AQUASAINS
(Jurnal Ilmu Perikanan dan Sumberdaya Perairan)

PENGELOMPOKKAN HABITAT DASAR PERAIRAN DANGKAL BERBASIS DATA SATELIT QUICKBIRD MENGGUNAKAN ALGORITMA *SELF ORGANISING MAP*

Asmadin[1] · **Vincentius P Siregar**[2] · **Antonius Bambang Wijanarto**[3]

Ringkasan Pengembangan algoritma self organising map dalam penelitian ini bertujuan untuk mengelompokkan habitat perairan dangkal berbasis data satelit Quickbird. Data primer dikumpulkan melalui data penginderaan jauh dan survey lapang, sedangkan data sekunder dikumpulkan dari penelitian yang relevan. Hasil penelitian menunjukkan bahwa klasifikasi algoritma self organising map dapat mengklaster/mengklasifikasi citra Quickbird dari berbagai kombinasi kanal. Dari berbagai kombinasi input data setelah direduksi kolom air dengan algoritma Lyzenga, Self organising map menunjukkan hasil klaster yang relatif baik. Algoritma Lyzenga dapat mengelompokkan habitat perairan dangkal 6 (enam) kelas habitat, yaitu karang mati (merah), karang hidup (hijau), lamun (orange), pasir (kuning), dan habitat campuran (hijau muda), daratan (hitam) dan perairan (biru). Setelah menggunakan self organising map secara visual terlihat 6 kelas habitat yang berbeda dari Lyzenga, yaitu karang mati (kuning), karang hidup (cyan), lamun (ungu), pasir (kuning), dan habitat campuran (biru), daratan (hijau) dan perairan (coklat). Algoritma self organising map dapat mengurangi kesalahan tematik habitat perairan dangkal dan sangat membantu proses ekstraksi ROI (*region of interset*) untuk reklasifikasi lebih lanjut dengan teknik klasifikasi supervised.

Keywords *Pengelompokkan, Self organising map, Lyzenga, Habitat dasar perairan dangkal, Quickbird*

[1])Fakultal Perikanan dan Ilmu Kelautan Universitas Haluoleo Jl HAE Mokodompit Kampus Bumi Tridharma Andionohu Kendari 93232 [2]) Departemen ITK FPIK IPB Bogor [3]) Bakorsurtanal Cibinong Jawa Barat E-mail: agussu.san@gmail.com

PENDAHULUAN

Berbagai studi sebelumnya menyatakan bahwa self-organizing map (SOM) dapat menjadi alternatif untuk klasfikasi citra *multilayer perceptron* (MLP) pada jaringan saraf tiruan di tingkat per pixel dan subpixel, meskipun performansi dari SOM dan MLP tidak dapat diperbandingkan dalam mengestimasi dan memetakan kenampakan citra [1]. Salah satu metode penilaian kesalahan tematik berdasarkan satuan pixel adalah menggunakan output dari suatu klasifikasi untuk mengestimasi ketidakpastian tematik [2]. Selanjutnya penentuan seleksi paling banyak tersedia pengklasifikasi untuk pemetaan penutupan lahan atau prediksi ketidakpastian tematik. [3]Standar algoritma secara supervised sangat lambat dan seringkali masalah sederhana memerlukan ratusan iterasi untuk mencapai konvergensi. Guna mereduksi dimensi input pola ke jumlah yang lebih sedikit

