

Bab 7

Fusi Data Dan Deteksi Perubahan

7.1 Fusi Data

Fusi data dua sumber citra melalui klasifikasi bergantung pada pengklasifikasi dan keputusan fusi. Berdasarkan fusi data yang telah dilakukan para peneliti sebelumnya, disertasi ini menggunakan gabungan pengklasifikasi *PNN Multinomial optimal* masing-masing untuk menghasilkan probabilitas *posterior* untuk fusi data dengan kaidah keputusan fusi. Berdasarkan uji coba pada kaidah keputusan Huber (2000), kaidah keputusan jumlah merupakan keputusan yang paling optimal dan hasilnya mencapai diatas 95%.

Kaidah keputusan jumlah diturunkan dari metode Bayes sebagai berikut [19]:

$$p(\omega_k | x_i, \dots, x_R) = \frac{p(x_i, \dots, x_R | \omega_k) p(\omega_k)}{p(x_i, \dots, x_R)} \dots\dots\dots (6.1)$$

$$p(x_i, \dots, x_R) = \sum_{j=1}^c p(x_i, \dots, x_R | \omega_j) p(\omega_j) \dots\dots\dots (6.2)$$

$$p(x_i, \dots, x_R | \omega_k) = \sum_{j=1}^R p(x_j | \omega_k) \dots\dots\dots (6.3)$$

$$p(\omega_k / x_i, \dots, x_R) = \frac{\sum_{j=1}^R p(x_i / \omega_k) p(\omega_k)}{\sum_{j=1}^c p(x_i, \dots, x_R / \omega_j) p(\omega_j)} \dots\dots (6.5)$$

$$p(\omega_k / x_i, \dots, x_R) = \frac{p(\omega_k) + \sum_{j=1}^R p(x_i / \omega_k)}{p(\omega_j) + \sum_{j=1}^c p(x_i, \dots, x_R / \omega_j)} \dots\dots (6.6)$$

Dengan aturan keputusan :

$$P(\omega_j / x_i, \dots, x_R) = \max_k P(\omega_k / x_i, \dots, x_R) \dots\dots (6.7)$$

maka :

$$p(\omega_j) + \sum_{i=1}^R p(x_i / \omega_j) = \max_{k=1}^C \left(p(\omega_k) + \sum_{i=1}^R p(x_i / \omega_k) \right) \dots\dots (6.40)$$

Dalam probabilitas *posterior* persamaan keputusan jumlah menjadi dirumuskan sebagai berikut :

$$(1-R)p(\omega_j) + \sum_{i=1}^R p(\omega_j / x_i) = \max_{k=1}^C \left((1-R)p(\omega_k) + \sum_{i=1}^R p(\omega_k / x_i) \right) \dots (6.8)$$

Keterangan :

R : jumlah pengklasifikasi

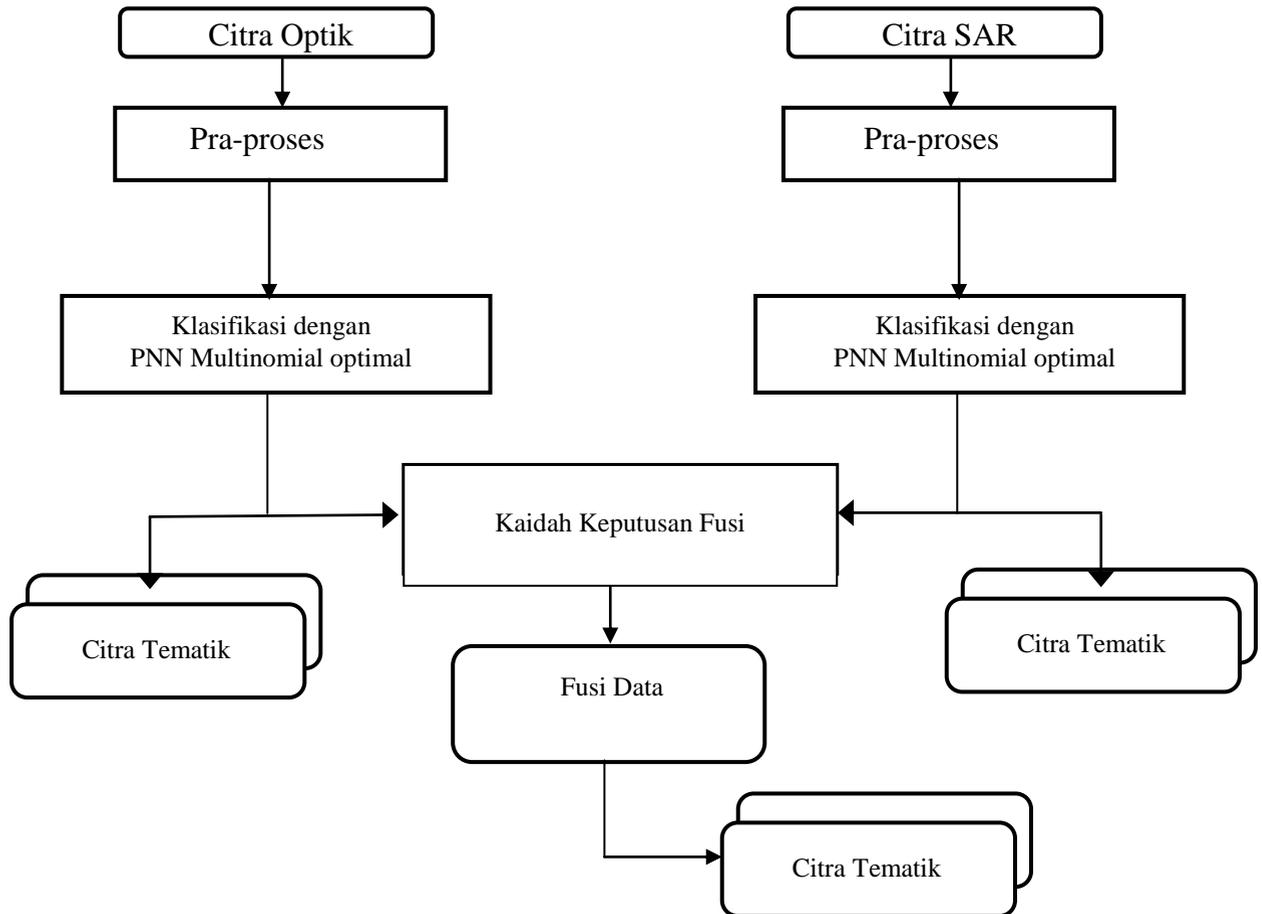
C : jumlah kelas obyek

$p(\omega)$: probabilitas prior

$p(\omega/x)$: probabilitas posterior

Kaidah keputusan jumlah dapat menjadi alternatif yang optimal untuk menggabungkan informasi dari sumber yang berbeda, dan dalam konteks ini penjumlahan merupakan representasi yang baik untuk sebuah penggabungan. Sifat penjumlahan melakukan pembauran yang seragam sehingga informasi dari masing-masing sumber dapat dipertahankan dan saling melengkapi. Skema fusi data dengan keputusan jumlah dibandingkan dengan skema fusi data menggunakan kaidah keputusan berdasarkan probabilitas *joint* dari Swain dkk. (1978) dan hasilnya pada kasus ini kaidah jumlah lebih tinggi.

