

Segmentasi Citra Ikan Tuna Menggunakan Gradient-Barrier Watershed Berbasis Analisis Hierarki Klaster dan Regional Credibility Merging

Arif Fadllullah¹, Agus Zainal Arifin², Dini Adni Navastara³

Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember

Kampus ITS Keputih, Sukolilo, Surabaya, 60111, Jawa Timur

Email: ¹arif.fadl@gmail.com, ²agus.za@its-sby.edu, ³dini_navastara@if.its.ac.id

Masuk: 20 Januari 2016; Direvisi: 2 Februari 2016; Diterima: 2 Februari 2016

Abstract. *The main issue of object identification in tuna image is the difficulty of extracting the entire contour of tuna physical features, because it is often influenced by uneven illumination and the ambiguity of object edges in tuna image. We propose a novel segmentation method to optimize the determination of tuna region using GBW-AHK and RCM. GBW-AHK is used to optimize the determination of adaptive threshold in order to reduce over-segmented watershed regions. Then, RCM merges the remaining regions based on two merging criteria, thus it produces two main areas of segmentation, the object extraction of tuna and the background. The experimental results on 25 tuna images demonstrate that the proposed method successfully produced an image segmentation with the average value of RAE by 4.77%, ME of 0.63%, MHD of 0.20, and the execution time was 11.61 seconds.*

Keywords: *watershed, gradient-barrier, hierarchical cluster analysis, regional credibility merging, tuna segmentation*

Abstrak. *Kendala utama identifikasi objek tuna pada citra ikan tuna adalah sulitnya mengekstraksi seluruh kontur tubuh ikan, karena seringkali dipengaruhi faktor iluminasi yang tidak merata dan ambiguitas tepi objek pada citra. Penelitian ini mengusulkan metode segmentasi baru yang mengoptimalkan penentuan region objek tuna menggunakan Gradient-Barrier Watershed berbasis Analisis Hierarki Klaster (GBW-AHK) dan Regional Credibility Merging (RCM). Metode GBW-AHK digunakan untuk mengoptimalkan penentuan adaptif threshold untuk mereduksi region watershed yang over-segmentasi. Kemudian RCM melakukan penggabungan region sisa hasil reduksi berdasarkan dua syarat penggabungan hingga dihasilkan dua wilayah utama segmentasi, yakni ekstraksi objek ikan tuna dan background. Hasil eksperimen pada 25 citra ikan tuna membuktikan bahwa metode usulan berhasil melakukan segmentasi dengan nilai rata-rata relative foreground area error (RAE) 4,77%, misclassification error (ME) 0,63%, modified Hausdorff distance (MHD) 0,20, dan waktu eksekusi 11,61 detik.*

Kata Kunci: *watershed, gradient-barrier, analisis hierarki klaster, regional credibility merging, segmentasi tuna*

1. Pendahuluan

Tuna merupakan salah satu komoditas perikanan ekspor andalan Indonesia selain udang yang memasok lebih dari 16% total produksi tuna dunia (Pregiwati, 2015). Seiring produksi hasil tangkapan tuna yang mengalami peningkatan dari tahun ke tahun, tentu harus diimbangi dengan terjaminnya standar mutu pengolahan dan penanganan kualitas produksi. Berkaitan dengan menjaga mutu tuna agar kesegaran tidak terlalu mengalami penurunan, efisiensi waktu pemilahan ke penyimpanan perlu mendapat pertimbangan prioritas. Sayangnya ketika bahan baku berlimpah, jika masih mengandalkan pemilahan kualitas secara manual ikan tuna dengan berbagai variasinya, seperti cacalung, mata besar, albakora, sirip kuning, sirip biru, dan lainnya. Alhasil, berimbas pada semakin lamanya waktu proses dan hasil klasifikasi yang subjektif.

Salah satu penelitian yang mencoba untuk mengatasi permasalahan tersebut adalah sistem klasifikasi ikan tuna menggunakan metode kombinasi *Fuzzy Logic* dan *Decision Tree* dengan parameter klasifikasi berupa hasil ekstraksi fitur geometri dan *multi texton co-*

occurrence descriptor (MTCDD) (Puspita, dkk., 2015). Hasil penelitian menunjukkan bahwa tingkat akurasi klasifikasi yang sangat tinggi sebesar 91%, tetapi terdapat kelemahan dalam tahapan segmentasi yang hanya menggunakan deteksi tepi sobel dan morfologi citra, sehingga rentan terhadap derau, inkonsistensi tepi, dan perpendaran cahaya. Untuk itu, diperlukan tahapan segmentasi yang lebih optimal agar pengambilan lingkup fitur ekstraksi menjadi lebih banyak dan akurat. Salah satu metode segmentasi citra yang dapat digunakan adalah segmentasi berbasis region, seperti *watershed*. Metode ini handal digunakan untuk segmentasi karena kelebihan yang menghasilkan sejumlah region dengan kontur tertutup dan ketebalan satu piksel. Namun, kompleksitas segmentasi *watershed* terhitung tinggi apalagi diterapkan secara langsung ke citra asal karena dapat menghasilkan region yang berlebih atau *over-segmentasi*.