sehingga pemrosesan komputer menjadi lebih hemat, maka [4] menggunakan aplikasi SOM dalam pengenalan pola, analisis citra, monitoring proses dan diagnosis kesalahan. Algoritma SOM pertama kalinya dikembangkan oleh [5], bahwa rata-rata klasifikasi statistik atau clustering input data space dinyatakan kedalam class region dengan sistem pengorganisasian sendiri (mandiri). Dalam sistem penginderaan jauh perairan dangkal, salah satu algoritma yang sering digunakan adalah algoritma depth invariant index [6] [7]. Algoritma ini juga diterapkan dalam penelitian [8], [9] dan [10] sebagai pengklasifikasi habitat. Algoritma ini mengaplikasikan metode koreksi kolom air atau dikenal dengan Algoritma Lyzenga. Metode ini efektif untuk meningkatkan kualitas identifikasi dan klasifikasi habitat dasar perairan dangkal secara tematik. Selain itu terdapat beberapa algoritma klasifikasi citra yang digunakan untuk diskriminasi antara terumbu karang dan asosiasi habitat adalah *maximum likelihood, contextual editing* dan *object oriented* [11]. Algoritma Lyzenga dan SOM ini sangat membantu tidak terlepas hanya pada keunggulan teknologi satelit Quickbird untuk memetakan habitat perairan dangkal, karena kemampuannya melakukan monitoring dan inventarisasi pada areal yang luas dan repetitif, biaya operasional relatif murah, dan resiko sangat kecil [12] dan [13]. Oleh karena itu kajian ini diperlukan untuk mengintegrasikan dua algoritma pengelompokkan data citra kedalam kelas region dengan teknik klasifikasi secara tidak terbimbing. Penelitian ini sangat penting manfaatnya dalam menentukan r*egion of interest* (ROI) yang tepat bagi penerapan metode klasifikasi supervised lebih lanjut dan untuk mengurangi kesalahan dan ketidakpastian tematik.

METODE PENELITIAN

Bahan penelitian ini menggunakan data penginderaan jauh hasil perekaman citra Quickbird tanggal 28 September 2008 dan data posisi in-situ survei lapangan 23 – 29 Juni 2009 di wilayah terumbu karang di Gusung Karang Lebar dan Karang Congkak Kepulauan Seribu, Provinsi Daerah Khusus Ibukota Jakarta sebagai data primer. Distribusi spasial karakteristik habitat dasar perairan dangkal diolah dari citra satelit menggunakan beberapa pendekatan seperti komposit Band dan penajaman citra dengan algoritma *Depth Invariant Index* dan *Self Organising Map*. Algoritma depth invariant index ini mengaplikasikan metode koreksi kolom air [6] [7] dengan persamaan algoritma diturunkan sebagai berikut:

$$Y = Ln\,B1 - (\frac{k_i}{k_j})Ln\,B2 \quad (1)$$

$$\frac{k_i}{k_j} = a + \sqrt{(a^2+1)} \quad (2)$$

$$a = \frac{\sigma_i - \sigma_j}{2\sigma_{ij}} \quad (3)$$

dimana:

Y = ideks dasar perairan; B = Band yang dipilih; k_i/k_j= koefisien atenuasi; σ_i= Varians Band ke-i; σ_j= varians Band ke-j; dan σ_{ij}= Kovarians Band ke-ij

Sedangkan pembelajaran (*learning*) menggunakan algoritma *self organising map* (SOM) diadopsi dari [5]. Desain *unsupervised learning* menggunakan algoritma SOM memiliki kemampuan atau pengorganisasian mandiri tanpa adanya pendefinisian kelas sebelumnya, sehingga membentuk suatu klaster dengan input minimal dari user (unit input layer) untuk membagi jumlah kelas/klaster yang dihasilkan (*unit output layer*). Ekstraksi parameter input dari penelitian ini menyelidiki kombinasi kanal citra Qukcbird sebagai parameter input. Parameter training disusun dengan jumlah input kanal citra 3, training rate 0.5-0.001, radius ketetanggaan pixel 4 dan 10,000 iterasi.

