

Penggunaan Model Multinomial Untuk Mendukung Keputusan Neural Buatan Dalam Klasifikasi dan Deteksi Perubahan Penutup Lahan Citra Multi Waktu dan Multi Sensor

Wawan Setiawan
Jurusan Ilmu Komputer
Universitas Pendidikan Indonesia
pik@upi.edu

Abstract

This paper presents the results of continuing study on image classification. In previous study, have recommended a neuro-statistical scheme in the framework of multitemporal optical-sensor image classification. The scheme consists of neural network classifier to compute the posterior probabilities, expectation maximum method to optimize prior joint probabilities, and compound probabilities to produce thematic image and change image. This paper reports the results of extending the scheme for multivariate multisensor image classification. For each sensor image classifier, two schemes have been evaluated. The first scheme has used the co-occurrence matrix texture feature images or original tonal images as the input data and the Gaussian kernel for the neural network classifier. The second scheme has used the original tonal image as the input data and the multinomial co-occurrence matrix kernel for the neural network classifier. Based on this study we have proposed a scheme for multivariate-multisensor image classification.

Keywords: Probabilistic Neural Network, Gaussian Model, Multinomial Model, Multisensor Multitemporal.

Abstrak

Makalah ini menyajikan hasil studi berkelanjutan pada klasifikasi citra. Dalam studi sebelumnya, telah direkomendasikan skema neuro-statistik dalam skema multi temporal citra sensor optik. Skema ini terdiri atas pengklasifikasi jaringan neural untuk menghitung probabilitas posterior, metode ekspektasi maksimum untuk mengoptimalkan probabilitas join, dan probabilitas majemuk untuk menghasilkan citra tematik dan citra perubahan penutup lahan. Makalah ini melaporkan hasil perluasan dari skema yang telah ada untuk klasifikasi citra multi waktu – multi sensor. Untuk setiap pengklasifikasi citra sensor, dua skema telah dilakukan pengujian. Skema pertama menggunakan fitur tekstur citra tonal asli sebagai data input Model Gaussian untuk pengklasifikasi jaringan neural. Skema kedua menggunakan fitur tekstur citra asli dan matrik ko-okuren dengan Model Multinomial sebagai data input pengklasifikasi jaringan neural. Berdasarkan studi ini kami merekomendasi sebuah skema untuk klasifikasi citra multi waktu- multi sensor.

Kata Kunci: Probabilistic Neural Network, Model Gaussian, Model Multinomial, Multisensor Multitemporal

1. Pendahuluan

Indonesia telah lama menggunakan data sensor optik untuk mendukung program pengelolaan sumber daya alam sejak ERTS-1 yang diluncurkan pada tahun 1972. Kebutuhan untuk menggunakan citra sensor SAR (Synthetic Aperture Radar) dalam klasifikasi penutup lahan menjadi penting karena adanya gangguan awan pada citra optik. Sebaliknya citra sensor *Synthetic Aperture Radar* (SAR) tidak terganggu awan namun belum banyak digunakan untuk pemetaan lahan karena relatif lebih sulit dalam interpretasinya. Pada beberapa studi, penggunaan citra optik atau SAR saja secara tunggal dipandang kurang memadai. Oleh karena itu menjadi penting untuk mengembangkan suatu skema untuk pengolahan citra multi sensor. Adapun data citra multi waktu sangat cocok digunakan untuk identifikasi dan mendeteksi perubahan penutup lahan, dan juga

untuk mereduksi gangguan (noise). Berdasarkan hal tersebut, selanjutnya skema yang menarik untuk dikembangkan dalam pengolahan citra adalah sebuah skema untuk multi sumber (multi waktu – multi sensor).


Murni dkk. [1] telah menggunakan pendekatan statistik untuk klasifikasi citra multi sumber dan fusi, serta untuk mengeliminasi gangguan awan. Bruzzone dkk. [3] telah juga menggunakan pendekatan *neuro-statistik* dengan Jaringan Neural Buatan (JNB) Propagasi Balik (BP) untuk klasifikasi citra multi sumber. Murni dkk. [2] melakukan modifikasi terhadap skema Bruzzone, dkk. [3] dengan Jaringan Neural Probabilistik (PNN) selain Jaringan Neural Buatan Propagasi Balik (BPNN) untuk skema klasifikasi citra multi waktu. Benediktsson dkk. [4] melakukan studi perbandingan antara pendekatan statistik dan pendekatan jaringan neural untuk klasifikasi dan fusi citra multi sumber.

