

Perbandingan Ruang Warna HSV dan LAB pada Klasifikasi Tingkat Roasting Biji Kopi Menggunakan Jaringan Syaraf Tiruan Backpropogation

Uswatun Hasanah¹, Sulfayanti², Nurhikma Arifin³

^{1,2,3}Informatika, Universitas Sulawesi Barat, Indonesia

Email: ¹*khazanahuswatun83@gmail.com, ²sulfayanti@unsulbar.ac.id, ³nurhikma_arifin@unsulbar.ac.id

Abstrak

Kopi menjadi salah satu jenis tanaman perkebunan yang memiliki nilai ekonomis tinggi dan telah lama dibudidayakan oleh masyarakat Indonesia, namun banyak petani dan produsen kopi masih kesulitan dalam menentukan tingkat hasil penyangraian (*roasting*) biji kopi. Oleh karena itu, penelitian ini bertujuan untuk mengklasifikasikan tingkat *roasting* biji kopi secara konsisten. Penelitian ini berfokus pada implementasi ruang warna HSV dan LAB dalam mengidentifikasi variasi warna berdasarkan tingkat *roasting* biji kopi yang diklasifikasikan menggunakan algoritma Jaringan Syaraf Tiruan (JST) Backpropogation. Klasifikasi ini terdiri dari 4 kategori kelas yaitu *green bean*, *light roast*, *medium roast* dan *dark roast*. Dataset yang digunakan mencakup 1600 citra tingkat *roasting* biji kopi yang dibagi menjadi 1200 data latih dan 400 data uji. Data latih terdiri dari 300 citra sedangkan data uji terdiri dari 100 citra untuk masing-masing tingkat kategori *roasting*. Proses eksperimen dilakukan dengan pengujian beberapa variasi parameter jaringan untuk memperoleh konfigurasi terbaik. Variasi yang diuji meliputi arsitektur jaringan 3-7-4 dan 3-8-4, fungsi aktivasi menggunakan *sigmoid* dan *softmax*, *learning rate* sebesar 0,005, 0,01, dan 0,05, serta jumlah *epoch* sebanyak 1000, 1500, dan 2000. Berdasarkan hasil pengujian, kinerja terbaik pada fitur HSV diperoleh dengan tingkat akurasi sebesar 99,25%, sedangkan fitur LAB menghasilkan akurasi tertinggi sebesar 99,75%. Hasil matriks evaluasi pada fitur LAB menghasilkan jumlah kesalahan klasifikasi yang lebih sedikit dibandingkan HSV, namun analisis statistik pada McNemar menunjukkan perbedaan tersebut tidak signifikan secara statistik dengan nilai 0,500 ($p > 0,05$). Penelitian ini menghasilkan tingkat akurasi yang tinggi pada kedua ruang warna sehingga diharapkan dapat diimplementasikan secara langsung untuk membantu petani dan produsen kopi dalam membedakan tingkat *roasting* biji kopi.

Kata Kunci: HSV; LAB; Biji Kopi Roasting; JST Backpropogation; Klasifikasi;

Abstract

Coffee is a high value cash crop that has long been cultivated by the Indonesian people; however, many coffee farmers and producers still struggle to determine the appropriate *roasting* level for coffee beans. Therefore, this study aims to consistently classify the stages of coffee bean *roasting*. This study focuses on the implementation of HSV and LAB color spaces in identifying color variations based on the *roasting* level of coffee beans classified using the Backpropagation Artificial Neural Network (ANN) algorithm. This classification consists of four categories: *green bean*, *light roast*, *medium roast*, and *dark roast*. The dataset used comprises 1,600 images of coffee bean roast levels, divided into 1,200 training data points and 400 test data points. The training data consists of 300 images, while the test data consists of 100 images for each roast level category. The experimental process involved testing several variations of network parameters to obtain the optimal configuration. The variations tested included 3-7-4 and 3-8-4 network architectures, activation functions using *sigmoid* and *softmax*, *learning rates* of 0.005, 0.01, and 0.05, and the number of *epochs* set to 1,000, 1,500, and 2,000. Based on the test results, the best kinerjance for the HSV feature was achieved with an accuracy rate of 99.25%, while the LAB feature yielded the highest accuracy of 99.75%. The evaluation matrix results for the LAB color space showed fewer classification errors compared to HSV; however, statistical analysis using the McNemar test indicated that this difference was not statistically significant, with a p-value of 0.500 ($p > 0.05$). This study yielded high accuracy rates in both color spaces, so it is expected that the results can be directly implemented to help farmers and coffee producers distinguish the roasting levels of coffee beans.