1. Unit input layer xi diaktifkan oleh input data citra. Input nilai pixel citra secara linear dibuat dari skala 0.0 dan 1.0 untuk input dengan Band minimum dan maksimum.
2. Unit output layer yj merupakan output klaster. Output layer adalah kelompok yang paling dekat/mirip radius ketetanggaan pixel dari masukan yang diberikan

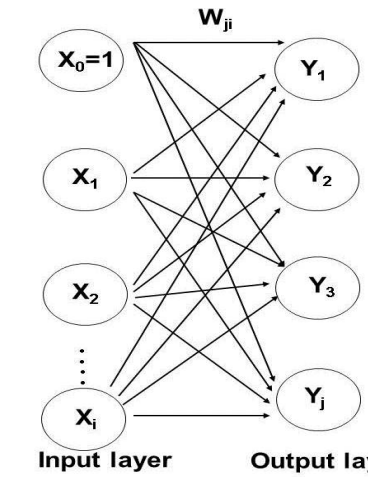

Keterangan:
xi : input variabel dari node i dalam input layer
Yj : output node k dalam output layer (nilai prediksi untuk node j)
Wji : bobot koneksi node i input layer dengan node j dalam output layer

Gambar 1 Jaringan Algoritma ANN-SOM

Pelatihan jaringan Algoritma ANN-SOM (Gambar 1.) melalui langkah berikut:

1. Inisialisasi: (a) bobot-bobot wij (biasanya random antara 0 - 1); (b) laju pemahaman awal dan faktor penurunannya; dan (c) bentuk dan jari-jari (=R) topologi sekitarnya
2. Jika kondisi henti gagal, lakukan langkah 3-8.
3. Untuk setiap vektor masukan x, lakukan langkah 3-6
4. Untuk setiap j, hitung:

$$d_j^2 = \sum_i^k \left(x_i^n - w_{ji}^n\right)^2 \quad (4)$$

dimana : x_i^n adalah input neuron ke i pada iterasi n, dan w_{ji}^n adalah bobot dari input neuron i ke output neuron j pada iterasi n

5. Tentukan indeks j sehingga dj minimum:
6. Untuk setiap neuron j disekitar J modifikasi bobot:

$$w_{ji}\, baru = w_{ji}\, lama + \alpha\,(X_{ji} - w_{ji}\, lama) \quad (5)$$

7. Perbaiki kecepatan pembelajaran (mulai dengan 0.5 dan turunkan 0.001)
8. Uji kondisi penghentian Kondisi penghentian iterasi adalah selisih antara wji saat itu dengan wji pada iterasi sebelumnya. Apabila semua wji hanya berubah sedikit saja, berarti iterasi sudah mencapai konvergensi sehingga dapat dihentikan.

HASIL DAN PEMBAHASAN

Pelatihan SOM bertujuan untuk menghasilkan klaster-klaster yang merupakan representasi secara visual sesuai karakteristik fitur-fitur masing-masing kelompok dalam citra yang terintegrasi membentuk 3 buah kanal RGB. Jika pelatihan SOM dijalankan menggunakan input klasifikasi dengan parameter training pada Bab sebelumnya, maka diperoleh perbedaan kenampakan spasial berbagai transformasi kombinasi Band dari satelit Quickbird (Gambar 2). Perbedaan yang mencolok ini masih sulit diintrepretasi secara visual, karena masih ada faktor-faktor kolom air yang belum dikoreksi dan ini mengurangi kemampuan panjang gelombang kanal untuk mendiskriminasi habitat perairan dangkal itu sendiri.

