Pada gambar *scatterplot* tersebut diekspresikan sebagai *outliers* yang akan membuat kesalahan pada proses normalisasi. Kemunculan *outliers* ini yang akan membuat citra yang akan dinormalisasi mengalami *overfitting* atau *underfitting*.



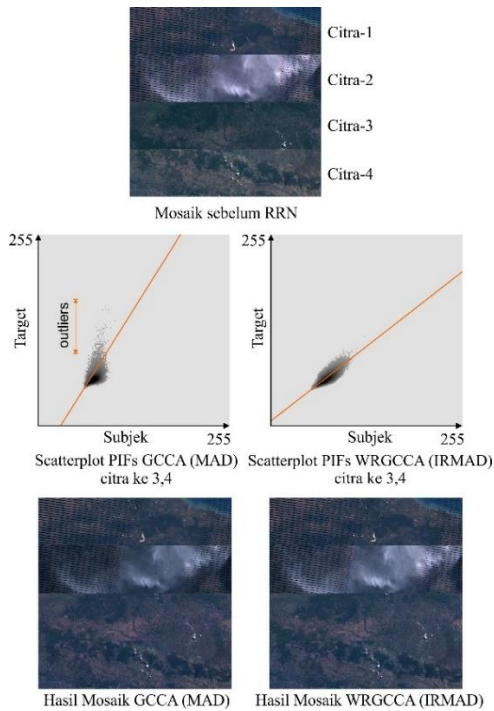
Gambar 5. Perbandingan penyeleksian PIFs terhadap metode MAD dan IRMAD. (Area: Jawa Tengah)

Sebagai contoh lain pada Gambar 6 (bagian bawah), kedua citra tersebut terlihat hampir sama dalam intensitas *digital number*-nya. Namun jika dilihat dengan seksama, warna kemerah-merahan akan sangat jelas terlihat pada mosaik GCCA (bawah-kiri). Sedangkan pada gambar hasil mosaik WRGCCA (bawah-kanan), gradasi warna antara data citra bisa dikategorikan hampir sama, kecuali pada area awan yang terdapat pada Citra-2.

Evaluasi lebih jauh dapat dilakukan dengan menentukan RMSE (*Root Mean Squared Error*) dari data citra yang telah dinormalisasi terhadap citra Target. Citra yang telah dinormalisasi bisa disebut dengan citra terkoreksi. Proses awal dalam menghitung RMSE dapat dilakukan dengan pemfilteran data oleh PIFs. Sehingga data citra yang terkoreksi dan data citra Target dapat dievaluasi dengan piksel yang hanya mengandung nilai PIFs yang akurat. Nilai RMSE tersebut dalam pengaplikasian multi-temporal, diperoleh dari citra yang bersinggungan yaitu Citra 1-2, Citra 2-3, Citra 3-4



(Gambar 6) dengan disimbolkan pada Tabel 3 sebagai C1-2, C2-3, dan C3-4 secara berurutan. Untuk lebih jelas memahami skema penyusunan ini, maka Gambar 7 tersedia antara C1-C2 yang sesuai dengan PIF1-PIF2 yang diekstraksi dari proses MAD dan IRMAD secara berurutan. Dapat dilihat bahwa hasil seleksi PIFs pada metode MAD terlihat masih terdapat fitur *variant* (awan) dibandingkan dengan metode IRMAD yang sangat akurat dalam penyeleksian PIFs.



Gambar 6. Perbandingan penyeleksian PIFs terhadap metode MAD dan IRMAD. (Area: Jawa Tengah)

Dalam proses analisa kuantitatif, dapat dilihat bahwa nilai RMSE pada citra yang dilakukan WRGCCA sangat rendah dibandingkan daripada citra yang dilakukan GCCA. Hal ini sangat jelas bahwa skema pembobotan yang dimaksud sangat memberikan pengaruh normalisasi yang sangat signifikan. Begitu juga yang terjadi pada citra dataset II dan citra dataset III.

TABEL 3. ANALISA KUANTITATIF DARI DATA PIFS, DATASET I (JAWA TENGAH)


Kanal	RMSE (GCCA)			RMSE (WRGCCA)		
	C1-2	C2-3	C3-4	C1-2	C2-3	C3-4
1	17,18	15,00	6,28	9,45	9,47	4,34
2	14,86	13,45	6,37	8,15	8,52	4,46
3	16,45	15,06	7,42	9,45	10,62	6,09
4	9,32	9,52	9,05	8,47	7,89	7,32
5	10,56	10,81	8,24	9,81	9,93	7,10
6	8,96	8,85	7,46	6,91	7,81	6,29