Keywords: HSV; LAB; Coffee Bean Roasting; Backpropagation Neural Network; Classification;

***Corresponding Author:**

Uswatun Hasanah, Universitas Sulawesi Barat, Indonesia

Email: khazanahuswatun83@gmail.com

1. PENDAHULUAN

Kopi merupakan salah satu komoditas pertanian yang memberikan kontribusi besar dalam penerimaan devisa negara [1]. Berdasarkan data dari Badan Pusat Statistik (BPS) tahun 2024, nilai ekspor kopi Indonesia mencapai USD 1,63 billion dengan volume sebesar 312,90 ribu ton meningkat 76,33% dibandingkan tahun 2023 yang hanya USD 917 million dengan volume sebesar 276,33 ribu ton [2]. Data dari Kementerian Pertanian tahun 2023, menunjukkan provinsi Sumatera Selatan menjadi daerah dengan kontribusi produksi kopi tertinggi di Indonesia sebesar 36,78% setara dengan rata-rata produksi 204,27 ribu ton. Provinsi Lampung dan Bengkulu berada di posisi kedua dan ketiga dengan produksi masing-masing 20,84% dan 10,96% atau rata-rata produksi 115,76 ribu ton dan 60,86 ribu ton. Produksi dari ketiga provinsi tersebut secara keseluruhan menyumbang 68,59% dari total produksi kopi nasional. Selain menjadi salah satu komoditas unggulan di sektor perkebunan, kopi juga merupakan minuman yang sangat populer di berbagai kalangan masyarakat. Berdasarkan data dari Katadata Media Network tahun 2024, konsumsi kopi di Indonesia mencapai 368,752 ribu ton pertahun. Hal ini menunjukkan bahwa kopi memiliki nilai ekonomi tinggi sehingga pengelolaan dari masa produksi hingga olahan menjadi minuman perlu dilakukan [3].

Proses mengolah biji kopi menjadi minuman dengan cita rasa dan aroma yang khas terletak pada proses *roasting* atau penyangraian [4]. *Roasting* adalah pemanasan biji kopi mentah menjadi biji kopi siap seduh. Proses ini merupakan tahap penting dalam produksi kopi karena menentukan aroma, cita rasa dan warna akhir biji kopi. Seiring dengan meningkatnya minat terhadap kopi di kalangan masyarakat, ada berbagai permasalahan yang umum ditemukan di industri rumahan terkait rasa kopi yang berbeda meskipun dari jenis yang sama. Hal ini disebabkan karena proses *roasting* dilakukan tidak konsisten sehingga mempengaruhi rasa yang dihasilkan [5].

Seiring perkembangan teknologi telah banyak dilakukan penelitian terkait klasifikasi biji kopi *roasting*. Saputra et al. [6] melakukan penelitian dengan menggunakan ekstraksi fitur warna HSV berhasil mendapatkan akurasi sebesar 100% namun penggunaan variasi dataset yang digunakan sangat sedikit. Penelitian lain dilakukan oleh Rabbani et al. [7] dengan menerapkan metode JST Backpropagation pada dua skenario pengujian, yaitu menggunakan fitur warna RGB dan HSV serta penambahan fitur tekstur LBP. Hasil penelitian menunjukkan akurasi sebesar 99,2% pada pengujian pertama dan 98,2% pada pengujian kedua. Meskipun demikian, penelitian belum mencoba ruang warna seperti *Lightness, Green to Red, dan Blue to Yellow (LAB)*.


Dalam arsitektur jaringan syaraf tiruan, beberapa penelitian terdahulu mengimplementasikan model Backpropagation untuk meningkatkan kinerja klasifikasi. Studi yang dilakukan Musdar et al. [8] dan Jamaluddin et al. [9] dengan penerapan Backpropagation dalam melakukan klasifikasi citra dengan hasil akurasi 98,33% dan 95,31%. Meskipun demikian, penerapan Backpropagation pada klasifikasi citra tingkat *roasting* biji kopi masih belum banyak dikaji secara mendalam terutama dalam hal penggunaan dan perbandingan fitur ruang warna.