Skema yang diusulkan dalam riset ini menggunakan pendekatan yang tergolong *neuro-statistic*. Skema ini dapat dianggap sebagai penyempurnaan pendekatan berbasis model dalam melakukan komputasi probabilitas *posterior* ketika menggunakan pengklasifikasi Probabilistic Neural Network (PNN). Selanjutnya, probabilitas posterior digunakan sebagai masukan metode ekspektasi maksimum (EM) untuk mendapatkan probabilitas *join* yang optimal dalam kontekstual multi sumber. Probabilitas *join* optimal selanjutnya digunakan oleh pengklasifikasi majemuk untuk menghasilkan citra tematik dan citra perubahan terbaik. Model Gaussian efektif dan baik untuk citra input yang homogen (bukan tekstur). Sementara citra SAR memiliki tekstur, sehingga model Gaussian menjadi kurang efektif. Dalam penelitian ini lakukan uji coba terhadap dua skema. Skema pertama, input citra adalah fitur tonal atau tekstur citra, yang diharapkan akan lebih homogen dari citra asli menggunakan pengklasifikasi PNN Model Gaussian. Skema kedua, input citra adalah fitur tekstur citra dan menggunakan pengklasifikasi PNN Model Multinomial. Lohmann [5] telah memperkenalkan perhitungan probabilitas posterior berdasarkan distribusi multinomial menggunakan matriks ko-okuren. Selanjutnya fokus riset ini untuk mengembangkan pengklasifikasi uniform berbasis PNN untuk memecahkan data multi waktu dan multi sensor dengan parameter gabungan.


2. Metodologi dan Eksperimen

2.1. Data Eksperimen

Citra multi sensor (SPOT pankromatik dan Airborne SAR) daerah Muara Sekampung dan T dan citra multi waktu (Landsat TM) daerah Saguling digunakan sebagai data riset ini. Citra pankromatik SPOT (s_1) dan citra udara SAR (s_2) Muara Sekampung pada 5 Agustus 1987 dan 20 Mei 1988. Citra Landsat TM Saguling pada 04 Juli 1982 (t_1) dan 09 Juli 1994 (t_2).



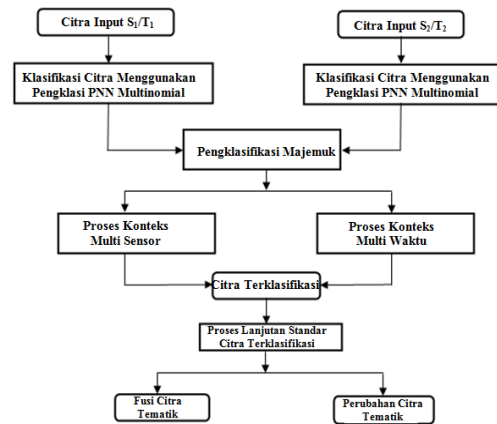
Gambar 1: Daerah Muara Sekampung (a) Citra Pankromatik SPOT tahun 1987; (b) Citra Udara SAR tahun 1988.



Gambar 2: Daerah Saguling (a) Landsat TM tahun 1982; (b) Landsat TM tahun 1994.

(Sumber data : BAKOSURTANAL RI)

Pengklasifikasi majemuk berbasis PNN diturunkan dengan skema yang memuat dua pengklasifikasi PNN untuk dua karakteristik data yang berbeda.



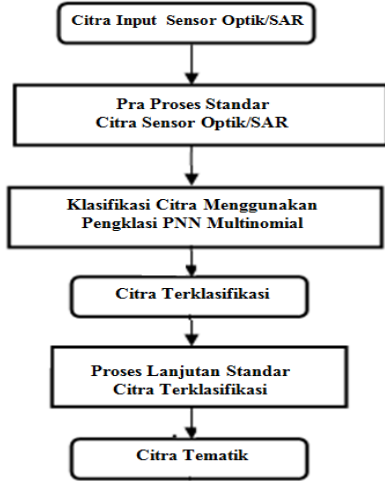
Gambar 3: Skema Pengklasifikasi Majemuk.

2.2 Jaringan Neural Probabilistik (PNN)

Jaringan neural probabilistik (PNN) Model Gaussian dapat menentukan batasan keputusan fenomena nonlinier dengan pendekatan Bayes telah dihasilkan oleh Murni, dkk. [1]. Batasan keputusan dapat diubah secara real-time dengan data baru yang tersedia, dan dapat diimplementasikan menggunakan "neuron" buatan yang beroperasi secara paralel (Murni, dkk.) [1]. Keakuratan keputusan tergantung pada keakuratan estimasi fungsi probabilitas densitas (Probabilistic Decision Function /PDF). Namun perlu hati-hati bahwa PDF secara sederhana merupakan penjumlahan dari distribusi Gaussian dengan multivarian kecil yang terpusat pada setiap sampel. Namun demikian, jumlah tidak membatasi selalu Gaussian. Pada kenyataannya, terdapat fungsi densitas yang smooth. Terdapat kesamaan antara jaringan analog paralel yang mengklasifikasi pola menggunakan estimator nonparametrik dari fungsi probabilitas densitas (PDF) dengan dan jaringan neural panjar-maju apabila menggunakan algoritma pelatihan yang lain. Konsep yang sama dapat diberlakukan untuk pengklasifikasi PNN. Di bawah ini beberapa persamaan untuk model Gaussian dan model Multinomial yang digunakan untuk menghitung fungsi probabilitas densitas untuk setiap kelas objek penutup lahan.