TABEL 4. ANALISA KUANTITATIF DARI DATA PIFS, DATASET II (JAWA TIMUR)

Kanal	RMSE (GCCA)			RMSE (WRGCCA)		
	C1-2	C2-3	C3-4	C1-2	C2-3	C3-4
1	11,59	7,01	9,26	9,09	5,66	6,78
2	9,52	6,55	8,47	7,68	5,30	6,43
3	11,24	7,94	9,62	9,14	7,23	7,08
4	10,28	9,11	7,43	9,93	9,87	6,97
5	10,81	8,99	8,08	9,16	8,40	6,44
6	6,91	7,25	7,24	6,66	6,88	6,04

TABEL 5. ANALISA KUANTITATIF DARI DATA PIFS, DATASET III (TAIWAN)

Kanal	RMSE (GCCA)			RMSE (WRGCCA)		
	C1-2	C2-3	C3-4	C1-2	C2-3	C3-4
1	14,32	15,03	11,51	8,06	7,38	2,62
2	11,60	14,94	11,67	6,17	8,33	2,71
3	13,63	15,55	11,83	6,69	8,53	2,71
4	10,80	19,95	13,36	9,73	22,98	6,50
5	11,16	19,63	13,41	7,17	20,16	6,03
6	9,06	14,67	12,09	4,54	11,26	3,58



Gambar 7. Perbandingan penyeleksian PIFs terhadap metode MAD dan IRMAD. (Area: Taiwan) Gambar bagian atas menjelaskan hasil sebelum citra terkoreksi dan telah terkoreksi. Pada gambar dengan Tabel Citra Orisinal, GCCA (MAD), dan WRGCCA (IRMAD) adalah penampakan citra yang bersinggungan. Warna hitam merepresentasikan fitur *variant* (*changed piksel*)

#### IV. KESIMPULAN

Studi ini menerangkan metode WRGCCA dengan data multi sensor dan multi-temporal. Dengan menggunakan ketiga data tersebut, citra dataset I (Jawa Tengah), citra dataset II (Jawa Timur) dan citra dataset III (Taiwan), yang digunakan untuk mengevaluasi performa kedua algoritma tersebut. Hasil evaluasi dilakukan dengan menggunakan metode RMSE, yang menyatakan bahwa WRGCCA lebih baik dalam melakukan RRN daripada

metode GCCA. Pada Tabel 3, Tabel 4, dan Tabel 5, penurunan nilai RMSE pada WRGCCA dapat diukur mencapai 10% hingga 50% terhadap nilai RMSE dari metode GCCA. Penurunan nilai RMSE ini sangat signifikan, sehingga hal ini menunjukkan adanya perbaikan dalam mereduksi perbedaan radiometric dari hasil citra normalisasi. Hasil normalisasi yang baik ini juga telah dibuktikan dalam proses penyeleksian PIFs pada data multi-temporal secara visualisasi. Hal ini sangat logis, ketika proses penyeleksian PIFs mendapatkan hasil yang akurat, maka secara bersamaan akan menentukan hasil normalisasi pada citra tersebut. Penelitian ini menggunakan data Landsat 7 dan Landsat 8 sebagai data pengujian. Akan tetapi, citra dari sensor lainnya juga dapat digunakan dengan memperhatikan tiga aspek penting yaitu, perlu adanya penyamaan resolusi piksel dan spasial, koreksi geometrik atau yang biasa disebut registrasi, dan penyamaan resolusi DN (*digital number*) pada tahapan *pre-processing*.

#### UCAPAN TERIMAKASIH

Alhamdulillah telah terselesaikan penelitian ini dengan baik. Saya mengucapkan terimakasih kepada National Cheng Kung University yang telah memberikan tempat pembelajaran secara optimal. Kepada teman dan kerabat serta kepada para dosen dan para peneliti atas saran dan koreksinya dalam membangun metode ini.