Skema fusi data ditunjukkan ditunjukkan seperti gambar berikut :



Gambar-7.1 : Skema Fusi Data Alternatif

7.2 Deteksi Perubahan Wilayah

Metode deteksi perubahan wilayah konvensional merupakan pencocokan hasil dari dua pengklasifikasi tunggal. Metode seperti itu memerlukan kondisi yang persis sama dan studi lapangan untuk data terbarunya namun dalam prakteknya kondisi seperti itu sulit didapatkan dan mahal. Metode tersebut

mencocokkan hasil setiap pengklasifikasi, jika tema kelas sama maka dinyatakan tidak terjadi perubahan dan jika tidak sama maka terjadi perubahan wilayah. Metode yang diusulkan oleh Benediktsson dkk. (1989) tidak memasukkan parameter temporal, Schistad Solberg dkk. (1994) memasukkan informasi temporal dengan tambahan faktor penalti [1, 26]. Swain dkk. (1978) membangun metode fusi data untuk *multitemporal* tetapi untuk *singlesensor*. Pada metode Schistad dan Swain menggunakan probabilitas transisi $p(\omega_i/v_k)$. Murni dkk. (1996) telah mencoba menggunakan probabilitas transisi untuk menyatakan berubah dan tak berubah maka tidak menghitung probabilitas transisi aktual [25]. Sebagai contoh, jika beda waktu diantara dua waktu pengambilan data kurang lebih satu tahun, dianggap bahwa probabilitas transisi dari sebuah piksel sama dengan 0.75 dan probabilitas transisi dari sebuah piksel berubah adalah 0.25 tergantung pengetahuan tentang data tersebut, atau dapat juga menghitung probability transisi berubah dan tak berubah aktual menggunakan pengklasifikasi tersendiri.

Metode Bruzzone dkk. (1999) menggunakan pengklasifikasi *uniform* dengan pendekatan *Back Propagation* (BP) [5]. Pada penelitian tersebut telah dicoba menggunakan probabilitas *joint* $p(\omega_i, v_j)$ dengan menghitungnya secara aktual dengan *algoritme Expectation Maximization* (EM) dengan rentang nilai 0-1. Pada penelitian ini digunakan dua pengklasifikasi *PNN multinomial optimal* yang dilatih secara independen dan digunakan untuk mengestimasi probabilitas *posterior* kelas $P(\omega_i/X_1)$ dan $P(v_j/X_2)$. Nilai aktual dari probabilitas *joint* untuk himpunan pengujian dan estimasi probabilitas diperoleh pada iterasi terakhir dari *algoritme* EM.

Deteksi perubahan wilayah diterapkan untuk citra *multitemporal* dengan menggunakan parameter probabilitas *joint* $P(\omega_i, v_j|x_1, x_2)$ untuk kategori obyek ω_i dan v_j . Pada citra *multitemporal* ada kemungkinan untuk posisi piksel yang sama namun tema kelas obyeknya berbeda antara waktu rekaman t_1 dan t_2 , misal hutan

pada suatu saat t_1 berubah menjadi daerah perkebunan atau daerah pertanian pada waktu t_2 karena itu dipilih nilai $P(\omega_i, v_j | x_1, x_2)$ yang terbesar. Bila $i \neq j$, maka terjadi perubahan wilayah obyek penutup lahan dan dicatat sebagai obyek baru, serta sebaliknya bila $\omega_i = v_j$ berarti tidak ada perubahan pada lokasi bersangkutan. Kaidah Keputusan dengan probabilitas *joint prior* didasarkan pada perumusan sebagai berikut [5]:

$$p(\omega_i, v_j | X_1, X_2) = p(X_1, X_2 | \omega_i, v_j) p(\omega_i, v_j) \dots\dots\dots (7.9)$$

$$p(\omega_i, v_j | X_1, X_2) = p(X_1 | \omega_i) p(X_2 | v_j) p(\omega_i, v_j) \dots\dots\dots (7.10)$$

$$p(\omega_i, v_j | X_1, X_2) = \frac{p(\omega_i | X_1) p(v_j | X_2)}{p(\omega_i) p(v_j)} p(\omega_i, v_j) \dots\dots\dots (7.11)$$

$$p(\omega_i, v_j | X_1, X_2) = \frac{p(\omega_i, v_j)}{p(\omega_i) p(v_j)} p(\omega_i | X_1) p(v_j | X_2) \dots\dots\dots (7.12)$$

Deteksi perubahan wilayah dinyatakan dengan persamaan dirumuskan sebagai berikut :

$$\max_{\omega_i, v_j} \left\{ \frac{P(\omega_i | X_1) P(v_j | X_2) P(\omega_i, v_j)}{P(\omega_i) P(v_j)} \right\} \dots\dots\dots(7.13)$$

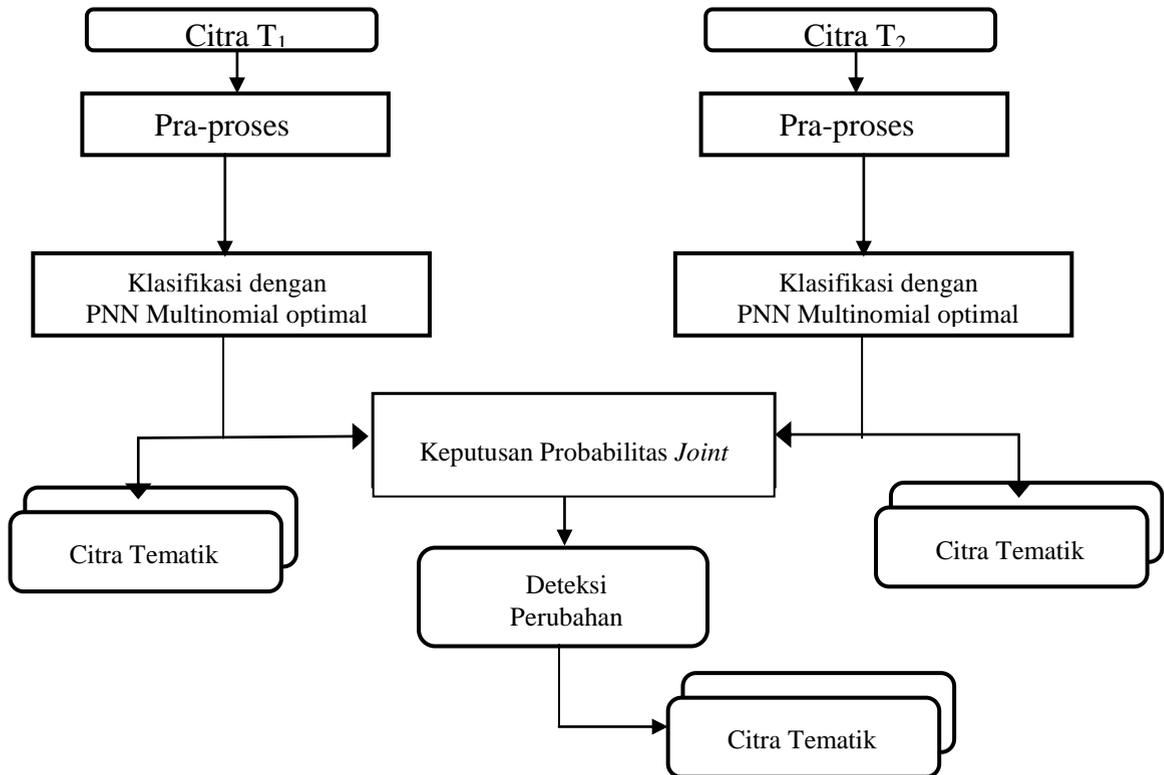
Posterior probabilitas $P(\omega_i | X_1)$ dan $P(v_j | X_2)$ diestimasi dengan pengklasifikasi PNN *multinomial* Optimal, sedangkan probabilitas *joint prior* $P(\omega_i, v_j)$ diestimasi