Model Gaussian menggunakan estimator rerata $\hat{\mu}_i$ dan matrik kovarian $\hat{\Sigma}_i$, sementara model multinomial menggunakan estimator matriks $(\hat{p}_{uv}^i)^{x_{uv}}$ untuk objek kelas \hat{i} . Variabel u dan v adalah tingkat keabuan dan x_{uv} adalah jumlah kemunculan ko-okuren dari tingkat keabuan (u, v) . Notasi p_{uv}^i adalah matrik ko-okuren terestimasi untuk kelas \hat{i} . Semua estimator dihitung berdasarkan data pelatihan yang divalidasi

oleh pakar. Sepasang persamaan fungsi probabilitas densitas dan aturan keputusan masing-masing seperti persamaan (1) dan (2) untuk PNN Model Gaussian, sedangkan persamaan (3) dan (4) untuk PNN Model Multinomial. Variabel d pada persamaan (1) menunjukkan dimensi fitur dan k dalam persamaan (4) menunjukkan jumlah acuan yang digunakan dalam perhitungan matrik ko-okuren.



Gambar 4 : Diagram Pengklasifikasi Tunggal.

$$\rho\left(\vec{X} | \omega_i, \vec{\mu}, \Sigma_i\right) = \frac{1}{(2\pi)^{\frac{d}{2}} |\Sigma_i|^{\frac{1}{2}}} \exp(-0.5) \quad (1)$$

$$\left(\left(\vec{X} - \vec{\mu}_i \right)^t \Sigma_i^{-1} \left(\vec{X} - \vec{\mu}_i \right) \right)$$

$$\rho\left(\vec{X} | \omega_i, \hat{\mu}_i, \hat{\Sigma}_j\right) \geq \rho\left(\vec{X} | \omega_j, \hat{\mu}_j, \hat{\Sigma}_j\right) \quad \forall_j \quad (2)$$

$$\frac{\rho(\chi | \omega_i)}{\rho(\chi)} = \pi \left(\frac{\rho^{iuv}}{\rho^{uv}} \right)^{x_{uv}} \quad (3)$$

$$\Pi_k \Pi_{uv} \left(\frac{\hat{\rho}_{uv}}{\rho_{uv}} \right)^{x_{uv}} \geq \Pi_k \Pi_{uv} \left(\frac{\hat{\rho}_{uv}^j}{\rho_{uv}} \right)^{x_{uv}} \quad \forall_j \quad (4)$$

Karena p_{uv} adalah sebuah konstanta, maka persamaan (4) sebagai aturan keputusan *log-likelihood* untuk menyatakan sebuah piksel pada tekstur ω_i jika :

$$\Sigma_k \Sigma_{u,v} x_{uv} \log(\hat{\rho}_{uv}^i) \geq \Sigma_k \Sigma_{u,v} x_{uv} \log(\hat{\rho}_{uv}^j) \quad \forall_j \quad (5)$$

2.3 Metode Optimasi

Metode optimasi menggunakan ekspektasi maksimum (EM) untuk meng memperkirakan fungsi probabilitas densitas (pdf). EM biasanya digunakan untuk menghitung estimasi maksimum likelihood (ML) sampel data yang kurang jelas. Misal distribusi observasi $x \in R^p$ seperti di bawah:

$$f(x | \Theta) = \sum_{i=1}^L \alpha_i f_i(x | \Theta_i) \quad (6)$$

$\alpha_1, \dots, \alpha_L$: prior probabily,

$\Phi = (\alpha_1, \dots, \alpha_L, \phi_1, \dots, \phi_L)$: densitas campuran,

$x = (x_1, \dots, x_n)$: sampel pelatihan,

(ϕ_1, \dots, ϕ_L) : kebergantungan bebas.

E-Step:

$$\tau_{ij}^c = \tau_i(x_j | \Theta_{ij}^c) \frac{\alpha_i^c f_i(x_j | \Theta_{ij}^c)}{\sum_{i=1}^L \alpha_i^c f_i(x_j | \Theta_{ij}^c)} \quad (7)$$

dimana : τ_{ij} adalah probabilitas posterior x_j dari kelas i

M-Step :

$$\alpha_i^+ = \frac{\sum_{j=1}^L \tau_{ij}^c}{n} \quad (8)$$

$$\phi_i^+ \in \arg \max_{\phi_i \in \Omega} \left(\sum_{k=1}^n \tau_{ik} \ln f_i(x_k | \phi_i) \right) \quad (9)$$

Algoritma Pelatihan :

1) Hitung faktor bobot

$$\omega_{ij}^c = \tau_i(x_j | \Theta_{ij}^c) \frac{\alpha_i^c f_i(x_j | \Theta_{ij}^c)}{\sum_{k=1}^L f_i(x_j | \Theta_k^c)} \quad (10)$$

2) Maksimumkan the mixed log likelihood

$$\Theta_i^+ \in \arg \max_{\Theta_i \in \Omega} \left(\sum_{k=1}^n \omega_{ik}^c \ln f_i(x_k | \Theta_i) \right) \quad (11)$$

3) Tentukan klasifikasi berdasarkan ML

$$x \in i \leftrightarrow i \arg \max_{1 \leq i \leq L} \left(\ln f_i(x_k | \Theta_{ij}^+) \right) \quad (12)$$

Secara umum, kebutuhan komputasi untuk EM bisa lebih rumit karena memerlukan integrasi yang kompleks untuk menghitung ekspektasi dan menentukan nilai maksimumnya. Namun pada bagian ini, dapat membatasi untu kasus khusus dari EM dimana cocok untuk distribusi model dari keluarga eksponensial. Perumusan EM yang diberikan di sini sangat cocok untuk bekerja dengan distribusi eksponensial, termasuk distribusi Bernoulli, Poisson, Gamma, Beta, Multinomial, dan Dirichlet.