Beberapa penelitian telah mencoba untuk mengatasi permasalahan tersebut, diantaranya region *watershed* dibangun menggunakan hierarki berbasis skala berdasarkan konvolusi *gaussian blurring* (Gauch, 1999), sehingga menghasilkan area region lebih luas, hanya saja region-region yang dihasilkan tidak menangkap objek dengan benar, karena terjadi penurunan kualitas tepi objek. Berikutnya, penggunaan filter *anisotropic diffusion* untuk membentuk region *watershed* cukup berhasil membentuk region-region yang dapat menangkap objek, khususnya pada bagian tepi objek. Akan tetapi, jika terdapat objek dengan kekuatan tepi yang beragam, maka teknik ini akan mereduksi minimal tepi objek (Arefin, dkk., 2014). Selain itu, terdapat juga teknik reduksi region *watershed* yang memanfaatkan pemilihan intensitas minima region menggunakan fitur rata-rata piksel *gradient magnitude* citra sebagai nilai *threshold* pemotongan region objek dan non objek (Ng, dkk., 2008). Segmentasi *watershed* berbasis *marker* (Zhang, dkk., 2014) atau *gradient-barrier watershed* (Yang & Ahuja, 2014) yang memiliki teknik kurang lebih sama dengan penelitian Ng, dkk. (2008), tetapi *threshold* pemotongan diperoleh secara manual dengan nilai yang statis untuk seluruh citra berdasarkan pendekatan memilih proporsi tepi objek paling minimal. Penggunaan nilai *threshold* yang statis untuk masing-masing citra tentu akan menghasilkan keoptimalan reduksi region yang berbeda satu dengan yang lain. Selain itu, pemanfaatan rata-rata *gradient magnitude* sebagai *threshold* otomatis juga kurang optimal, karena tidak mempertimbangkan varian puncak dan lembah histogram. Ini mengakibatkan titik potong *threshold* tidak secara ideal berada di lembah tertentu guna memotong dua puncak yang mewakili kluster *marker* objek dan non objek tuna, khususnya dalam mempertahankan region tepi objek tuna.

Oleh karena itu, penelitian ini mengusulkan metode baru dalam segmentasi citra ikan tuna yang mengoptimalkan penentuan region objek tuna menggunakan *Gradient-Barrier Watershed* berbasis Analisis Hierarki Kluster (GBW-AHK) dan *Regional Credibility Merging* (RCM). *Gradient-barrier* dalam skema *watershed* digunakan untuk menghasilkan *barrier thresholding* yang penentuannya mempertimbangkan satu dari sekian *multi-threshold* yang dihasilkan dari analisis hierarki kluster histogram *gradient magnitude* citra, sehingga dihasilkan *threshold* yang lebih adaptif guna mereduksi region yang tidak signifikan membentuk region objek. Selanjutnya, RCM menggabungkan beberapa region tersisa dengan mempertimbangkan dua syarat penggabungan yaitu, ketetanggaan antar region dan ketidakmiripan tekstur-warna hingga dihasilkan dua wilayah utama segmentasi, yakni ekstraksi objek ikan tuna dan *background*. Diharapkan penelitian ini menghasilkan segmentasi yang tahan terhadap masalah *over-segmentasi* region, termasuk iluminasi yang tidak merata dan ambiguitas konsistensi tepi kontur objek sebelum masuk ketahapan klasifikasi.

2. Tinjauan Pustaka

Pada bagian ini akan dibahas mengenai penelitian segmentasi ikan tuna, normalisasi citra, *gradient-barrier watershed*, analisis hierarki kluster, dan *regional credibility merging*.

2.1. Perkembangan Segmentasi Ikan Tuna

Penelitian yang berkaitan dengan segmentasi citra ikan tuna belum begitu banyak. Beberapa diantaranya adalah penelitian terkait pengukuran panjang ikan tuna pada citra digital menggunakan *hough transform* (HT) dan *projective transform* (PT). Cara ini terbukti berhasil

mengukur panjang tuna secara otomatis dengan posisi kamera berbagai sudut (Hsieh, dkk., 2011). Selain itu, terdapat juga penelitian segmentasi citra ikan secara umum menggunakan *K-means* dengan inisialisasi puncak histogram sebagai kandidat jumlah kluster yang berhasil menentukan jumlah kluster secara adaptif guna memisahkan region objek ikan dengan *background* (Yao, dkk., 2013). Akan tetapi, untuk kasus citra dengan warna objek dan *background* mendekati sama, tentu akan menyulitkan proses kluster karena terdapat kemungkinan region objek dan *background* memiliki label yang sama, sedangkan penggunaan deteksi tepi seperti *hough transform* seringkali menghasilkan garis segmen terputus. Oleh karena itu, perlu pendekatan segmentasi yang dapat menghasilkan region dengan label berbeda dan kontur tertutup dengan mempertimbangkan informasi spasial ketetanggaan dan fitur tekstur-warna untuk identifikasi region objek.

2.2. Normalisasi Citra

Terdapat tiga tahapan normalisasi citra yang digunakan untuk mereduksi derau citra tuna. Pertama, filter *bilateral* berfungsi untuk menghaluskan tekstur kasar pada citra dengan melakukan kombinasi non-linier berdasarkan dua metode pembobotan, yaitu bobot spasial (W_s) pada domain filter dan bobot fotometrik (W_R) pada rentang filter (Elad, 2002). Perhitungan intensitas *bilateral* $B[k]$ tiap piksel menggunakan proses konvolusi berdasarkan persamaan (1), dimana N adalah dimensi kernel yang besarnya ditentukan oleh *user*, $W[k,u]$ merupakan nilai perkalian bobot spasial (W_s) dengan fotometrik (W_R) tetangga terhadap titik pusat k , dan $g[k-u]$ merupakan intensitas piksel tetangga terhadap piksel pusat $g[k]$.