menggunakan metode iteratif algoritme *Expectation Maximization* (EM) pada Bab 2, dan perubahan wilayah terjadi apabila $i \neq j$.

Kerangka penelitian yang dikembangkan mengacu pada penelitian terdahulu dari para peneliti sebelumnya. Dari hasil penelitian Schistad (1997) dan Murni (1997) dengan pendekatan statistik, pada metodologi tersebut ditemui masalah untuk klasifikasi citra *Synthetic Aperture Radar* (SAR) sehingga akurasi sekitar 70% [25, 26]. Hasil penelitian Benediktsson (1990) dan Bruzzone (1999) membuktikan bahwa pendekatan *Neural Network* (NN) dapat memperbaiki pendekatan statistik terutama untuk *Synthetic Aperture Radar* (SAR) sehingga akurasi meningkat sampai sekitar 85% [2, 4]. Donald (1991) mengembangkan metodologi *Probabilistic Neural Network* (PNN) dan Bruzzone (1997) membandingkan kinerja dengan *Back Propagation Neural Network* (BPNN) yang memiliki masalah dengan waktu komputasi terutama waktu pelatihan. PNN pada dasarnya dapat menutupi kelemahan BPNN [9]. PNN Donald (1991) memiliki masalah juga untuk citra SAR karena menggunakan model Gaussian. Murni (1997) menunjukkan bahwa citra optik dan SAR mengandung bagian yang homogen dan tekstur [26]. Lohman (1994) telah membuktikan bahwa *model multinomial* berhasil untuk sintesa citra optik dan SAR [21]. Jacksson (2001) berhasil menggunakan algoritme *Expectation Maximization* (EM) untuk mengoptimalkan pengklasifikasi [17]. Didasarkan pada beberapa penelitian di atas, dalam disertasi ini diusulkan pengklasifikasi *Probabilistic Neural Network* (PNN) *model multinomial* yang dioptimalkan dengan algoritme *Expectation Maximization* (EM).

Skema deteksi perubahan wilayah ditunjukkan seperti gambar berikut :

7.3 Model Kerangka Klasifikasi



Gambar-7.2 : Skema Deteksi Perubahan Wilayah

Dalam konteks fusi data dan deteksi perubahan wilayah, Swain (1978) mengusulkan penggunaan *cascade classifier* untuk mendeteksi perubahan wilayah berdasarkan data multi temporal [28]. Benediktsson (1989) mengusulkan penggunaan konsep *joint probability* untuk aturan keputusan berdasarkan data multisumber [1]. Schistad (1997) menggunakan konsep *joint probability* untuk aturan keputusan pengklasifikasi berdasarkan tekstur untuk SAR dan pengklasifikasi statistik untuk optik [26]. Murni (1997) mengusulkan *uniform classifier* berdasarkan konsep *multiple classifier* (Ho. dkk.: 1994) untuk aturan keputusan berdasarkan SAR dan optik [25]. Bruzzone (1999) mengusulkan *uniform classifier* berdasarkan BP dan menggunakan *cascade classifier* untuk deteksi perubahan wilayah [5]. Huber (2000) membahas pendekatan untuk fusi data dengan beberapa alternatif kaidah keputusan [16]. Selanjutnya dalam disertasi ini diusulkan skema fusi data menggunakan pengklasifikasi *Probabilistic Neural Network (PNN) multinomial optimal* dengan keputusan fusi data menggunakan kaidah dari Huber (2000). Sedangkan skema deteksi perubahan wilayah menggunakan keputusan joint dari Bruzzone (1999).

7.4 Kinerja Pengklasifikasi

Hasil klasifikasi biasanya ditunjukkan dengan *sebuah matrik* $c \times c$ dimana c menunjukkan kelas ketegori, elemen N_{ij} adalah piksel kelas j yang diklasifikasi sebagai kelas i . Bentuk matrik tersebut ditunjukkan seperti di bawah ini:

$$\begin{array}{cccc} N_{11} & N_{12} & \dots & N_{1j} \\ N_{21} & N_{22} & \dots & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ N_{i1} & \dots & \dots & N_{ij} \end{array}$$

Elemen diagonal matrik merupakan kategori klasifikasi yang benar. Kelas yang salah klasifikasi dinyatakan oleh elemen dengan $i \neq j$. Ukuran kinerja pengklasifikasi dapat dinyatakan dengan tingkat akurasi meliputi : *producer's accuracy* (PA), *user's accuracy* (UA), dan *overall accuracy* (OA), tingkat komputasi, tingkat generalisasi, dan tingkat signifikansi [8].

Producer's Accuracy (PA) merupakan perbandingan kategori obyek yang benar terhadap jumlah kategori obyek yang terjadi.

$$PA = \frac{N_{ii}}{\sum_j N_{ij}} \times 100\%$$

Keterangan :

N_{ii} : kategori obyek yang benar

$\sum_j N_{ij}$: kategori obyek yang terjadi

PA menunjukkan kemampuan pengklasifikasi untuk memetakan piksel pada kelas yang sebenarnya dari seluruh kategori obyek yang terjadi pada kelas tersebut.

User's Accuracy (UA) merupakan perbandingan kategori obyek yang benar terhadap jumlah kategori obyek seharusnya.

$$UA = \frac{N_{jj}}{\sum_i N_{ij}} \times 100\%$$

Keterangan :

N_{jj} : kategori obyek yang benar

$\sum_i N_{ij}$: kategori obyek seharusnya

UA menunjukkan kemampuan pengklasifikasi untuk memetakan piksel pada kelas yang sebenarnya dari seluruh kategori obyek yang seharusnya.