Analisis literatur yang telah disebutkan sebelumnya menunjukkan bahwa klasifikasi tingkat *roasting* biji kopi telah berkembang dalam beberapa tahun terakhir, namun sebagian besar penelitian hanya fokus pada penggunaan satu jenis warna tanpa melakukan analisis perbandingan kinerja antar ruang warna secara mendalam, padahal setiap ruang warna memiliki karakteristik representasi yang berbeda dalam mengekstraksi informasi citra. Pemilihan ruang warna HSV dan LAB didasarkan pada perbedaan representasi warna yang dimiliki, sehingga dapat dilakukan analisis mengenai ruang warna yang lebih efektif dalam merepresentasikan perubahan warna biji kopi selama proses *roasting*. Kontribusi penelitian ini tidak hanya terletak pada perbandingan kinerja kedua ruang warna, tetapi juga pada analisis karakteristik representasi warna yang memengaruhi kemampuan JST Backpropagation dalam mengenali perbedaan biji kopi *roasting*. Oleh karena itu, penelitian ini dilakukan untuk mengisi gap penelitian dengan membandingkan kinerja ruang warna HSV dan LAB pada klasifikasi tingkat *roasting* biji kopi menggunakan metode JST Backpropagation.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk menerapkan metode JST Backpropagation dengan membandingkan penggunaan HSV dan LAB sebagai fitur ekstraksi warna. Penelitian ini digunakan untuk mengetahui kinerja terbaik dari kedua ruang warna dalam membedakan tingkat *roasting* biji kopi secara lebih akurat dan konsisten, sehingga dapat membantu proses identifikasi tingkat *roasting* yang selama ini masih dilakukan secara subjektif oleh petani dan pelaku usaha kopi.

2. METODE PENELITIAN

Penelitian ini menggunakan metode kuantitatif dengan pendekatan eksperimen. Penelitian dilakukan dengan membandingkan kinerja ruang warna HSV dan LAB pada proses klasifikasi tingkat *roasting* biji kopi menggunakan algoritma JST Backpropagation. Tahapan dari penelitian ini di tampilkan pada gambar 1.



Gambar 1. Tahapan penelitian


Gambar 1 menunjukkan tahapan penelitian yang diawali dengan studi literatur terkait teori dan metode yang digunakan, dilanjutkan dengan pengumpulan dataset citra tingkat *roasting* biji kopi, perancangan sistem, implementasi, pengujian algoritma, evaluasi dan analisis hasil sistem, kemudian tahap akhir adalah pembuatan laporan.

2.1. Identifikasi Masalah dan Studi Literatur

Tahap ini dilakukan dengan mengidentifikasi permasalahan yang berkaitan dengan klasifikasi tingkat *roasting* biji kopi. Selain itu, dilakukan studi literatur melalui jurnal, buku, dan penelitian terdahulu yang berhubungan dengan pengolahan citra, ruang warna HSV dan LAB, serta metode JST Backpropagation sebagai landasan teori penelitian.

2.2. Pengumpulan Data

Penelitian ini diawali dengan proses pengumpulan dataset citra tingkat *roasting* biji kopi yang diperoleh dari *website* Kaggle dengan nama [Coffee Bean] Classification with Deep Learning yang diakses pada <https://www.kaggle.com/code/emreikyurt/coffee-bean-classification-with-deep-learning>. Dataset yang digunakan terdiri dari 1600 citra yang telah dibagi dengan rasio 75:25. 1200 citra data latih (75%) dan 400 citra data uji (25%) dengan empat tahapan kategori yaitu *green bean*, *light roast*, *medium roast* dan *dark roast*. Pembagian tersebut digunakan dalam penelitian untuk mengikuti struktur dataset asli pada Kaggle, sehingga proses pelatihan dan pengujian dapat dilakukan secara konsisten sesuai dengan rancangan dataset yang telah disediakan. Sampel citra biji kopi dari keempat kategori ditampilkan pada Gambar 2 berikut.