2.4 Klasifikasi Compound

Dua citra penginderaan jauh multi sumber yang dihasilkan dari sensor optik (s_1) dan SAR (s_2) atau dihasilkan dari waktu t_1 dan t_2 yang merujuk pada wilayah yang sama, dijadikan data pengujian pada penelitian ini. Misal pasangan piksel dari citra multi spektral diambil dari sensor optik (s_1) atau pada waktu t_1 dimana pixel spasial yang bersesuaian diperoleh juga dari sensor SAR (S_2) atau pada waktu t_2 . Piksel tersebut ditunjukkan oleh dimensi vektor fitur masing-masing $d-X_1$ dan $d-X_2$. Misal $\Omega = \{w_1, w_2, \dots, w_n\}$ adalah himpunan kemungkinan kelas dari s_1 (t_1), dan $N = \{v_1,$

v_2, \dots, v_m adalah himpunan kemungkinan kelas dari s_2 (t_2). Sebuah fusi atau perubahan penutup lahan dari pasangan piksel bersifat sinergi atau deteksi perbedaan dari dua kelas w_i dan v_j yang mana piksel akan ditetapkan.

Fusi menggunakan metode pengklasifikasi kombinasi dengan aturan-aturan keputusan sebagai berikut.

1. Aturan keputusan produk :

$$\rho(x_i, \dots, x_R | \omega_k) = \prod_{i=1}^R \rho(x_i | \omega_k) \quad (13)$$

$$\rho(\omega_k | x_i, \dots, x_R) = \frac{\prod_{i=1}^R \rho(x_i | \omega_k)}{\sum_j^c \rho(\omega_j) \prod_{i=1}^R \rho(x_i | \omega_k)} \quad (14)$$

$$\rho(\omega_j) \prod_{i=1}^R \rho(x_i | \omega_j) = \max_{k=1}^c \rho(\omega_k) \prod_{i=1}^R \rho(\bar{x}_i | \omega_k) \quad (15)$$

$$\rho^{-(R-1)}(\omega_j) \prod_{i=1}^R \rho(\bar{\omega}_j | \bar{x}_i) \rho(\bar{x}_i) = \max_{k=1}^c \rho^{-(R-1)}(\omega_k) \prod_{i=1}^R \rho(\bar{\omega}_j | \bar{x}_i) \rho(\bar{x}_i) \quad (16)$$

Untuk aturan keputusan deteksi perubahan penutup lahan dapat menggunakan probabilitas *join* seperti yang diusulkan Bruzzone, dkk. [3] di bawah ini.

$$P(w_i, v_j | X_1, X_2) = \max P(w_i, v_j) \frac{P(w_i | X_1) P(v_j | X_2)}{P(w_i) P(v_j)} \quad (17)$$

2. Aturan keputusan jumlah :

$$(1-R) \rho(\omega_j) + \sum_{i=1}^R \rho(\omega_j | \bar{x}_i) = \max_{k=1}^c \left((1-R) \rho(\omega_k) + \sum_{i=1}^R \rho(\omega_k | \bar{x}_i) \right) \quad (18)$$

3. Aturan keputusan maksimum :

$$\max_{i=1}^R \rho(\omega_j | \bar{x}_i) = \max_{k=1}^c \max_{k=1}^R \rho(\omega_j | \bar{x}_i) \quad (19)$$

4. Aturan memilih mayoritas :

$$\Delta_{ki} = 1 \text{ jika } \rho(\omega_j | \bar{x}_i) = \max_{k=1}^c \rho(\omega_j | \bar{x}_i) \quad (20)$$

$$\Delta_{ki} = 0 \text{ lainnya } \sum_{i=1}^R \Delta_{ij} = \max_{k=1}^c \sum_{i=1}^R \Delta_{ki} \quad (21)$$

Probabilities join $P(w_i, v_j)$ adalah estimasi iteratif pada iterasi ke k dengan algoritma EM seperti persamaan (22)

$$P_{k+1}(w_i, v_j) = \frac{1}{S} \frac{\sum_{q=1}^S \frac{P_k(w_i, v_j) P(w_i | X_1^q) P(v_j | X_2^q)}{\sum_{wn \in \Omega} \sum_{vm \in N} \frac{P_k(w_n, v_m)}{P_k(w_n) P_k(v_m)} P(w_n | X_1^q) P(v_m | X_2^q)}}{\sum_{q=1}^S \frac{P_k(w_i, v_j) P(w_i | X_1^q) P(v_j | X_2^q)}{\sum_{wn \in \Omega} \sum_{vm \in N} \frac{P_k(w_n, v_m)}{P_k(w_n) P_k(v_m)} P(w_n | X_1^q) P(v_m | X_2^q)}} \quad (22)$$

Algoritma ini beriterasi sampai konvergensi dan tercapai apabila maksimum estimasi selisih diantara dua iterasi berurutan berada di bawah sebuah ambang. Tepatnya, kriteria henti didefinisikan oleh persamaan (23) berikut.

$$\max_{w_i, v_j} \left\| P_{k+1}(w_i, v_j) - P_k(w_i, v_j) \right\| < \varepsilon, w_i \in \Omega, v_j \in N \quad (23)$$

dimana $\varepsilon \in [0,1]$.