Overall Accuracy (OA) merupakan perbandingan seluruh kategori obyek yang benar terhadap seluruh kategori obyek yang ada.

$$OA = \frac{\sum_i N_{ii}}{\sum_{ij} N_{ij}} \times 100\%$$

Keterangan :

$\sum_i N_{ii}$: jumlah kategori obyek yang benar

$\sum_{ij} N_{ij}$: jumlah seluruh kategori obyek

OA menunjukkan kemampuan pengklasifikasi untuk memetakan piksel pada kelas yang sebenarnya dari seluruh kategori obyek dari kelas yang ada. OA didefinisikan sebagai kemampuan umum suatu pengklasifikasi.

Pengklasifikasi yang baik juga dapat di perhatikan melalui tingkat generalisasinya yaitu kemampuan pengklasifikasi yang stabil untuk setiap kelas. Generalisasi pengklasifikasi ditunjukkan oleh *norm selisih producer's accuracy* (PA) dengan *user's accuracy* (UA). $|\Delta_{PA-UA}|$ Semakin kecil $|\Delta_{PA-UA}|$ suatu pengklasifikasi maka memiliki generalisasi yang semakin baik dan sebaliknya.

Kemampuan pengklasifikasi menyelesaikan tugasnya dapat dijadikan pertimbangan untuk memilihnya. Tingkat komputasi yang baik merupakan seberapa cepat pengklasifikasi menyelesaikan tugasnya. Semakin cepat pengklasifikasi mengeksekusi tugasnya dengan tingkat klasifikasi yang besar maka semakin baik dan sebaliknya. Sedangkan tingkat kepercayaan hasil klasifikasi dapat di ukur

melalui parameter chi-square (χ^2). Jika $\chi^2_{hitung} > \chi^2_{tabel}$ maka hasil klasifikasi signifikan pada derajat kebebasan tertentu [8].

$$\chi^2_{hitung} = \sum_{i=1}^k \frac{(fo - fe)^2}{fe}$$

Keterangan :

fo : frekuensi yang terjadi (kelas yang dikenali)

fe : frekuensi ekspektasi (kelas pelatihan)

k : jumlah kelas

7.5 Contoh Eksperimen

Eksperimen-5 untuk melihat kinerja PNN multinomial pada skema fusi data dan deteksi perubahan wilayah. Skema fusi data dan deteksi perubahan wilayah yang diusulkan, dibandingkan dengan skema Benediktsson, Solberg, dan Murni.

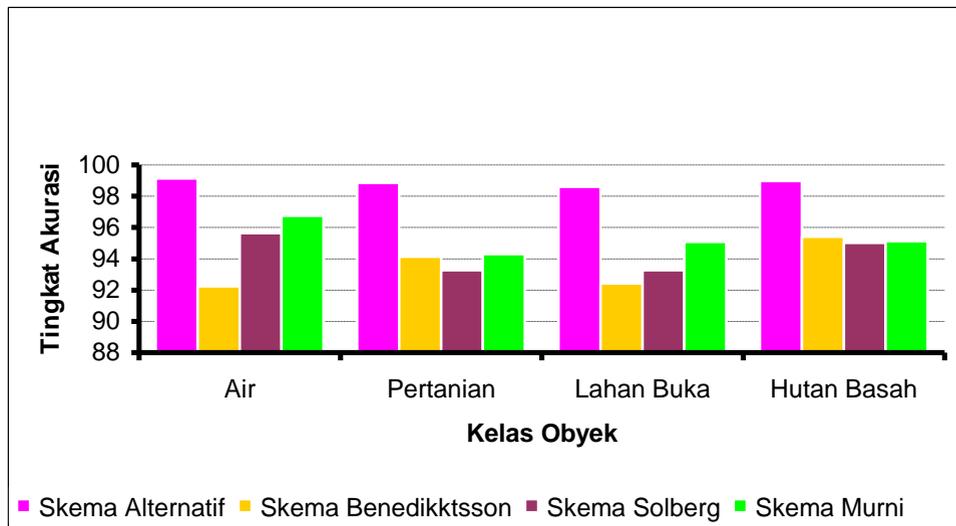
7.5.1 Fusi Data

Dua pengklasifikasi *PNN multinomial optimal* dilatih secara *independent* untuk mengestimasi probabilitas posterior kelas $P(w_i/X_1)$ dan $P(v_j/X_2)$. Fusi data dilakukan dengan kaidah keputusan fusi data dan kaidah penjumlahan paling baik dan representatif untuk mengimplementasikan sifat-sifat komplementer (jumlah). Secara umum skema yang diusulkan dapat menjadi alternatif dalam pengolahan citra penginderaan jauh, hal ini dapat diamati dari kecenderungan yang stabil untuk konteks multisumber. Berikut ini perbandingan fusi data skema yang diusulkan, Benediktsson, Schistad Solberg, dan Murni.

Tabel-7.1 dan Gambar-7.3 menunjukkan tingkat akurasi fusi data multisensor Citra Muara Sekampung.

Tabel-7.1 : Tingkat Akurasi Fusi Data Multisensor Citra Muara Sekampung

	Air	Pertanian	Lahan Buka	Hutan Basah	Rata-Rata
Skema Alternatif	99.13	98.85	98.61	98.97	98.89
Skema Benediktsson	92.23	94.13	92.43	96.40	93.55
Skema Solberg	96.64	93.26	93.26	96.01	94.29
Skema Murni	96.75	94.29	96.09	96.12	96.31



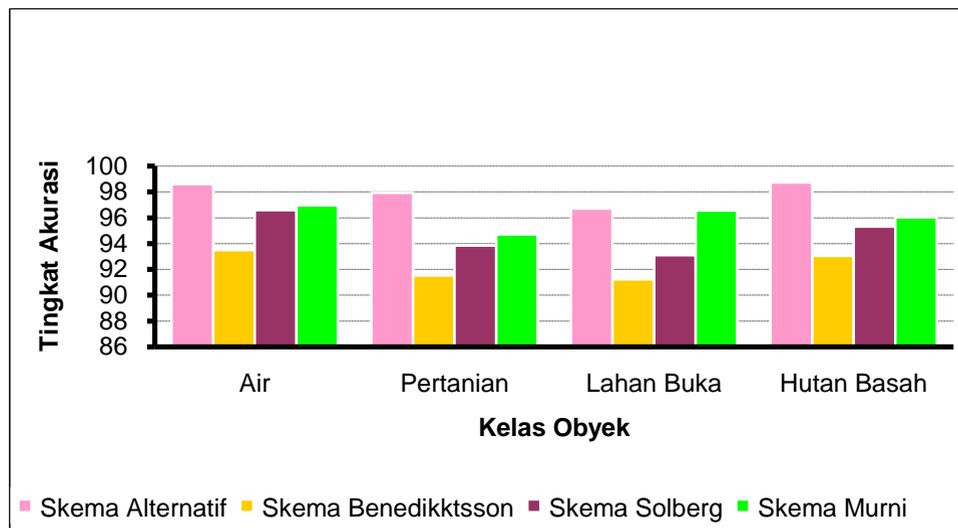
Gambar-7.3 : Tingkat Akurasi Fusi Data Multisensor Citra Muara Sekampung

Hutan basah merupakan kelas obyek dengan tingkat akurasi yang relative sama oleh skema Benediktsson, Solberg, dan Murni. Sedangkan obyek air dan lahan buka relative rendah dengan skema Benediktsson. Pada kasus tersebut skema alternatif paling memberikan tingkat akurasi paling besar.