#### DAFTAR PUSTAKA

- [1] N. Mishra, M. O. Haque, L. Leigh, D. Aaron, D. Helder, and B. Markham, "Radiometric cross calibration of landsat 8 Operational Land Imager (OLI) and landsat 7 enhanced thematic mapper plus (ETM+)," *Remote Sens.*, vol. 6, no. 12, pp. 12619–12638, 2014.
- [2] D. P. Roy *et al.*, "Characterization of Landsat-7 to Landsat-8 reflective wavelength and normalized difference vegetation index continuity," *Remote Sens. Environ.*, vol. 185, pp. 57–70, 2016.
- [3] P. M. Teillet, "Topographic correction," vol. 7, no. 12, 1986, pp. 1637–1651.
- [4] X. Yang and C. P. Lo, "Relative radiometric normalization performance for change detection from multi-date satellite images," *Photogramm. Eng. Remote Sensing*, vol. 66, no. August, pp. 967–980, 2000.
- [5] I. Olthof, D. Pouliot, R. Fernandes, and R. Latifovic, "Landsat-7 ETM+ radiometric normalization comparison for northern mapping applications," *Remote Sens. Environ.*, vol. 95, no. 3, pp. 388–398, 2005.
- [6] Y. Du, P. M. Teillet, and J. Cihlar, "Radiometric normalization of multitemporal high-resolution satellite images with quality control for land cover change detection," *Remote Sens. Environ.*, vol. 82, no. 1, pp. 123–134, 2002.
- [7] M. J. Canty and A. A. Nielsen, "Automatic radiometric normalization of multitemporal satellite imagery," *Remote Sens. Environ.*, vol. 112, no. 3, pp. 1025–1036, 2008.
- [8] M. A. Syariz, B. Y. Lin, L. G. Denaro, L. M. Jaelani, M. Van Nguyen, and C. H. Lin, "Spectral-consistent relative radiometric normalization for multitemporal Landsat 8 imagery," *ISPRS J. Photogramm. Remote Sens.*, vol. 147, no. March 2018, pp. 56–64, 2019.
- [9] D. Yuan and C. D. Elvidge, "Comparison of relative radiometric normalization techniques," *ISPRS J. Photogramm. Remote Sens.*, vol. 51, no. 3, pp. 117–126, 1996.
- [10] C.-H. Lin, B.-Y. Lin, K.-Y. Lee, and Y.-C. Chen, "Radiometric normalization and cloud detection of optical satellite images using invariant pixels," *ISPRS J. Photogramm. Remote Sens.*, vol. 106, pp. 107–117, 2015.
- [11] M. J. Canty and A. A. Nielsen, "Automatic radiometric normalization of multitemporal satellite imagery with the iteratively re-weighted MAD transformation," *Remote Sens. Environ.*, vol. 112, no. 3, pp. 1025–1036, 2008.
- [12] A. A. Nielsen, K. Conradsen, and J. J. Simpson, "Multivariate alteration detection MAD and MAF postprocessing in multispectral bitemporal image data New approaches to change detection studies," *Remote Sens. Environ.*, vol. 4257, no. 97, pp. 1–19, 1998.
- [13] A. Tenenhaus, "Regularized Generalized Canonical Correlation Analysis and PLS Path Modeling," *Psychometrika*, vol. 76, no. 2, pp. 257–284, 2011.
- [14] A. Tenenhaus and M. Tenenhaus, "Regularized generalized canonical correlation analysis for multiblock or multigroup data analysis," *Eur. J. Oper. Res.*, vol. 238, no. 2, pp. 391–403, 2014.
- [15] A. Tenenhaus, C. Philippe, and V. Frouin, "Kernel Generalized Canonical Correlation Analysis," *Comput. Stat. Data Anal.*, vol. 90, pp. 114–131, 2015.
- [16] L. G. Denaro, L. Bo-Yi, M. A. Syariz, L. M. Jaelani, and C.-H. Lin, "Pseudoinvariant feature selection for cross-sensor optical satellite

- images,” *J. Appl. Remote Sens.*, vol. 11, no. 1, 2018.
- [17] M. J. Canty, A. A. Nielsen, and M. Schmidt, “Automatic radiometric normalization of multitemporal satellite imagery,” *Remote Sens. Environ.*, vol. 91, no. 3–4, pp. 441–451, 2004.
- [18] F. G. Hall, D. E. Strebel, J. E. Nickeson, and S. J. Goetz, “Radiometric rectification: Toward a common radiometric response among multirate, multisensor images,” *Remote Sens. Environ.*, vol. 35, no. 1, pp. 11–27, 1991.
- [19] H. Hotelling, “Relations Between Two Sets of Variates,” *Biometrika*, vol. 28, no. 3/4, p. 321, 1936.
- [20] D. Hardoon, S. Szedmak, and J. Shawe-Taylor, “Canonical Correlation Analysis: An Overview with Application to Learning Methods,” *Neural Comput.*, vol. 16, no. 12, pp. 2639–2664, 2004.
- [21] Y. Bai, P. Tang, and C. Hu, “Kernel Mad Algorithm for Relative Radiometric Normalization,” *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. III-1, no. July, pp. 49–53, 2016.
- [22] O. A. De Carvalho Júnior *et al.*, “Radiometric normalization of temporal images combining automatic detection of pseudo-invariant features from the distance and similarity spectral measures, density scatterplot analysis, and robust regression,” *Remote Sens.*, vol. 5, no. 6, pp. 2763–2794, 2013.