3. Hasil dan Pembahasan

Ukuran citra yang digunakan adalah 350 x 350 piksel. Fitur sekunder dihasilkan berdasarkan model ko-okuren. Jumlah kelas objek wilayah Muara Sekampung terdiri atas empat kelas meliputi air, pertanian, lahan terbuka, dan hutan basah. Sedangkan jumlah kelas obyek wilayah Saguling terdiri atas lima kelas meliputi air, hutan, pertanian basah, pertanian kering, dan perkampungan. Jumlah sampel per kelas terdiri atas 4500 piksel, 40% (1800 piksel) digunakan untuk pelatihan dan 60% (2700 piksel) digunakan untuk pengujian.

Table 1 : Akurasi Citra Optik Muara Sekampung menggunakan PNN Model Gaussian.

Kelas Objek	Air	Pertanian	Lahan Terbuka	Hutan Basah	Producer's Accuracy - PA (%)
Air	2523	75	87	0	93.97
Pertanian	0	2378	48	110	93.77
Lahan Terbuka	0	70	2388	46	95.37
Hutan Basah	0	0	0	2367	100
User's Accuracy - UA (%)	100	94.25	94.65	93.82	Overall Accuracy - UA=95.68
					PA = 95.78 UA = 95.68

Berdasarkan tabel 1, hutan basah merupakan objek citra optik yang paling sulit dikenali PNN Model Gaussian. Kesalahan paling banyak, objek hutan basah diklasifikasi sebagai pertanian, namun kesalahan terbesar kedua terjadi pada lahan terbuka yang diklasifikasi sebagai air. Hal ini menunjukkan bahwa di samping objek air, daerah pertanian dan terbuka masih belum sempurna didekati dengan model gaussian, sehingga perlu berbagai koreksi tambahan atau membuat praproses lebih optimal. Sedangkan air sudah jelas sebagai objek tepat dengan Model Gaussian.

Table 2 : Akurasi Citra SAR Muara Sekampung menggunakan PNN Model Gaussian.

Kelas Objek	Air	Pertanian	Lahan Terbuka	Hutan Basah	Producer's Accuracy – PA (%)
Air	2317	197	182	7	85.95
Pertanian	0	2255	0	29	98.73
Lahan Terbuka	57	71	2341	94	91.35
Hutan Basah	149	0	0	2393	94.14
User's Accuracy- UA(%)	91.84	89.39	92.79	95.12	Overall Accuracy- UA=92.42
PA = 92.54 UA = 92.29					

Dari tabel 2, daerah pertanian adalah obyek citra SAR yang paling sulit untuk dikenali dengan PNN Model Gaussian. Sebagian besar kesalahan pada klasifikasi terjadi pada daerah pertanian yang dikenali sebagai air, sedangkan kesalahan terbesar kedua terjadi pada lahan terbuka yang dikenali sebagai air. Ini menunjukkan bahwa Model Gaussian kurang tepat untuk klasifikasi citra SAR sekalipun menggunakan PNN.

Tabel 3 menunjukkan bahwa pengenalan obyek citra optik dengan PNN Model Multinomial dapat ditingkatkan dengan menerapkan metode EM. Objek yang paling banyak terjadi kesalahan klasifikasi dengan model ini adalah lahan terbuka yang dikenali air. Metode EM memiliki peran penting dalam meningkatkan kemampuan pengklasifikasi PNN, namun masih belum bisa mengembalikan pengenalan objek air yang mencapai pengenalan maksimal 100% dengan Model Gaussian. Namun EM berhasil menekan kesalahan kelas lahan hutan. Hal ini menunjukkan bahwa EM dapat meningkatkan sensitivitas pengenalan substansi obyek.

Table 3 : Akurasi Citra Optik Muara Sekampung menggunakan PNN Model Gaussian dan EM.

Kelas Objek	Air	Pertanian	Lahan Terbuka	Hutan Basah	Producer's Accuracy – PA (%)
Air	2457	1	101	10	95.62
Pertanian	0	2.61	1	0	99.96
Lahan Terbuka	0	61	2421	70	92.49
Hutan Basah	66	0	0	2443	100
User's Accuracy- UA(%)	97.40	97.56	95.95	96.80	Overall Accuracy- UA=96.93
PA = 96.96 UA = 96.93					

Dari tabel 4, metode EM juga dapat meningkatkan kemampuan PNN Model Gaussian untuk pengenalan citra SAR. Pertanian adalah objek banyak terjadi kesalahan, yang diklasifikasi sebagai air, sedangkan obyek kesalahan terbesar kedua terjadi pada air

diklasifikasi hutan basah. Seperti dalam data tabel sebelumnya, EM juga dapat meningkatkan sensitivitas pengenalan substansi obyek dalam citra SAR.