Tabel-7.2 dan Gambar-7.4 menunjukkan tingkat akurasi fusi data multisensor Citra Teluk Belatung.

Tabel-7.2 : Tingkat Akurasi Fusi Data Multisensor Citra Teluk Belatung

	Air	Pertanian	Lahan Buka	Hutan Basah	Rata-Rata
Skema Alternatif	98.61	97.94	96.71	98.73	98.00
Skema Benediktsson	93.50	91.52	91.24	93.06	92.33
Skema Solberg	96.59	93.86	93.10	96.32	94.72
Skema Murni	96.95	94.73	96.55	96.04	96.07



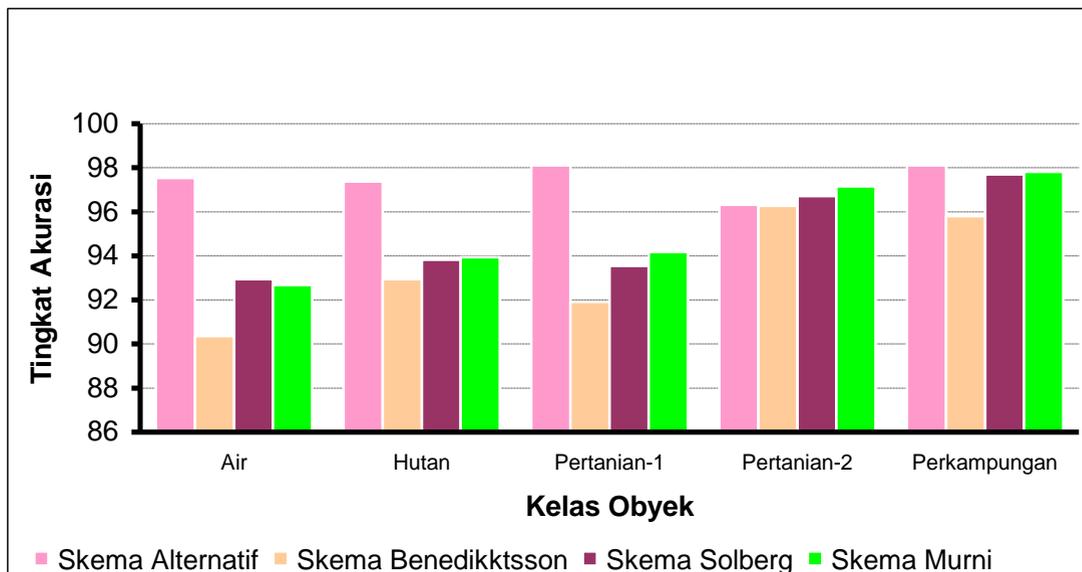
Gambar-7.4 : Tingkat Akurasi Fusi Data Multisensor Citra Teluk Belatung

Pada kasus multisensor Teluk Belatung, tingkat akurasi fusi data kelas pertanian dan lahan buka relative rendah pada semua skema.

Tabel-7.3 dan Gambar-7.5 menunjukkan tingkat akurasi fusi data multiband Citra Saguling.

Tabel -7.3: Tingkat Akurasi Fusi Data Multiband Citra Saguling (2 band)

	Air	Hutan	Pertanian-1	Pertanian-2	Perkampungan	Rata-Rata
Skema Alternatif	97.54	97.38	98.10	96.31	98.1	97.49
Skema Benediktsson	90.36	92.94	91.91	96.27	96.8	93.46
Skema Solberg	92.94	93.82	93.54	96.71	97.7	94.94
Skema Murni	92.67	93.94	94.17	97.15	97.82	96.15



Gambar-7.5: Tingkat Akurasi Fusi Data Multiband Citra Saguling

Pada kasus fusi data multiband Citra Saguling, ke empat skema relative berkemampuan seragam untuk kelas obyek Pertanian-1, dan Perkampungan, dan kelas obyek air relatif paling rendah terutama dengan skema Benediktsson.

Tabel-7.4 dan Gambar-7.6 menunjukkan perbandingan tingkat akurasi fusi data multiband Citra Saguling pada jumlah band yang berbeda.

Tabel-7.4 : Tingkat Akurasi Fusi Data Multiband Citra Saguling

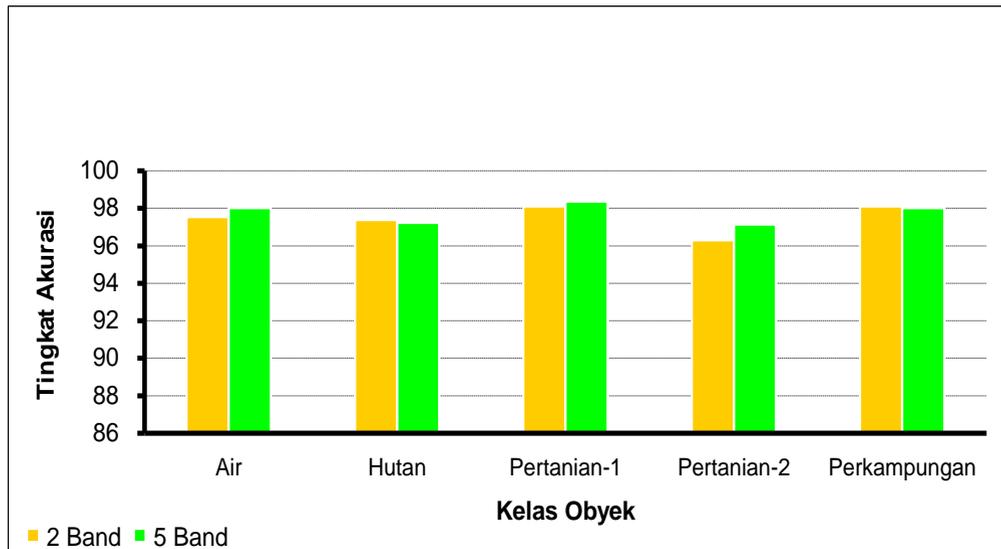
	Air	Hutan	Pertanian-1	Pertanian-2	Perkampungan	Rata-Rata
2 band	97.54	97.38	98.10	96.31	98.10	97.49
5 band	98.02	97.23	98.37	97.15	98.02	97.76
Selisih	+0.48	-0.15	+0.27	+0.84	-0.08	+0.27

Keterangan :