Gambar 2. Sampel citra tingkat *roasting* biji kopi (a) *green bean*, (b) *light roast*, (c) *medium roast*, (d) *dark roast*

Gambar 2 menunjukkan citra (a) adalah sampel tahapan *roasting* yang dimulai dari *green bean* ditandai dengan permukaan biji kopi memiliki warna kehijauan dengan permukaan yang tampak kusam dan tekstur yang relatif keras. Citra (b) dikategorikan sebagai *light roast* dengan warna biji cokelat muda terang dan tampak lebih kering dan belum menunjukkan adanya minyak yang keluar dari dalam biji kopi. Citra (c) dikategorikan sebagai *medium roast* dengan biji kopi berwarna cokelat terang yang lebih pekat dibandingkan *light roast* dengan biji kopi terlihat sedikit mengkilap sedangkan untuk kategori terakhir citra (d) adalah *dark roast* yang memiliki warna cokelat tua hingga mendekati hitam, permukaan biji tampak mengkilap akibat keluarnya minyak alami yang terdorong ke luar selama proses pemanasan [10] [11] .

2.3. Perancangan Sistem

Perancangan sistem merupakan tahapan yang dilakukan untuk merancang alur kerja sistem dalam proses klasifikasi tingkat *roasting* biji kopi. Proses ini bertujuan untuk menghasilkan alur yang terstruktur sehingga sistem dapat bekerja secara optimal dalam mengenali dan mengklasifikasikan tingkat *roasting* biji kopi. Alur perancangan sistem ditunjukkan pada Gambar 3 berikut.



Gambar 3. Perancangan sistem

Gambar 3 menunjukkan diagram alir sistem klasifikasi tingkat *roasting* biji kopi menggunakan metode JST Backpropagation. Proses dimulai dari *input* citra biji kopi yang kemudian melalui tahap *preprocessing* dan *object segmentation* yang masih merupakan bagian dari *preprocessing*, namun berfokus pada pemisahan objek biji kopi dari *background*. Selanjutnya dilakukan ekstraksi fitur warna menggunakan ruang warna HSV dan LAB untuk memperoleh karakteristik warna citra. Fitur yang

dihasilkan kemudian dinormalisasi dan digunakan sebagai data masukan pada proses pelatihan JST Backpropagation untuk membentuk model klasifikasi. Model yang telah diperoleh kemudian digunakan pada tahap pengujian. Hasil pengujian selanjutnya dievaluasi menggunakan *confussion matrix* dalam menentukan *output* kategori tingkat *roasting* biji kopi. Secara rinci proses pada Gambar 3 dijelaskan sebagai berikut.

2.2.1 Preprocessing Data

Tahap *preprocessing* data dilakukan untuk mempersiapkan citra sebelum memasuki proses segmentasi dan ekstraksi fitur. Dataset citra yang diperoleh dari Kaggle telah memiliki ukuran yang seragam, yaitu 224x224 piksel sehingga tidak memerlukan proses *resize*. Selanjutnya dilakukan penyesuaian format warna dari BGR ke RGB untuk ke tahap *object segmentation*.

2.2.2 Object Segmentation

Tahap *object segmentation* dilakukan untuk memisahkan objek tingkat *roasting* biji kopi dari *background* sehingga proses pengolahan citra berfokus pada area objek. Tahapan dari proses ini terdiri empat langkah yang dilakukan sebagai berikut:

1. Konversi Ruang Warna HSV
Citra dikonversi dari RGB ke HSV dengan tujuan untuk mempermudah proses pemisahan objek berdasarkan karakteristik warna.
2. *Thresholding*
Setelah citra berada pada ruang warna HSV, dilakukan proses pemisahan objek dan *backgorund* menggunakan metode *thresholding* melalui fungsi *inRange()*. Pada tahap ini ditentukan nilai batas bawah (*lower thresholding*) dan batas atas (*upper thresholding*) pada ruang warna *Hue*, *Saturation*, dan *Value* [12]. Rentang nilai tersebut digunakan untuk membentuk *mask* yang berfungsi menyeleksi piksel objek tingkat *roasting* biji kopi.
3. Operasi Morfologi
Hasil segmentasi dari *thresholding* masih memiliki *noise* sehingga menghasilkan citra yang belum sempurna. Oleh karena itu, dilakukan proses perbaikan menggunakan *closing* (*Morphological Closing*) dan *Hole filling*. *Closing* dilakukan dengan proses dilasi kemudian diikuti erosi dengan menutup celah kecil, menghubungkan bagian objek yang terpisah, serta mengurangi *noise* pada hasil segmentasi sedangkan *Hole filling* adalah pengisian area kosong atau lubang (*hole*) yang terdapat di dalam objek.
4. *Masking*
Proses *masking* dilakukan dengan memanfaatkan citra biner hasil segmentasi sebagai penanda (*mask*) untuk mempertahankan bagian objek utama. Hasil *masking* menghasilkan citra objek tingkat *roasting* biji kopi yang lebih fokus ke objek sehingga proses ekstraksi fitur dapat dilakukan dengan lebih optimal.
5. Hasil Segmentasi
Hasil akhir *object segmentation* berupa citra objek biji kopi yang telah terpisah dari *background*. Citra hasil segmentasi selanjutnya dikonversi dari ruang warna RGB ke HSV dan RGB ke LAB untuk digunakan pada tahap ekstraksi fitur warna.