Pengaruh yang signifikan semakin nampak setelah citra dikoreksi berdasarkan kolom air menggunakan algoritma Lyzenga (Gambar 3a). Hasil transformasi metode "*Deep Invariant Index*" (algoritma Lyzenga) sesuai hasil penelitian [8] menggunakan data SPOT diperoleh klasifikasi tutupan dasar perairan ekosistem terumbu karang Kelurahan Pulau Panggang Kepulauan Seribu terdiri atas: (i) dominasi karang mati ditampilkan dengan warna biru muda, (ii) dominasi karang hidup (merah), (iii) lamun (hijau), (iv) pasir (kuning), dan (v) perairan dalam dengan kedalaman >15 m. Berbeda halnya dengan sensor Quickbird yang digunakan dari hasil klasifikasi diperoleh 6 kelas habitat, yaitu nampak bahwa karang mati (merah), karang hidup (hijau), lamun (orange), pasir (kuning), dan habitat campuran (hijau muda). Adapun daratan (hitam) dan perairan (biru) terlihat dengan jelas. Intrepretasi ini relatif sama dengan [9] dan [10] yang sama-sama menggunakan Quickbird dalam penelitian ini. Substrat dasar pasir hampir mendominasi seluruh wilayah kajian. Karang hidup

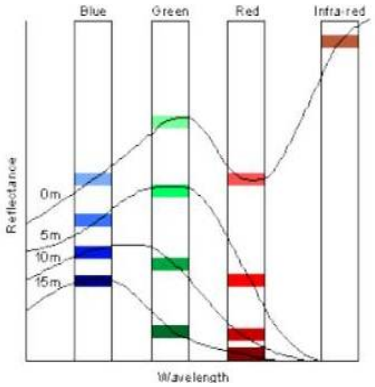

Gambar 2 Diagram untuk menunjukkan bagaimana spectra suatu habitat (seperti macroalgae atau seagrass) yang mungkin berubah dengan bertambahnya kedalaman untuk pengukuran radian empat panjang gelombang sensor biru, hijau, merah dan near infra-red pada spektrum electromagnetic

lebih banyak menyebar dibagian luar terumbu, dibandingkan di sekitar goba, demikan pula dengan sebaran pasir dan tutupan lamun juga banyak ditemukan disekitar tubir karang. Perbedaan kenampakan ini disebabkan oleh perbedaaan atenuasi empat panjang gelombang dalam kolom air menghasikan pengurangan kemampuan untuk mendiskriminasi antara habitat yang berbeda dengan penambahan kedalaman dan perbedaan spectra tercatat untuk habitat yang sama pada kedalaman berbeda sebagaimana ditunjukkan oleh [14] pada Gambar 3.

Selanjutnya pada penerapan SOM setelah dikoreksi kolom air menggunakan algoritma Lyzenga nampak keberhasilan aplikasi SOM. Keberhasilan aplikasi SOM tidak terlepas dari kemampuan fungsinya sebagai cluster data citra dimensi tinggi, generalisasi jaringan dapat mengenal ciri input yang belum pernah ditemukan sebelumnya, dan reduksi kenampakan spasial dari kombinasi citra dengan menunjukkan karakteristik spasial objek secara berarti [5]. Perbedaan kontras terlihat dengan jelas pada daerah gobah, tubir dan daratan (Gambar 4). Hal ini mempertegas pendapat [4] bahwa teknik aplikasi SOM ini dapat diterapkan dalam pengenalan pola, analisis citra, monitoring proses dan diagnosis kesalahan. Paramater jumlah radius ketetanggaan pixel dalam penelitian ini sebesar 4 diset lebih kecil dari 6.66 sesuai hasil penelitian [1] menggunakan citra ASTER. Hal ini diduga karena SOM mampu memetakan objek secara baik tidak hanya citra resolusi rendah sampai sedang, tetapi juga bagi citra resolusi tinggi seperti Quickbird.