Selisih = Tingkat Akurasi (5 band – 2 band)

- : *turun*

+ : *naik*



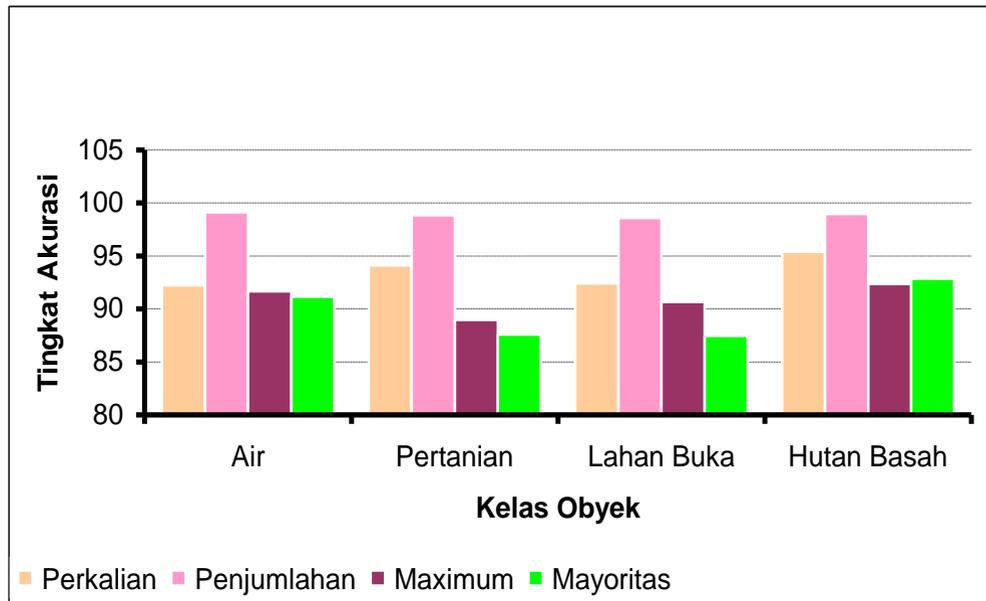
Gambar-7.6 : Tingkat Akurasi Fusi Data Multiband Citra Saguling

Pada dasarnya lebih banyak band dalam konteks multiband memberikan hasil yang lebih besar. Hal ini dapat dipahami bahwa kelengkapan informasi dari sejumlah band memberi kontribusi, namun demikian berdasarkan beberapa referensi dapat ditemukan jumlah band optimal.

Tabel-7.5 dan Gambar-7.7 menunjukkan perbandingan tingkat akurasi fusi data multisensor Citra Muara Sekampung pada berbagai kaidah keputusan.

Tabel-7.5 : Tingkat Akurasi Fusi Data Multisensor Citra Muara Sekampung

Kaidah	Air	Pertanian	Lahan Buka	Hutan Basah	Rata-Rata
Perkalian	92.23	94.13	92.43	96.4	93.55
Penjumlahan	99.13	98.85	98.61	98.97	98.89
Maximum	91.68	88.98	90.65	92.35	90.92
Mayoritas	91.16	87.59	87.48	92.87	89.78

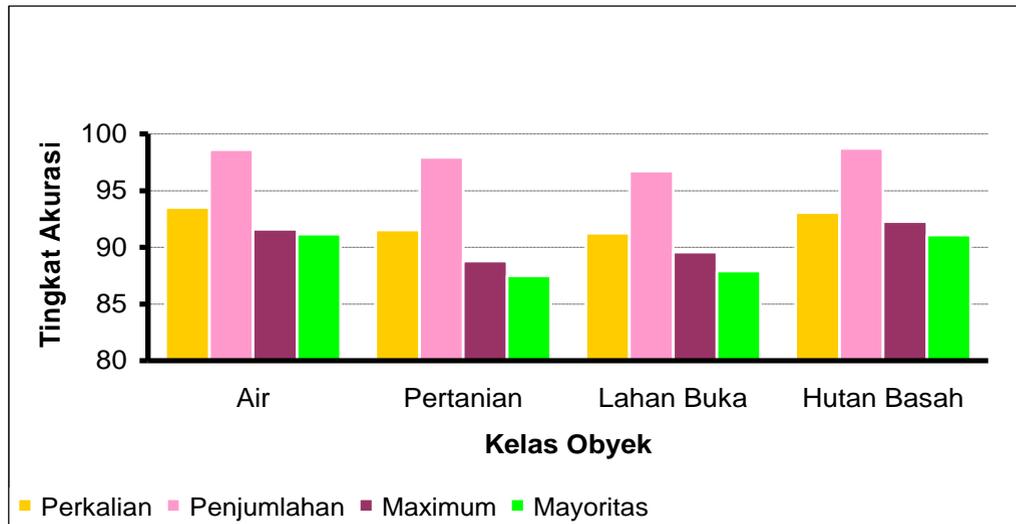


Gambar-7.7 : Tingkat Akurasi Fusi Data Multisensor Citra Muara Sekampung

Tabel-7.6 dan Gambar-7.8 menunjukkan perbandingan tingkat akurasi fusi data multisensor Citra Teluk Belatung pada berbagai kaidah keputusan.

Tabel-7.6 : Tingkat Akurasi Fusi Data Multisensor Citra Teluk Belatung

Kaidah	Air	Pertanian	Lahan Buka	Hutan Basah	Rata-Rata
Perkalian	93.5	91.52	91.24	93.06	92.33
Penjumlahan	98.61	97.94	96.71	98.73	98.00
Maximum	91.6	88.78	89.58	92.27	90.56
Mayoritas	91.17	87.48	87.91	91.08	89.41



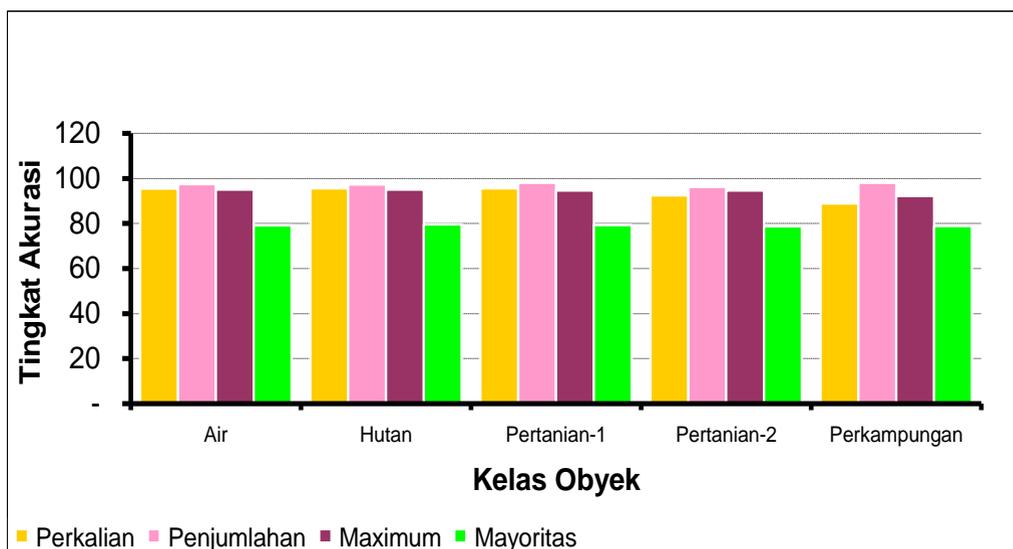
Gambar-7.8 : Tingkat Akurasi Fusi Data Multisensor Citra Teluk Belatung

Pada konteks multisensor, kaidah keputusan penjumlahan menunjukkan hasil lebih baik dari kaidah lainnya. Hal ini disebabkan bahwa kaidah keputusan jumlah memiliki tingkat estimasi error yang rendah [17].