Table 4 : Akurasi Citra SAR Muara Sekampung menggunakan PNN Model Gaussian dan EM.

Kelas Objek	Air	Pertanian	Lahan Terbuka	Hutan Basah	Producer's Accuracy – PA (%)
Air	2332	186	176	3	86.47
Pertanian	0	2294	0	29	98.75
Lahan Terbuka	49	43	2397	94	92.66
Hutan Basah	142	0	0	2397	94.41
User's Accuracy- UA(%)	92.43	90.92	93.02	95.01	Overall Accuracy- UA=92.96
PA = 93.07 UA = 92.85					

Tabel 5: Akurasi Klasifikasi Citra Optical Muara Sekampung Menggunakan PNN Multinomial.

Kelas Objek	Air	Pertanian	Lahan Terbuka	Hutan Basah	Producer's Accuracy – PA (%)
Air	2463	0	97	0	95.64
Pertanian	0	2455	0	31	99.96
Lahan Terbuka	13	68	2426	0	94.87
Hutan Basah	47	0	0	2492	97.37
User's Accuracy- UA(%)	97.38	97.54	95.96	96.83	Overall Accuracy- UA=97.46
PA = 97.47 UA = 97.46					

Tabel 6 : Akurasi Klasifikasi Citra SAR Muara Sekampung menggunakan PNN Multinomial.

Kelas Objek	Air	Pertanian	Lahan Terbuka	Hutan Basah	Producer's Accuracy – PA (%)
Air	2510	1	1	10	99.52
Pertanian	12	2433	35	0	98.10
Lahan Terbuka	0	35	2472	84	95.41
Hutan Basah	1	54	15	2429	97.20
User's Accuracy- UA(%)	99.48	96.43	97.48	96.27	Overall Accuracy- UA=97.54
PA = 97.56 UA = 97.54					

Dari tabel 5, pengenalan objek citra optik relatif terdistribusi secara merata dengan PNN Model Multinomial. Kesalahan klasifikasi yang paling banyak, terjadi pada hutan basah yang diklasifikasi sebagai lahan terbuka. Berdasarkan data di atas, fenomena yang terjadi dimana air pada citra optik dengan model Gaussian, didistribusikan terklasifikasi sebagai objek

selain lahan terbuka. Hal ini menunjukkan bahwa objek dengan potensi mengandung air ditafsirkan sebagai air. Dari tabel 6, pengenalan objek citra SAR relatif terdistribusi secara carried dengan PNN Model Multinomial. Model ini lebih konsisten untuk kesalahan klasifikasi objek dimana lahan terbuka diklasifikasi sebagai hutan basah. Hal ini menunjukkan bahwa klasifikasi citra SAR lebih optimal dengan Model Multinomial dibanding Model Gaussian.

Tabel 7: Akurasi Klasifikasi Citra Optik Muara Sekampung menggunakan PNN Multinomial EM.

Kelas Objek	Air	Pertanian	Lahan Terbuka	Hutan Basah	Producer's Accuracy – PA (%)
Air	2483	57	52	2	95.72
Pertanian	0	2466	0	40	98.40
Lahan Terbuka	0	0	2471	0	100
Hutan Basah	40	0	0	2481	98.41
User's Accuracy- UA(%)	98.41	97.74	97.94	98.34	Overall Accuracy- UA=98.11
PA = 98.13 UA = 98.11					

Dari tabel 7, perpaduan PNN Multinomial dengan EM dapat meningkatkan pengenalan obyek citra optik sekitar 1%. Pertanian dan lahan terbuka secara berturut-turut dinyatakan sebagai air. Dari data di atas terjadi anomali dengan lahan terbuka yang secara substansial kurang mengandung air, namun hal itu diduga ada ruang –ruang yang mengandung air dan bukan utuh lahan terbuka atau lahan kering.

Tabel 8: Akurasi Klasifikasi Citra SAR Muara Sekampung menggunakan PNN Multinomial dan EM.

Kelas Objek	Air	Pertanian	Lahan Terbuka	Hutan Basah	Producer's Accuracy – PA (%)
Air	2474	52	0	41	96.38
Pertanian	0	2471	47	0	98.13
Lahan Terbuka	0	35	2472	84	95.41
Hutan Basah	49	0	0	2482	98.06
User's Accuracy- UA(%)	98.06	97.94	98.14	98.37	Overall Accuracy- UA=98.13
PA = 98.14 UA = 98.13					

Dari tabel 8, perpaduan PNN multinomial dengan EM dapat meningkatkan akurasi pengenalan objek citra SAR sekitar 1%. Kesalahan klasifikasi pertanian masih sulit sekalipun menggunakan EM, dan diklasifikasi sebagai air. Kehadiran EM diyakini dapat meningkatkan sensitivitas pengklasifikasi pada substansi objek.