Intrepretasi lain ditinjau dari analisis visual menunjukkan ciri spasial dan spesifik berbeda setiap klaster berdasarkan perbedaan warna mewakili perbedaan kelas, sebagaimana [15] mengintrepretasi citra habitat terumbu karang Midway Atoll dan [16] memetakan habitat bentik di perairan tropik menggunakan citra Quickbird dengan teknik klasifikasi unsupervised ISODATA (iterative self organizing data analysis). Menurut [13] bahwa teknik klasifikasi unsupervised mengklasifikasi secara otomatis pixel kedalam sejumlah kelas berdasarkan kesamaan spektral tanpa referensi spektra dari user. Lain halnya dengan algoritma ISODATA, kemampuan SOM dapat mengeneralisasi data habitat terumbu karang yang sama kedalam satu klaster/kelas tersebut dapat diketahui dengan sendirinya dari distribusi nilai DN secara merata di semua kanal RGB yang didefinisikan menjadi Band 1 (Red), Band 2 (Green) dan Band 3 (Blue). Algoritma ISODATA menurut [16] dapat menyusun klaster citra kombinasi Band Quickbird kemudian diklasifikasi lebih lanjut dengan *maximum likelihood*. Perbedaan semakin nampak setelah menggunakan input Lyzenga untuk proses klaster SOM. Sama halnya dengan sensor Quickbird yang digunakan dari hasil klasifikasi diperoleh 6 kelas habitat, namun perbedaan warna terlihat bahwa karang mati (ungu), karang hidup (cyan), lamun (biru muda), pasir (kuning), dan habitat campuran (biru). Adapun daratan (hijau) dan perairan (coklat) terlihat dengan jelas. Intrepretasi ini relatif berbeda dengan [9] dan [10] yang sama-sama menggunakan Quickbird dalam penelitian ini.

Disamping kenampakan spasial diatas, secara statistik berdasarkan histogram Gambar 5 menunjukkan pola kenampakan yang berbeda satu dengan lainnya. Perubahan