Kedua, *contrast stretching* berguna untuk memperbaiki kontras citra dengan cara meningkatkan sebagian rentang dinamis dari level keabuan citra yang akan diproses (Gonzalez & Woods, 2002). Ketiga, filter *homomorphic* berfungsi untuk menormalkan iluminasi citra $f(x,y)$ yang tidak merata dengan melemahkan frekuensi rendah yang didominasi *illumination* $I(x,y)$ dan memperkuat frekuensi tinggi yang didominasi *reflectance* $R(x,y)$ (Fan & Zhang, 2011). Tahapan filter *homomorphic* diawali dengan memisahkan dua komponen citra tersebut menggunakan sifat logaritmik yang kemudian dikonversi ke domain frekuensi $S(u,v)$ dan dikenakan filter *high-pass* $H(u,v)$, misal *gaussian* seperti persamaan (2) dan (3). Untuk mendapatkan hasil filter *homomorphic* perlu dikembalikan ke dalam domain spasial menggunakan persamaan (4). Langkah terakhir, hitung eksponensial persamaan (5) untuk mendapatkan citra perbaikan $g(x,y)$.

$$B[k] = \frac{\sum_{u=1}^{(N \times N) - 1} W[k,u] g[k-u]}{\sum_{u=1}^{(N \times N) - 1} W[k,u]}, \quad (1)$$

$$F\{Z(x,y)\} = F\{\ln I(x,y)\} + F\{\ln R(x,y)\}$$

$$Z(u,v) = F_I(u,v) + F_R(u,v) \quad (2)$$

$$S(u,v) = H(u,v), Z(u,v) = H(u,v) [F_I(u,v) + F_R(u,v)]. \quad (3)$$

$$s(x,y) = F^{-1}\{S(u,v)\} = F^{-1}\{H(u,v) [F_I(u,v) + F_R(u,v)]\} = I'(x,y) + R'(x,y). \quad (4)$$

$$g(x,y) = e^{s(x,y)} = e^{\{I'(x,y) + R'(x,y)\}} = e^{I'(x,y)} \cdot e^{R'(x,y)}. \quad (5)$$

2.3. Gradient Barrier Watershed (GBW)

Titik *seed* penghasil region *watershed* dapat diseleksi memanfaatkan *gradient magnitude* citra yang kemudian direduksi dengan *threshold*. Jika semua piksel *gradient magnitude* lebih kecil dari *threshold*, maka *seed* teridentifikasi sebagai *marker* yang bernilai 1 (putih), sedangkan jika lebih besar, maka diabaikan bernilai 0 (hitam) (Zhang, dkk., 2014). Konsep yang kurang lebih sama, Yang & Ahuja (2014) memperkenalkan *gradient-barrier* untuk mengubah lokasi di mana air dari *marker* yang berbeda bertemu dengan menambahkan fitur penggunaan gradien citra objek guna memandu proses 'aliran air' dalam skema *watershed*.

Alur *gradient-barrier watershed* diawali dengan mendapatkan *gradient magnitude* citra yang dibuat berdasarkan kekuatan gradien (persamaan (6)), serta arah gradien (persamaan (7)). Selanjutnya, hitung *gradient threshold* T berdasarkan persamaan (8), dimana H_G disimbolkan sebagai histogram *gradient magnitude* dan presentase δ mewakili proporsi piksel tepi yang tajam (*sharp edge*). Semua *seed* yang telah ditandai sebagai *marker* baru kemudian dimasukkan ke dalam proses *watershed* untuk diproses hingga mampu mereduksi region yang *over-segmentasi* dengan label berbeda dan kontur tertutup.

$$\text{mag}(\nabla f) = \sqrt{\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2} = \sqrt{G_x^2 + G_y^2}, \quad (6)$$

$$\theta(x, y) = \arctan(G_x/G_y). \quad (7)$$

$$T_{\text{barrier}} = \left\{ \min(i) \mid \sum_{j=0}^i H_G(j) \leq 1 - \delta \right\}, \quad (8)$$

2.4 Analisis Hierarki Kluster (AHK)

Untuk menemukan persentase δ secara adaptif, penelitian ini mengusulkan pendekatan *agglomerative* yang mengambil organisasi hierarki kluster berupa level keabuan dendrogram dari histogram citra. Pada awalnya setiap level keabuan adalah kluster, kemudian masing-masing kluster dihitung jarak kemiripannya berdasarkan analisis varian inter kelas (kemiripan rata-rata dan probabilitas piksel antar kluster yang bertetangga) dan varian intra kelas (perubahan rata-rata dan probabilitas piksel saat kluster bertetangga telah bergabung), kemudian pasangan paling mirip akan bergabung menjadi kluster baru (Arifin & Asano, 2006). Untuk mengukur karakteristik setiap kluster, diperlukan fungsi kepadatan probabilitas dari setiap level keabuan histogram citra. $p(z) = h(z)/N$, dimana $p(z)$ merupakan probabilitas terjadinya piksel untuk setiap tingkat keabuan z ($z = 0, 1, \dots, L-1$) berdasarkan nilai h frekuensi banyaknya piksel terhadap tingkat keabuan z dibagi dengan N total piksel dalam citra. Fungsi $P(C_k)$ didefinisikan sebagai $\sum p(z)$ dalam kluster C_k .

Selanjutnya, jarak antara kluster C_{k1} dan C_{k2} didefinisikan dalam persamaan (9), dimana perhitungan varian inter kelas ditunjukkan pada persamaan (10), dimana $m(C_k)$ merupakan variabel rata-rata yang didefinisikan dalam persamaan (11), $M(C_{k1} \cup C_{k2})$ adalah variabel rata-rata global kluster yang didefinisikan pada persamaan (12). Sedangkan varian intra kelas adalah varian dari semua nilai piksel dari kluster saat telah bergabung. Perhitungan varian intra kelas dapat dilihat pada persamaan (13).

$$\text{Dist}(C_{k1}, C_{k2}) = \sigma_I^2(C_{k1} \cup C_{k2}) \cdot \sigma_A^2(C_{k1} \cup C_{k2}). \quad (9)$$

$$\sigma_I^2(C_{k1} \cup C_{k2}) = \frac{P(C_{k1}) \cdot P(C_{k2})}{(P(C_{k1}) + P(C_{k2}))^2} \cdot [m(C_{k1}) - m(C_{k2})]^2, \quad (10)$$

$$m(C_k) = \frac{1}{P(C_k)} \sum_{z=T_{k-1}+1}^{T_k} z p(z), \quad (11)$$

$$M(C_{k1} \cup C_{k2}) = \frac{P(C_{k1}) \cdot m(C_{k1}) + P(C_{k2}) \cdot m(C_{k2})}{P(C_{k1}) + P(C_{k2})}, \quad (12)$$

$$\sigma_A^2(C_{k1} \cup C_{k2}) = \frac{1}{P(C_{k1}) + P(C_{k2})} \times \sum_{z=T_{k1-1}+1}^{T_{k2}} \left[(z - M(C_{k1} \cup C_{k2}))^2 \right] p(z), \quad (13)$$

Dikarenakan operasi penggabungannya yang berulang, masalah *multi-level thresholding* dapat diselesaikan dengan metode ini hanya dengan mengakhiri klusterisasi ketika jumlah yang diharapkan dari nilai-nilai piksel suatu kluster atau titik potong lembah varian lokal tertentu telah diperoleh (Arifin & Asano, 2006).