Tabel 9 : Akurasi Fusi Citra (Optik dan SAR) Muara Sekampung menggunakan PNN Multinomial dengan Aturan Keputusan Jumlah.

Kelas Objek	Air	Pertanian	Lahan Terbuka	Hutan Basah	Producer's Accuracy – PA (%)
Air	2501	15	31	2	98.12
Pertanian	2	2494	0	24	98.97
Lahan Terbuka	20	14	2488	0	98.65
Hutan Basah	0	0	4	2497	99.84
User's Accuracy- UA(%)	99.13	98.85	98.61	98.97	Overall Accuracy- UA=98.89
PA = 98.89 UA = 98.89					

Dari tabel 9, melalui fusi dari citra optik dan SAR, kemampuan keputusan pengklasifikasi PNN Multinomial dengan aturan jumlah relatif tinggi dibandingkan dengan pengenalan citra tunggal dengan mengadopsi metode EM. Dengan fusi citra relatif dapat menyelesaikan masalah klasifikasi dan dapat menekan kesalahan sampai 1%.

Table 10 : Akurasi Deteksi Perubahan Wilayah Citra Saguling Menggunakan PNN Model Gaussian dengan Keputusan Gabungan.

Kelas Objek	A	B	C	D	E	F
A	2423	76	45	65	22	92.09
B	53	2390	0	0	0	97.83
C	47	57	2393	40	100	90.75
D	0	0	85	2408	0	96.59
E	0	0		10	2400	99.59
User's Accuracy- UA(%)	96.04	94.73	94.85	95.44	95.16	Overall Accuracy- UA=95.31
PA = 95.37 UA = 95.24						

Keterangan;

A = Air

B = Hutan

C = Pertanian kering

D = Pertanian basah

E = Perkampungan


F = Producer's Accuracy – PA (%)

Berdasarkan tabel 10, untuk mendeteksi keputusan perubahan dalam penggunaan lahan dengan parameter join cukup efektif sekalipun dengan pengklasifikasi PNN Gaussian. Perubahan lahan hutan merupakan perubahan dengan akurasi paling dibandingkan perubahan objek yang lain.


Tabel 11 : Akurasi Deteksi Perubahan Citra Saguling menggunakan PNN Multinomial dengan dan Aturan Keputusan Gabungan.

Kelas Objek	A	B	C	D	E	F
A	243 3	66	0	54	12	94.85
B	76	241 9	0	0	0	96.95
C	14	38	249 3	46	91	92.95
D	0	0	30	242 3	0	98.78
E	0	0		0	24 20	100
User's Accuracy- UA(%)	96.4 3	95.8 8	98.8 1	96.0 4	95 .9 2	Overall Accuracy- UA=96.66
PA = 96.71 UA = 96.62						


Dari tabel 11, aturan keputusan gabungan juga meningkat kemampuan deteksi perubahan lahan dengan pengklasifikasi PNN Multinomial dan lebih baik 1% dari Model Gaussian. Tetapi objek hutan merupakan objek yang terdeteksi dengan perubahan terkecil dari objek lain seperti halnya dengan Model Gaussian dan hampir sama untuk objek perkampungan. Hal ini menimbulkan asumsi bahwa substansi hutan dan perkampungan mengandung substansi objek-objek lain.




Gambar 5: Peta Tematik Paling Baru dari Citra Terklasifikasi dengan Menggunakan Pengklasifikasi Uniform, (a) Citra Pankromatik SPOT (b) Citra Udara SAR.



Gambar 5. Fusi citra menggunakan pengklasifikasi uniform, (a) Citra Optik dari Pankromatik SPOT (b) Citra SAR dari Foto Udara (c) Hasil Fusi Citra.



Gambar 6 : Citra Perubahan dengan Pengklasifikasi Uniform, (a) Peta Tematik Awal; (b) Citra Fusi Terklasifikasi; (c) Hasil Citra Perubahan.



Gambar 7: Citra Tematik, (a) Citra Optik Teluk Belatung, (b) Citra SAR Teluk Belatung (c) Fusion Citra Optik Teluk Belatung.

Data citra multi sensor seperti ditunjukkan pada gambar 5, digunakan untuk melengkapi dan meningkatkan kemampuan interpretasi pengklasifikasi fusi data melalui penggabungan data tersebut. Model pengklasifikasi yang dikembangkan, dapat digunakan untuk interpretasi perubahan penutup lahan dengan akurasi yang cukup tinggi jika kita memiliki data citra multi waktu seperti ditunjukkan pada gambar 6, dan 7.

Kemampuan pengklasifikasi juga ditentukan oleh kualitas data yang digunakan. Dalam penelitian ini tidak dilakukan praproses data dengan asumsi bahwa data yang digunakan telah memiliki kualitas yang baik berdasarkan penelitian sebelumnya. Namun, berdasarkan beberapa fenomena yang terjadi, kedepan perlu dilakukan praproses yang lebih khusus dengan metode yang ada kaitannya dengan model yang digunakan. Untuk mendapatkan data dengan kualitas baik, diperlukan metode yang lebih efektif praproses termasuk metode filter gangguan, terutama citra optik yang mendapat gangguan awan. Bahkan, adalah mungkin untuk citra SAR yang diasumsikan bebas dari gangguan awan, memiliki gangguan lain.