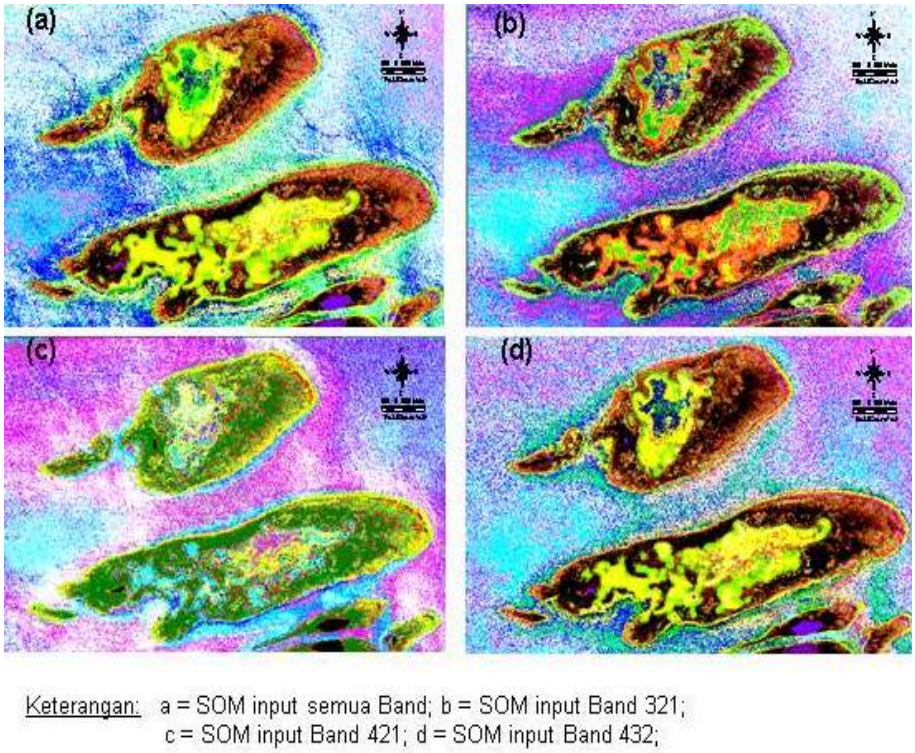

Gambar 3 Kenampakan spasial hasil klasifikasi algoritma SOM

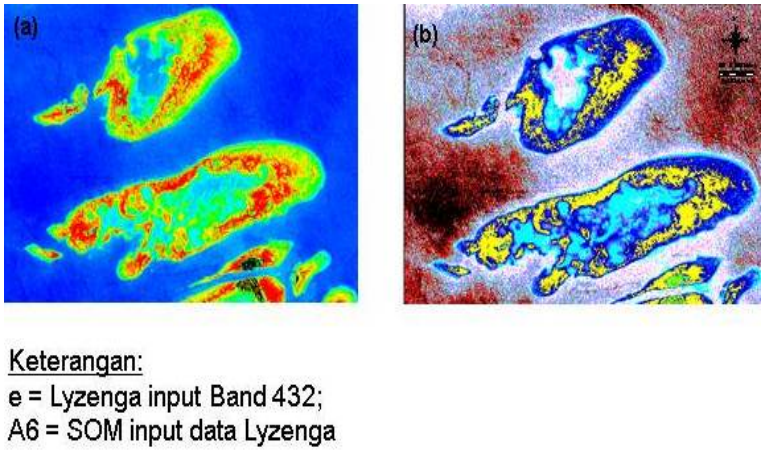

Gambar 4 Kenampakan spasial hasil klasifikasi algoritma SOM

yang signifikan terjadi setelah data input dikoreksi menggunakan algoritma Lyzenga. Kecenderungan ini terlihat dengan makin meningkatnya jumlah klaster pada kondisi tersebut. Hal ini semakin memperkuat bahwa input data Lyzenga baik untuk reklasifikasi lebih lanjut dengan klasifikasi jaringan saraf tiruan secara supervised. Hasil analisis statistik masing-masing klaster SOM meliputi nilai-nilai kovarians, koefisien korelasi dan *eigenvector* mencerminkan keeratan hubungan kombinasi masing-masing Band untuk mengekstraksi informasi spasial objek (target) tersebar pada nilai DN. Hasil analisis kovarian matrik dari masing-masing klaster berbeda sesuai pencirinya. Karakteristik ini terkait preservasi hubungan ketetanggaan sebesar 4 pixel jarak yang begitu jauh, nilai pixel ini merupakan data vektor ketetanggaan ruang

input yang dipetakan kedalam ruang output. Kenampakan secara spasial dan statistik ini membuat SOM sangat berguna dalam analisis data dan visual dimana tujuan umumnya adalah mewakili data dari suatu ruang dimensi tinggi dalam suatu ruang dimensi yang sama lemahnya untuk preservasi struktur internal dari data ruang input.

Berdasarkan analisis kovarian matrik menunjukkan adanya keeratan hubungan antara masing-masing variabel yaitu, Band 1 (Red), Band 2 (Green) dan Band 3 (Blue) terhadap ekstraksi objek. Nilai kovarian secara diagonal menunjukkan besar dan arah hubungan linear antara dua peubah Band. Nilai kovarian klaster A4 secara berurutan menunjukkan nilai makin besar pada Band 1, 3 dan 2 dengan nilai penciri (*eigen value*) terbesar yaitu Band 1. Karakteristik vektor (*eigen vector*) Band 1 besarannya searah Band 2 dan sebaliknya terhadap Band 3. Berbeda dengan nilai kovarian klaster A6 secara berurutan menunjukkan nilai makin besar pada Band 1, 2 dan 3 dengan nilai penciri (eigen value) terbesar yaitu Band 1. Eigen vector Band 1 besarannya searah terhadap Band 2 dan 3. Karakteristik ini menunjukkan secara jelas bahwa Band 1 optimal dalam mengekstraksi informasi, terutama kelas pasir. Hal ini diperkuat pula oleh nilai korelasi negatif ((-)) Band 1 terhadap Band 3 masih dengan eigen value terendah dibanding Band yang lain ataupun kombinasi lainnya. Pemetaan hubungan ketetanggaan SOM memungkinkan untuk melihat secara jelas output ruang dan struktur tersembunyi dalam data dimensi tinggi, seperti cluster. Sebagaimana SOM didefinisikan dengan asumsi bahwa beberapa parameter peta, seperti parameter pembelajaran, topology dan ukuran peta selama fase training. Kenampakan ini mempengaruhi peta akhir, sehingga sangat penting kehatihatian untuk memilih parameter-parameter yang menghasilkan peta tepat [4]. Oleh karena itu, pengembangan klasifikasi algoritma supervised dapat mengesktrak nilai ROI lebih lanjut pada klaster tersebut, sehingga berguna sebagai target data pembelajaran. Guna menguji perbedaan pilihan, dapat menggunakan beberapa komputasi tiruan untuk mengevaluasi kualitas peta dan menseleksi satu yang optimal untuk mewakili data.