2.5 Regional Credibility Merging (RCM)

RCM sebagai salah satu teknik perhitungan kemiripan region yang mengintegrasikan ketetanggaan, ukuran wilayah, nilai tepi antar wilayah bertetangga, dan ketidakmiripan tekstur-warna (Yang, dkk., 2013). Perhitungan RCM ditunjukkan pada persamaan (14), dimana fungsi ψ digunakan untuk mengecek ketetanggaan regional yang bernilai 1 apabila region bertetangga langsung. $|R_i|$ dan $|R_j|$ didefinisikan sebagai ukuran luasan masing-masing region. E_{ij} merupakan sekumpulan poin tepi dengan $(x_{i,j}^n, y_{i,j}^n)$ merepresentasikan koordinat dari ke- n poin E_{ij} dan fungsi ϕ digunakan untuk mengekstraksi tepi asli pada poin koordinat $(x_{i,j}^n, y_{i,j}^n)$. $J(R_i, R_j)$ didefinisikan untuk mengukur ketidakmiripan tekstur-warna yang memiliki dua kondisi perhitungan (R_i, R_j) seperti pada persamaan (15), yaitu standar rata-rata dan J -divergence, dimana Σ merupakan kovarian matriks, μ sebagai rata-rata vektor, dan D adalah panjang dimensi fitur tekstur-warna. Terakhir dilakukan normalisasi hasil RCM setiap pasangan region R_i dan R_j berdasarkan persamaan (16). Jika diperoleh hasil $RCMD_{i,j}^* \leq T_{RCMD}$ untuk R_i dan R_j yang bertetangga, maka R_i dan R_j dapat digabung menjadi region baru. Jika sebaliknya, maka abaikan penggabungan region.

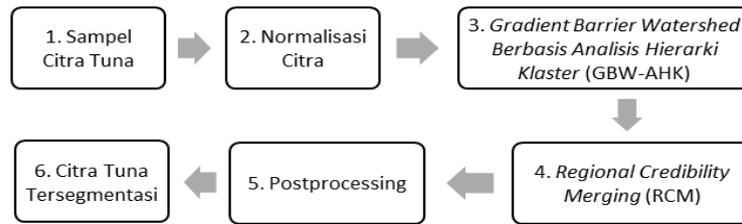
$$RCMD(R_i, R_j) = -\psi(R_i, R_j) \cdot \frac{|R_i| \cdot |R_j|}{|R_i| + |R_j|} \cdot J(R_i, R_j) \cdot \exp\left(-\frac{1}{|E_{i,j}|} \sum_{n=1}^{|E_{i,j}|} \phi(x_{i,j}^n, y_{i,j}^n)\right)^{-1}, \quad (14)$$

$$J(R_i, R_j) = \begin{cases} \left[\left(\mu_{R_i} - \mu_{R_j} \right)^T \cdot \left(\mu_{R_i} - \mu_{R_j} \right) \right]^{1/2}, & \text{jika } (|R_i| \leq R_{Min} \parallel |R_j| \leq R_{Min}) \\ \frac{1}{2} \left[\left(\text{tr}(\Sigma_{R_i} \cdot \Sigma_{R_j}^{-1} + \Sigma_{R_i}^{-1} \cdot \Sigma_{R_j}) \right) + \left(\mu_{R_i} - \mu_{R_j} \right)^T \left(\Sigma_{R_i}^{-1} \cdot \Sigma_{R_j}^{-1} \right) \left(\mu_{R_i} - \mu_{R_j} \right) - 2D \right]^{1/2}, & \text{sebaliknya} \end{cases} \quad (15)$$

$$RCMD_{i,j}^* = \left(\sum_{f=1}^K \sum_{g=1}^{|S_f|} \sum_{h=1}^{|S_{f,g}|} RCMD_{g,h} \right)^{-1} \cdot RCMD_{i,j}. \quad (16)$$

3. Metode Penelitian

Gambar 1 menunjukkan skema segmentasi tuna yang diawali dengan pengambilan sampel citra tuna berwarna. Citra ini dinormalisasi berdasarkan tiga jenis filterisasi yang kemudian disegmentasi berdasarkan kontribusi penelitian ini yaitu GBW-AHK dan RCM. Langkah-langkah GBW-AHK sebagai berikut: (1) Konversi citra normalisasi ke dalam bentuk *gradient magnitude*. (2) Dapatkan histogram *gradient magnitude*. (3) Konversi histogram ke dalam bentuk dendogram dengan memilih level keabuan n yang tidak kosong. (4) Awalnya, masing-masing level keabuan n menghasilkan m kluster. (5) Labeli masing-masing kluster $\{C_{ki} | i=1, 2, \dots, m\}$. (6) Setiap kluster C_{ki} memiliki dua kluster tetangga, sebelah kiri $C_{k(i-1)}$ dan kanan $C_{k(i+1)}$ sebagai pasangan dalam distribusi histogram. (7) Hitung kemiripan setiap kluster C_{ki} dengan pasangan ketetanggaannya, yaitu $Dist(C_{k(i-1)}, C_{ki})$ dan $Dist(C_{ki}, C_{k(i+1)})$ berdasarkan persamaan 10 dan 13. (8) Pasangan kluster dengan kemiripan tertinggi digabung. (9) Lakukan langkah 6 sampai 8 untuk seluruh kluster C_{ki} dan update jumlah m kluster C_{ki} . (10) Jika jumlah $m \neq K$ yang ditentukan oleh *user*, maka kembali ke langkah 5. Sebaliknya jika tidak, maka pilih level keabuan terakhir dari satu kluster diantara sekian kluster yang dihasilkan sebagai kandidat nilai δ . (11) Hitung $T_{barrier} = 1 - \delta$. (12) Jika intensitas *gradient magnitude* $\leq T_{barrier}$, maka pertahankan *seed*. Jika sebaliknya, maka reduksi *seed*; (13) Terakhir, ubah titik *seed* menjadi region *watershed* objek tuna. Dalam hal ini, diperlukan pengujian parameter untuk mengetahui berapa batasan jumlah kluster K yang tepat dan pemilihan *threshold* ke- C_{ki} berapa yang mendekati nilai titik potong lembah histogram citra yang sebenarnya. Untuk kasus dataset kami, *threshold* yang dapat memotong region objek dan non objek adalah saat $K=15$, dengan nilai *threshold barrier* diambil dari nilai level keabuan terakhir C_{k1} (kluster pertama) setiap citra.