4. Kesimpulan

Penelitian ini mengusulkan sebuah metodologi interpretasi untuk klasifikasi citra multi waktu- multi sensor berbasis pada Pengklasifikasi PNN Model Multinomial Uniform. Kontribusi yang inovatif dari penelitian ini adalah bahwa PNN Model Multinomial dapat bekerja sebagai pengklasifikasi uniform untuk data sensor SAR dan sensor optik. Beberapa kesimpulan dapat disampaikan secara ringkas sebagai berikut:

1. Kinerja pengklasifikasi PNN Model Multinomial dibandingkan dengan model konvensional PNN Model Gaussian menunjukkan akurasi klasifikasi dan memiliki kapabilitas generalisasi yang lebih baik.
2. Aplikasi dari pengklasifikasi yang diusulkan untuk citra SAR juga menunjukkan hasil yang lebih baik dibandingkan dengan pengklasifikasi dengan pendekatan statistik.
3. Tidak ada perbedaan waktu komputasi yang signifikan dengan Model Gaussian sekalipun Model Multinomial memiliki tambahan proses komputasi.
4. Model multinomial menerapkan dalam fusi dan deteksi perubahan wilayah penutup lahan, menunjukkan hasil yang optimal dibandingkan dengan pendekatan yang lain.

5. Ucapan Terima Kasih

Penelitian ini merupakan program riset unggulan universitas dan dilakukan dengan bantuan dan kerjasama dengan dari sejumlah pihak. Untuk itu kami ucapkan terima kasih kepada Pimpinan Universitas Pendidikan Indonesia, Ketua Lembaga Penelitian dan Pengabdian Masyarakat UPI, Dekan Fakultas Pendidikan Matematika dan Ilmu Pengetahuan Alam UPI, Ketua Laboratorium Kecerdasan Komputasi dan Pengolahan Citra Ilmu Komputer UPI. Secara khusus terima kasih kepada Prof Aniati Murni dari Universitas Indonesia, dan Dr. Ketut Wikantika dari Institut Teknologi Bandung. Harapan kami semoga hasil riset ini dapat memberikan kontribusi positif dalam upaya mengoptimalkan pembangunan Indonesia.

6. Daftar Pustaka

- [1]. Murni, A., A.K. Jain, and J. Rais, *A Framework for Multidate Multisensor Image Interpretation*, Proceedings of IEEE International Geoscience and Remote Sensing Symposium (IGARSS'96), Lincoln, Nebraska, pp. 1851-1854, 1996.
- [2]. Murni A., W. Setiawan, and D. Hadianto, *Evaluation of Several Classification Methods for Land Cover Development Constrain Parameters*, Proceeding World Multiconference on Systemic, Cybernetics and Information, ISBN: 980-07-6688-X, Volume II, pp. 228-232, Orlando, Florida, USA, 2000.
- [3]. Bruzzone L., D.F. Prieto, and S.B. Serpico, *A Neural-Statistical Approach to Multitemporal and Multisource Remote Sensing Image Classification*, IEEE Transaction on Geoscience and Remote Sensing, Vol.37, pp. 1350-1358, May 1999.
- [4]. Benediktsson JB., P.H. Swain, and O.K. Ersoy, *Neural Network Approaches Versus Statistical Methods in Classification of Multisource Remote Sensing Data*, IEEE Transactions on Geoscience and Remote Sensing, 28(4): 540-551, July 1990.
- [5]. Lohmann G., *Co-occurrence-based Analysis and Synthesis of Textures*, Proc. 12th Int. Conference on Pattern Recognition, Jerusalem, pp. 449-453, October 1994.
- [6]. Murni A., F.R. Rohmah, and D. Chahyati, *A Framework for Cloud Cover Removal in Optical Remote Sensing Images*, Proc. World Multiconference on Systemics, Cybernetics and Informatics, Volume V: Image, Acoustic, Speech and Signal Processing; Part I, Orlando, pages 229-234, July 23-26, 2000.
- [7]. Setiawan W., A. Murni, and B. Kusumoputro, *Multitemporal Optical-Sensor Image Classification Based on A Cascade of Neural Network, EM Algorithm and Compound Classifier*, Proceeding The 2002 International Conference On Opto-Electronic and Laser Applications ISBN : 979-8575-03-2 pp. C48-C53, Program Opto-Elektroteknik and Laser Application, Universitas Indonesia, Jakarta, 2002.
- [8]. Setiawan W., A. Murni, and B. Kusumoputro, *Probabilistic Neural Network Based On Multinomial Model For Remote Sensing Image Classification*, International Conference On Computer, Communication and Control Technologies CCCT'03, The 9th International Conference on Information Systems Analysis and Synthesis ISAS'03, Volume V ISBN : 980-6560-05-1. pp. 132-136, Orlando, Florida, USA, 2003.
- [9]. Swain PH., *Bayesian Classification in a Time-Varying Environment*, IEEE Transactions on Systems, Man, and Cybernetics, SMC-8 (12):879-883, December 1978.