Tabel-7.7 dan Gambar-7.9 menunjukkan perbandingan tingkat akurasi fusi data multiband Citra Saguling pada berbagai kaidah keputusan.

Tabel-7.7 : Tingkat Akurasi Fusi Data Multiband Citra Saguling

	Air	Hutan	Pertanian-1	Pertanian-2	Perkampungan	Rata-Rata
Perkalian	96.53	96.66	96.66	92.50	88.98	93.67
Penjumlahan	97.53	97.39	98.08	96.30	98.08	97.48
Maximum	96.02	96.06	94.59	94.67	92.22	94.31
Mayoritas	79.26	79.57	79.40	78.70	78.87	79.16
Perkalian	96.53	96.66	96.66	92.50	88.98	93.67



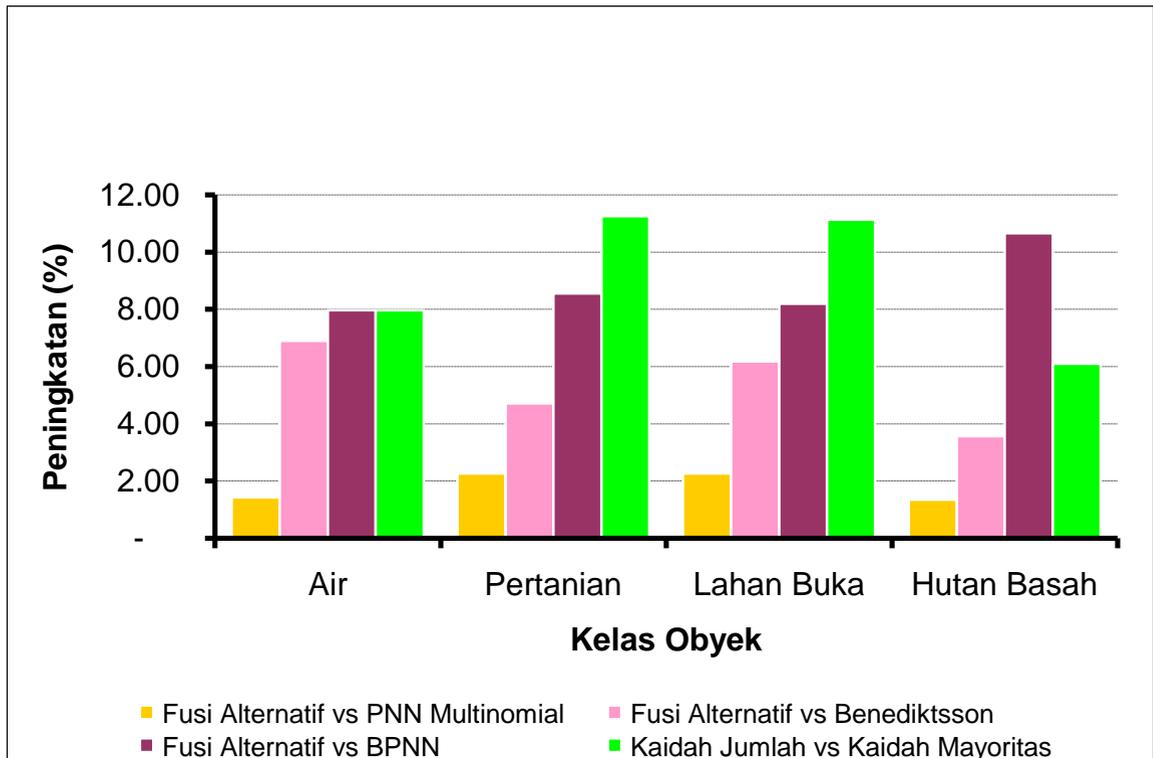
Gambar-7.9 : Tingkat Akurasi Fusi Data Multiband Citra Saguling

Dalam konteks multiband keempat akidah keputusan menunjukkan hasil yang relatif seragam terutama untuk tiga kaidah yaitu perkalian, penjumlahan, dan *maximum* . Hal ini dapat dipahami karena tingkat homogenitas citra yang tinggi akan menghasilkan fitur yang mudah terbedakan.

Perbandingan hasil fusi data dengan kaidah penjumlahan lebih optimal dibanding yang lainnya seperti ditunjukkan pada Tabel-7.8 dan Gambar-7.10.

Tabel-7.8 : Peningkatan Akurasi Fusi Data Alternatif Dibanding Metode Lainnya

	Air	Pertanian	Lahan Buka	Hutan Basah	Rata-Rata
Fusi Alternatif vs PNN Multinomial	1.43	2.26	2.26	1.35	1.83
Fusi Alternatif vs Benediktsson	6.90	4.72	6.18	3.57	6.34
Fusi Alternatif vs BPNN	7.97	8.56	8.20	10.66	8.85
Kaidah Jumlah vs Kaidah Mayoritas	7.97	11.26	11.13	6.10	9.11



Gambar-7.10 : Peningkatan Akurasi Fusi Data Alternatif Dibanding Metode Lainnya

Secara umum fusi data dapat memberikan peningkatan yang cukup signifikan dibanding metode lainnya. Kaidah keputusan fusi yang optimal dalam kasus ini adalah kaidah penjumlahan. Secara teori kaidah penjumlahan menghasilkan tingkat kesalahan (error) yang lebih rendah dari kaidah perkalian yang sering dipakai sebelumnya. Fusi data dengan menggunakan pengklasifikasi PNN model multinomial dan kaidah keputusan jumlah dapat melengkapi informasi citra sensor optik berawan dengan informasi dari citra sensor SAR. Fusi Data dengan kaidah penjumlahan lebih optimal dibanding yang lainnya sehingga peningkatan akurasi pengenalan mencapai rata-rata sekitar 8.85% dari hasil klasifikasi tunggal, mencapai peningkatan sekitar 6.34% dari skema fusi data yang lain, dan mencapai peningkatan sekitar 9.11% dari kaidah yang lain. Untuk fusi data multisensor

diperoleh user's accuracy 98.89% dan producer's accuracy 98.89%, dan untuk fusi data multiband diperoleh user's accuracy 97.59% dan producer's accuracy 97.49%.