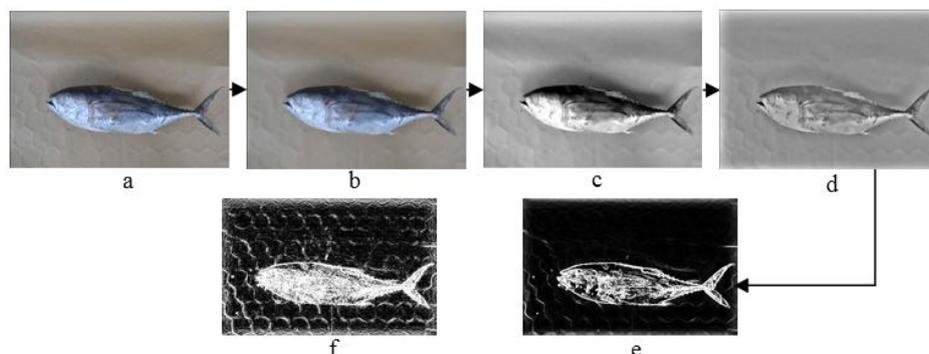
Gambar 1. Desain Sistem

Kemudian, langkah-langkah RCM sebagai berikut: (1) Labeli region *watershed*, $\{R_i | i=1,2,\dots,p\}$. (2) Urutkan label region berdasarkan luasan dari tertinggi hingga terendah dan pilih yang tertinggi sebagai kandidat awal region *background*, R_B . (3) Temukan pasangan region R_i yang bertetangga terhadap R_B . (4) Hitung normalisasi $RCMD * R_i$ terhadap R_B (persamaan 14 dan 16 dengan mengabaikan perhitungan luas area dan tepi). Fitur tekstur-warna yang digunakan dalam perhitungan vektor rata-rata dan kovarian matriks adalah LAB dengan mengambil komponen a dan b (5) Jika perhitungan $RCM \leq T_{RCMD}$, maka ubah label region R_i menjadi R_B ($relabel(R_i)=R_B$). (6) Jika sebaliknya, maka abaikan penggabungan region. Nilai T_{RCMD} yang kami gunakan sebagai batasan kemiripan adalah $4,5 \times 10^{-4}$. (7) Perbaharui label region, karena ada label yang hilang dan berubah. (8) Lakukan kembali langkah 3 sampai 7 hingga benar-benar tidak terdapat region R_i yang dapat digabung dengan R_B . (9) Ganti label sisa selain R_B menjadi region objek, R_F . (10) Pada tahapan *postprocessing*, hapus *small* region yang masih ada dengan operasi morfologi. (11) Segmentasi label R_F sebagai objek ikan tuna.

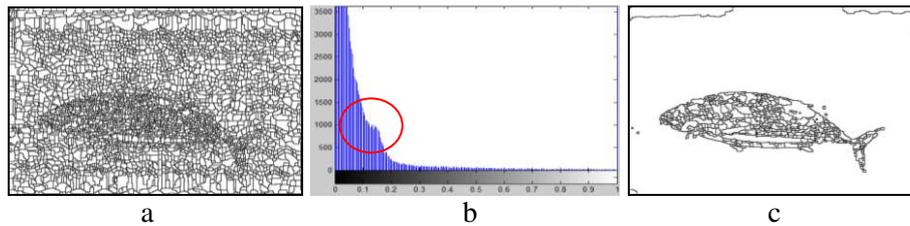
Uji coba menggunakan total 25 dataset berupa citra JPG satu objek dengan ukuran 448×299 piksel yang diperoleh dari penelitian sebelumnya (Puspita, dkk., 2015). Evaluasi hasil reduksi region yang *over-segmentasi* dilakukan dengan menghitung selisih jumlah region hasil reduksi metode GBW-AHK dengan jumlah region hasil reduksi metode GBW manual. Sedangkan evaluasi hasil segmentasi dengan melihat perbandingan nilai RAE, ME, dan MHD metode usulan (GBW-AHK dan RCM) dan kontrol (GBW manual dan RCM). RAE mengukur kesalahan jumlah perbedaan properti objek yang dihasilkan oleh sistem terhadap citra referensi. ME didefinisikan untuk mengukur kesalahan klasifikasi atau korelasi objek segmentasi sistem terhadap objek referensi dan MHD mengukur distorsi bentuk objek yang dihasilkan sistem terhadap objek referensi (Sezgin, 2004). Terakhir evaluasi efisiensi waktu metode usulan dilakukan dengan membandingkan nilai rata-rata waktu terhadap waktu metode kontrol.