KESIMPULAN

Klasifikasi algoritma self organising map dapat mengklaster/mengklasifikasi citra Quickbird dari berbagai kombinasi kanal. Dari berbagai kombinasi input data setelah direduksi kolom air dengan algoritma Lyzenga, self organising map menunjukkan hasil yang relatif baik. Algoritma Lyzenga dapat mengelompokkan habitat perairan dangkal 6 (enam) kelas habitat, yaitu karang mati (merah), karang hidup (hijau), lamun (orange), pasir (kuning), dan habitat campuran (hijau muda), daratan (hitam) dan perairan (biru). Setelah menggunakan self organising map diperoleh 6 kelas habitat yang berbeda intrepretasi warna dari Lyzenga, yaitu terlihat bahwa karang mati (kuning), karang hidup (cyan), lamun (ungu), pasir (kuning), dan habitat campuran (biru), daratan (hijau) dan perairan (coklat). Algoritma self organising map dapat mengurangi kesalahan tematik habitat perairan dangkal dan sangat membantu proses ekstraksi ROI (region of interest) untuk reklasifikasi lebih lanjut dengan teknik klasifikasi supervised.

PUSTAKA

1. Hu X and Q Weng. 2009. Estimating Impervious Surfaces From Medium Spatial Resolution Imagery Using The Self Organizing Map and Multi-Layer Perceptron Neural Networks. *J Remote Sens,* 113:2089-2102.
2. Brown KM, GM Foody dan PM Atkinson. 2009. Estimating per-pixel thematic uncertainty in remote sensing classifications. UK: Int. *J. Remote Sense*, 30(1):209–229.
3. Rajapandian VVJ and N Gunaseeli. 2007. Modified Standard Backpropagation Algorithm with Optimum Initialization for Feedforward Neural Networks. *IJISE*,GA, 1(3):86-89.
4. Uriarte EA and FD Martin, 2005. Topology Preservation in SOM. Faculty of Engineering, University of Deusto. Bilbao: *Intl J Mathematical and Computer Sciences*, 1:1.