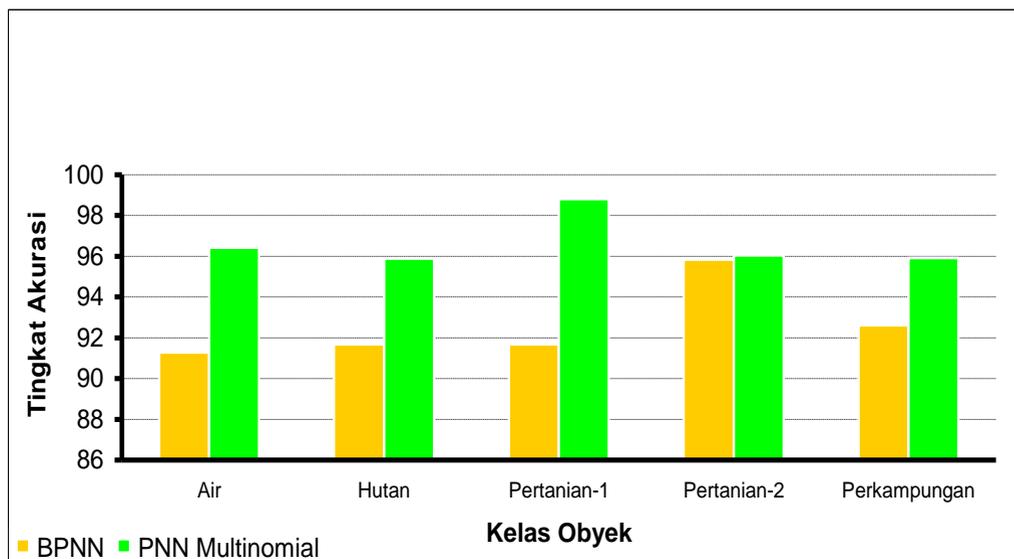
7.6.2 Deteksi Perubahan Wilayah

Untuk deteksi perubahan wilayah digunakan parameter probabilitas *joint* yang diestimasi dengan algoritme EM. Untuk menguji akurasi deteksi perubahan wilayah digunakan dua citra yang sama (tidak ada perubahan) dan keadaan ini akan menghasilkan matrik diagonal yang baik dari probabilitas *joint*. Berikut ini hasil dengan citra Saguling pada tempo yang sama.

Tabel-7.9 dan 7.11, dan Gambar-7.10 dan 7.12 menunjukkan perbandingan tingkat akurasi deteksi perubahan wilayah citra Saguling pada skema pengklasifikasi yang berbeda.

Tabel-7.9 : Tingkat Akurasi Deteksi Perubahan Wilayah Citra Saguling 1972

	Air	Hutan	Pertanian-1	Pertanian-2	Perkampungan	Rata-Rata
BPNN	91.28	91.68	91.68	96.84	92.62	92.62
PNN Multinomial	96.43	96.88	98.81	96.04	96.92	96.62
Peningkatan	6.15	4.20	7.13	0.20	3.30	4.00

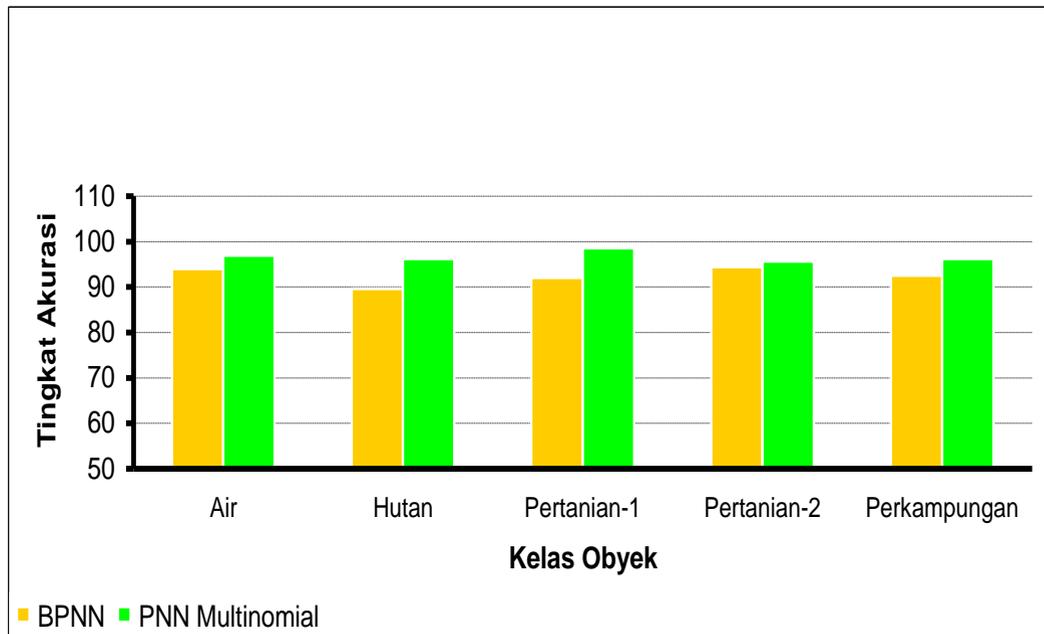


Gambar-7.11 : Tingkat Akurasi Deteksi Perubahan Wilayah Citra Saguling 1972

Deteksi kelas obyek pertanian-2 relatif sama untuk kedua skema baik menggunakan BPNN ataupun PNN multinomial, dan perbedaan paling besar terjadi pada kelas obyek pertanian-1. Dilain pihak skema PNN multinomial paling mudah mendeteksi perubahan kelas pertanian-1.

Tabel-7.10 : Tingkat Akurasi Deteksi Perubahan Wilayah Citra Saguling 1992

	Air	Hutan	Pertanian-1	Pertanian-2	Perkampungan	Rata-Rata
BPNN	94.05	89.66	92.07	94.41	92.55	92.55
PNN Multinomial	96.95	96.2	98.57	96.64	96.2	96.71
Peningkatan	2.90	6.54	6.50	1.23	3.65	4.16



Gambar-7.12 : Tingkat Akurasi Deteksi Perubahan Wilayah Citra Saguling 1992

Berdasarkan skema deteksi perubahan dengan BPNN, perubahan kelas hutan paling sulit dideteksi, dan paling mudah untuk kelas obyek air dan pertanian-2.

Deteksi perubahan wilayah dengan menggunakan parameter probabilitas *joint* dan pengklasifikasi PNN model multinomial mencapai user's accuracy 96.62% dan producer's accuracy 96.71% dan meningkat rata-rata sekitar 4% dari skema BP dengan user's accuracy 92.62% dan producer's accuracy 92.42%. Probabilitas *Joint* diperoleh dengan menggunakan *algoritme EM* dari sumber ganda membutuhkan rata-rata 16 – 20 kali.