4. Hasil dan Pembahasan

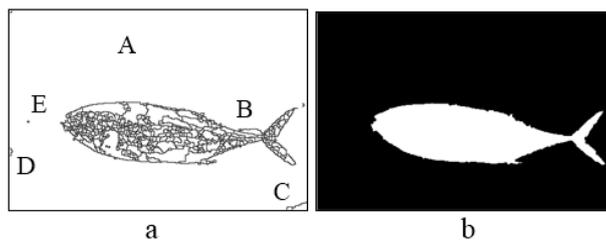
Perbedaan Gambar 2 (e) dan (f) menunjukkan bahwa filter *bilateral* dan *contrast stretching* berperan untuk menghaluskan tekstur *background* yang kasar dan meningkatkan kontras yang rendah pada citra tuna, selain juga perlunya filter *homomorphic* guna menormalkan iluminasi. Ketiga filter ini membantu untuk menghasilkan histogram *gradient magnitude* yang merepresentasikan suatu varian kluster sebagai kumpulan kekuatan tepi region-region objek.

Gambar 2. Citra (a) asli, (b) filter *bilateral*, (c) *contrast stretching*, (d) filter *homomorphic*, (e) *gradient-magnitude* hasil normalisasi, dan (f) *gradient magnitude* tanpa tahap b dan c

Gambar 3 (a) menunjukkan masih terdapat masalah *over-segmentasi watershed*, meskipun *gradient magnitude* telah dinormalisasi, sehingga diperlukan GBW-AHK untuk mereduksi region yang tidak signifikan membentuk objek tuna. Gambar 3 (b) menunjukkan bagaimana AHK saat $K=15$ mampu menghasilkan tingkat keabuan anggota terakhir C_{kl} sebagai $T_{barrier}=0,09$ yang mendekati nilai T sebenarnya untuk memotong region objek dan non objek citra yaitu 0,1, sehingga dapat menghasilkan region objek seperti yang ditunjukkan Gambar 3 (c). Sedangkan perbedaan Gambar 4 (a) dan (b) menunjukkan kemampuan RCM dan morfologi dalam mengatasi permasalahan jika masih terdapat lebih dari satu region non objek hasil GBW-AHK. Dengan pendekatan kemiripan tekstur-warna, region-region tersebut dapat digabung kembali hingga menghasilkan region objek yang tunggal.

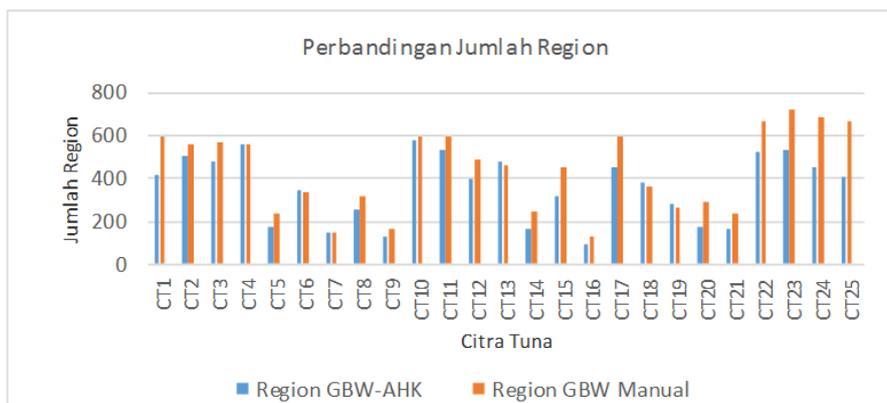


Gambar 3. Pembentukan (a) region watershed secara langsung dari *gradient magnitude*, (b) Pemilihan varian lokal yang mewakili objek dengan AHK dan (c) region hasil GBW-AHK, saat $T_{barrier}=0,09$



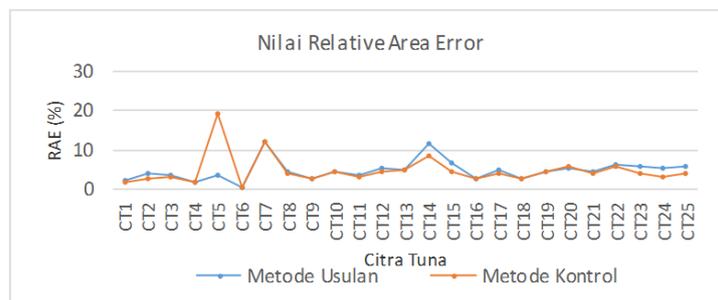
Gambar 4. (a) Region GBW-AHK yang masih terdapat *over-segmentasi*. (b) Citra biner setelah proses RCM dan morfologi

Berkaitan dengan keoptimalan reduksi region, berdasarkan Gambar 5 diperoleh fakta bahwa GBW-AHK dengan nilai $T_{barrier}$ adaptif dan bervariasi untuk masing-masing citra berhasil mereduksi region watershed yang *over-segmentasi* secara optimal bila dibandingkan dengan GBW *threshold* manual yang memilih *threshold* terendah yang sama untuk seluruh citra ($T_{statis}=0,09$). Gambar 5 menunjukkan terdapat citra CT25 dengan selisih jumlah region tertinggi. Dilihat dari selisih jumlah region untuk keseluruhan data, maka GBW-AHK berhasil memperoleh region watershed untuk seluruh citra dengan rata-rata selisih 80,4 region lebih sedikit bila dibandingkan dengan GBW *threshold* manual.