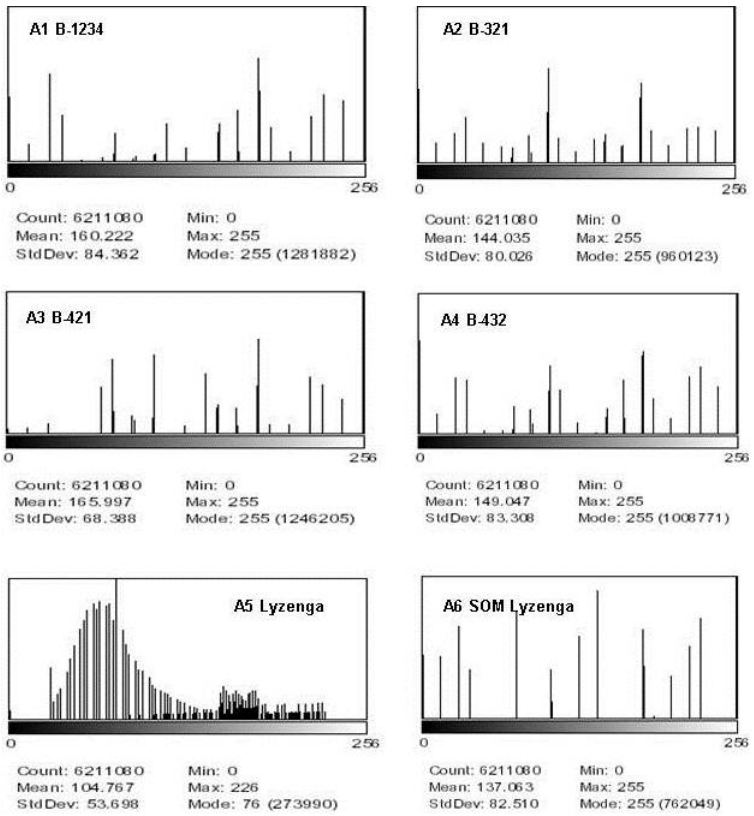

Gambar 5 Histogram Klasifikasi Algoritma SOM

5. Kohonen T. 1984. *Self Organizing and Associative Memory*. Berlin: Springer-Verlag.
6. Lyzenga, D.R., 1978, Passive remote sensing techniques for mapping water depth and bottom features. *Applied Optics*, 17:379–383.
7. Lyzenga, D.R., 1981, Remote sensing of bottom reflectance and water attenuation parameters in shallow water using aircraft and Landsat data. *Intl J. Remote Sens*, 2:71–82.
8. Sulma S, dan D Kushardono. 2006. Pemanfaatan Citra Satelit SPOT-5 untuk Identifikasi Terumbu Karang di Perairan Kepulauan Seribu. Jakarta: *Majalah Berita Inderaja LAPAN*, V(9):31-33.
9. Amri K, Siregar VP, Takwir A dan Asmadin. 2010. Kajian Akurasi Citra Satelit Quickbird dengan Metode Differential Global Positioning untuk Klasifikasi Tipe Substrat Dasar Perairan Karang Congkak dan Karang Lebar Kepulauan Seribu. *Jurnal Kelautan Nasional*, 5(1):25-32
10. Siregar VP, S Wouthuyzen, S Sukimin, SB Agus, MB Selamat, Adriani, Sriati dan Muzaki. 2010. Informasi Spasial Habitat Perairan Dangkal dan Pendugaan Stok Ikan Terumbu Menggunakan Citra Satelit. Bogor: *SEAMEO BIOTROP-FPIK IPB*.
11. Benfield SL, H M Guzman, J M Mairs and JAT Young. 2007. Mapping the distribution of coral reefs and associated sublittoral habitats in Pacific Panama: a comparison of optical satellite sensors and classification methodologies. *Intl J Remote Sens,* 28(20):5047-5070.
12. Mumby, P.J., Green, E.P., Clark, C.D., Edwards, A.J., 1998. Digital analysis of multispectral airborne imagery of coral reefs. *Coral Reefs* 17, 59–69.
13. Green EP, PJ Mumby, AJ Edwards, and CD Clark. 2000. *Remote Sensing Handbook for Tropical Coastal Management*. Paris: UNESCO.
14. Mumby PJ, and Edwards AJ. 2004. Benefits of water column correction and contextual editing for mapping coral reefs. *Intl J Remote Sens*, 19:203-210.
15. Camacho, MA. 2006. *Depth Analysis of Midway Atoll Using Quickbird Multispectral Imaging Over Variable Substrates*. Monterey: Naval Postrgraduate School.
16. Mishra D, S Narumalani, D Rundquist, and M Lawson. 2006. Benthic Habitat Mapping in Tropical Marine Environments Using Quickbird Multispectral Data. American Society for Photogrammetry and Remote sensing, New York: *Photogrametric Engineering and Remote Sensing*, 72(9):1037-1048.