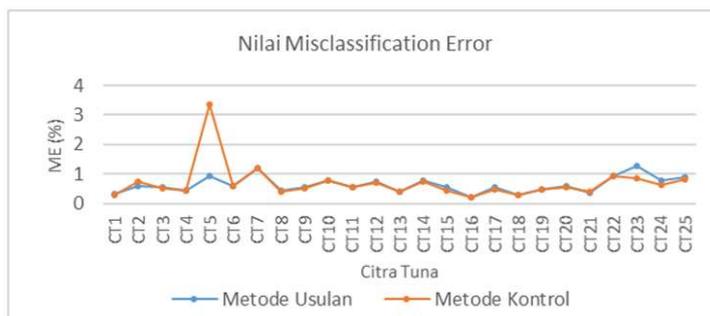
Gambar 5. Bar perbandingan jumlah region GBW-AHK dan GBW manual

Berdasarkan Gambar 6, diperoleh fakta bahwa metode usulan dan kontrol sama-sama menghasilkan segmentasi citra yang memiliki rata-rata piksel berlebih dari citra referensi (RAE) di bawah 5%. Metode usulan menghasilkan nilai rata-rata persentase RAE (*relative area error*) untuk seluruh dataset adalah 4,77%, dimana terdapat dua citra yang memiliki nilai RAE terbesar diatas 10% yaitu CT7 dan CT14. Sedangkan nilai RAE metode kontrol adalah 4,72%, dimana terdapat dua citra yang memiliki nilai RAE terbesar diatas 10% yaitu CT5 dan CT7. Dilihat dari hasil perbandingan rata-rata RAE, maka metode kontrol memiliki nilai RAE lebih kecil bila dibandingkan metode usulan. Ini disebabkan pada sebagian kecil sampel, normalisasi citra belum optimal, sehingga saat dilakukan pemilihan kluster objek dan non objek berdasarkan *threshold* adaptif GBW-AHK, maka region tepi objek yang memiliki kekuatan tepi yang hampir sama dan mirip dengan kekuatan tepi di sekitar area *background* citra dianggap sebagai satu kluster non objek yang ikut tereduksi.



Gambar 6. Grafik perbandingan nilai RAE metode usulan dan kontrol

Berdasarkan Gambar 7, diperoleh fakta bahwa metode usulan dan kontrol sama-sama menghasilkan segmentasi citra yang memiliki kesalahan klasifikasi piksel dengan citra referensi (ME) di bawah 1%. Metode usulan menghasilkan nilai rata-rata persentase ME untuk seluruh dataset adalah 0,63%, dimana terdapat dua citra yang memiliki nilai ME terbesar diatas 1% yaitu CT7 dan CT23. Sedangkan metode kontrol menghasilkan nilai rata-rata persentase ME untuk seluruh dataset adalah 0,70%, dimana terdapat dua citra yang memiliki nilai ME terbesar diatas 1% yaitu CT5 dan CT7. Dilihat dari hasil perbandingan rata-rata ME, maka metode usulan memiliki nilai ME lebih kecil bila dibandingkan metode kontrol.

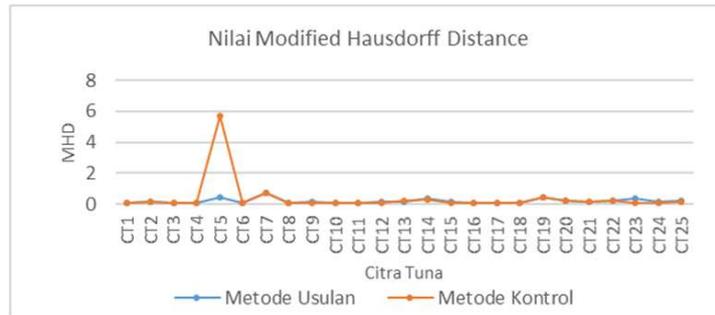


Gambar 7. Grafik perbandingan nilai ME metode usulan dan kontrol

Berdasarkan Gambar 8, diperoleh fakta bahwa metode usulan menghasilkan nilai rata-rata distorsi bentuk (MHD) segmentasi citra terhadap citra referensi untuk seluruh dataset adalah 0,20, dimana citra yang memiliki nilai MHD terbesar adalah CT7. Sedangkan metode kontrol menghasilkan nilai rata-rata MHD untuk seluruh dataset adalah 0,38, dimana terdapat citra yang memiliki nilai MHD terbesar adalah CT5. Dilihat dari hasil perbandingan rata-rata MHD, maka metode usulan memiliki nilai MHD lebih kecil bila dibandingkan metode kontrol.

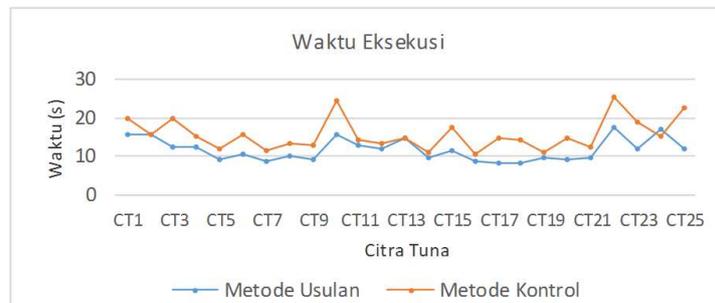
Kesalahan tertinggi (RAE, ME, dan MHD) segmentasi metode kontrol pada sampel tertentu, seperti citra CT5 membuktikan bahwa *threshold* manual dengan nilai yang statis malah

akan semakin menambah kompleksitas perhitungan RCM, karena terdapat kemungkinan banyak region sisa pada daerah *background* yang masih *over-segmentasi*. Belum lagi jika region sisa tersebut tidak dapat bergabung dengan region *background* (paling luas), karena terlihat dari sisi tekstur RCM, region itu tetap dianggap berbeda dengan region *background*. Sedangkan jika menggunakan GBW-AHK, region-region yang *over-segmentasi* dengan kekuatan tepi di bawah kekuatan minimal tepi objek secara otomatis masuk ke dalam kluster *background*, sehingga RCM tidak perlu melakukan pengecekan kemiripan terhadap region-region itu karena secara otomatis telah menjadi bagian dari region *background*. Dengan kata lain, integrasi GBW-AHK dan RCM terbukti saling mendukung untuk menghasilkan segmentasi yang lebih akurat.



Gambar 8. Grafik perbandingan nilai MHD metode usulan dan kontrol

Gambar 9 menunjukkan perbandingan rata-rata waktu eksekusi segmentasi metode usulan dan kontrol untuk seluruh dataset, dimana metode usulan menghasilkan rata-rata waktu berkisar 11,61 detik. Sedangkan nilai rata-rata waktu eksekusi metode kontrol berkisar 15,54 detik. Dari hasil perbandingan efisiensi waktu ini diperoleh fakta bahwa metode usulan lebih cepat daripada metode kontrol, sekaligus membuktikan bahwa GBW-AHK berhasil mengoptimalkan reduksi region untuk sebagian besar citra yang pada gilirannya turut membantu mempercepat proses RCM untuk melakukan penggabungan region yang tersisa.



Gambar 9. Grafik perbandingan waktu eksekusi metode usulan dan kontrol

Akan tetapi, dilihat dari rata-rata waktu eksekusi segmentasi, baik metode usulan maupun metode kontrol memiliki rata-rata eksekusi yang masih diatas 10 detik. Segmentasi yang masih dikatakan lama untuk dapat dijadikan bagian dari sistem otomatis klasifikasi ikan tua yang tidak hanya mengandalkan keakuratan, tetapi juga menuntut kecepatan dan efisiensi waktu. Lamanya proses segmentasi ini sebenarnya terjadi bukan karena kompleksitas GBW-AHK dan RCM yang tinggi dalam mengekstraksi seluruh kontur objek dari citra tuna, melainkan besarnya alokasi waktu yang dibutuhkan pada proses normalisasi, khususnya saat dilakukan penghalusan tekstur pada filter *bilateral*.

5. Kesimpulan

Integrasi GBW-AHK dan RCM menghasilkan segmentasi akurat yang mampu mengoptimalkan penentuan region objek dari citra tuna dengan nilai rata-rata RAE, ME, dan

MHD berturut-turut adalah 4,77%, 0,63% dan 0,20. Penggunaan AHK pada GBW terbukti mampu mempercepat proses RCM, sehingga mampu mengoptimalkan waktu eksekusi segmentasi dengan rata-rata waktu eksekusi adalah 11,61 detik.

6. Saran

Kesulitan dalam normalisasi citra membuat perlu adanya penelitian lebih lanjut untuk memperbaiki skema filter yang dapat mereduksi tekstur kasar pada area *background* sambil mempertahankan tekstur tepi objek secara optimal untuk seluruh citra tuna. Perlu adanya pemilihan filter normalisasi yang prosesnya tidak hanya akurat namun juga cepat, dimungkinkan pengembangan filter yang bekerja pada domain frekuensi. Termasuk menambahkan beberapa fitur tekstur-warna alternatif pada RCM, agar proses penggabungan region menjadi semakin akurat untuk seluruh data dengan tingkat variasi warna dan tekstur yang tinggi.

Referensi

- Arefin, M. G., Rahman, M. M., & Hossain, A. D. 2014. Automatically Gradient Threshold Estimation of Anisotropic Diffusion for Meyer's Watershed Algorithm Based Optimal Segmentation. *International Journal of Image, Graphics and Signal Processing (IJIGSP)*, 6(12), 26-31.
- Arifin, A. Z., & Asano, A. 2006. Image segmentation by histogram thresholding using hierarchical cluster analysis. *Pattern Recognition Letters*, 27(13), 1515-1521.
- Elad, M. 2002. On the origin of the bilateral filter and ways to improve it. *Image Processing, IEEE Transactions on*, 11(10), 1141-1151.
- Fan, C. N., & Zhang, F. Y. 2011. Homomorphic filtering based illumination normalization method for face recognition. *Pattern Recognition Letters*, 32(10), 1468-1479.
- Gauch, J. M. 1999. Image segmentation and analysis via multiscale gradient watershed hierarchies. *Image Processing, IEEE Transactions on*, 8(1), 69-79.
- Gonzalez, R. C. & Woods, R. E. Digital Image Processing. 2002. *New Jersey: Prentice Hall*, 6, 681.
- Hsieh, C. L., Chang, H. Y., Chen, F. H., Liou, J. H., Chang, S. K., & Lin, T. T. 2011. A simple and effective digital imaging approach for tuna fish length measurement compatible with fishing operations. *Computers and Electronics in Agriculture*, 75(1), 44-51.
- Ng, H. P., Huang, S., Ong, S. H., Foong, K. W. C., Goh, P. S., & Nowinski, W. L. 2008. Medical image segmentation using watershed segmentation with texture-based region merging. In *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE* (pp. 4039-4042). IEEE.
- Pregiwati, L. A. 2015. *Industri Tuna Kian Strategis*, (Online), (<http://kkp.go.id/index.php/pers/industri-tuna-indonesia-kian-strategis/>), diakses 6 September 2015).
- Puspita, S. D., Arifin, A. Z., & Khotimah, W. N. 2015. Penggunaan Multi Texton Co-occurrence Descriptor untuk Klasifikasi Ikan Tuna. *Publikasi Ilmiah Online Mahasiswa ITS (POMITS)*, 4(1), 1-6.
- Sezgin, M. 2004. Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic imaging*, 13(1), 146-168.
- Yang, H., & Ahuja, N. 2014. Automatic segmentation of granular objects in images: Combining local density clustering and gradient-barrier watershed. *Pattern Recognition*, 47(6), 2266-2279.
- Yang, Y., Han, S., Wang, T., Tao, W., & Tai, X. C. 2013. Multilayer graph cuts based unsupervised color-texture image segmentation using multivariate mixed student's t-distribution and regional credibility merging. *Pattern Recognition*, 46(4), 1101-1124.
- Yao, H., Duan, Q., Li, D., & Wang, J. 2013. An improved K-means clustering algorithm for fish image segmentation. *Mathematical and Computer Modelling*, 58(3), 790-798.
- Zhang, X., Jia, F., Luo, S., Liu, G., & Hu, Q. 2014. A marker-based watershed method for X-ray image segmentation. *Computer methods and programs in biomedicine*, 113(3), 894-903.