2.2.3 Ekstraksi Fitur Warna

Tahap ekstraksi fitur dilakukan untuk mendapatkan informasi warna dari citra hasil segmentasi. Nilai fitur didapatkan dari rata-rata setiap komponen warna pada citra hasil segmentasi. Pada tahap ini ada tiga ruang warna yang digunakan yaitu RGB, HSV dan LAB.

1. Citra RGB
Ruang warna RGB (*Red*, *Green*, *Blue*) merupakan warna dasar yang merepresentasikan kombinasi tiga kanal warna utama yaitu merah (*Red*), Hijau (*Green*), dan biru (*Blue*). Setiap kanal memiliki rentang nilai 0-255. Nilai didapatkan dengan menghitung nilai rata-rata dari masing-masing kanal warna [13]. Rumus normalisasi RGB ditunjukkan pada persamaan (1) berikut.

$$r = \frac{R}{255} \quad g = \frac{G}{255} \quad b = \frac{B}{255} \quad (1)$$

Keterangan : r adalah komponen normalisasi dari nilai R (*red*), g adalah nilai G (*green*), dan b adalah komponen normalisasi dari nilai B (*blue*).

2. Citra HSV

HSV merupakan singkatan dari *Hue*, *Saturation* dan *Value*. *Hue* mengacu pada ruang warna merah menuju hijau, *saturation* mengacu pada ruang warna dari merah ke merah muda, sedangkan *value* yang merupakan intensitas cahaya yang mengacu pada warna hitam ke putih [14]. Rumus mendapatkan nilai HSV dari nilai RGB ditunjukkan pada persamaan (2), (3) dan (4) berikut.

$$V = \max(r, g, b) \quad (2)$$

$$S = \begin{cases} 0, & \text{jika } value = 0 \\ \left(\frac{\max - \min}{\max} \right), & \text{jika lainnya} \end{cases} \quad (3)$$

$$H = \begin{cases} 60^\circ \times \left(\frac{G-B}{\max - \min} \right), & \max = R \\ 60^\circ \times \left(\frac{B-R}{\max - \min} + 2 \right), & \max = G \\ 60^\circ \times \left(\frac{R-G}{\max - \min} + 4 \right), & \max = B \end{cases} \quad (4)$$

Keterangan : r , g , dan b adalah hasil komponen normalisasi dari nilai *red*, *green*, dan *blue*. Nilai V didapatkan dari komponen warna maksimum, S menunjukkan tingkat kejenuhan warna, sedangkan H merepresentasikan corak warna yang nilainya dihitung berdasarkan komponen RGB dengan nilai maksimum.

3. Citra LAB

LAB adalah ruang warna yang mendekati persepsi visual manusia yang memisahkan informasi kecerahan (L^*) dari informasi warna (a^* dan b^*) [15], Rumus mendapatkan nilai LAB ditunjukkan pada persamaan (5), (6), dan (7) berikut.

$$L^* = 116f\left(\frac{Y}{Y_n}\right) - 16 \quad (5)$$

$$a^* = 500 \left[f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right] \quad (6)$$

$$b^* = 200 \left[f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right] \quad (7)$$

Keterangan: L^* merupakan komponenn *Lightness* yang menunjukkan tingkat kecerahan warna dengan retang nila 0-100. Nilai a^* merepresentasikan ruang warna hijau-merah (*green-red axis*), sedangkan b^* merujuk pada ruang warna biru-kuning (*blue-yellow axis*). Nilai X , Y , dan Z adalah komponen pada ruang warna CIE XYZ, sedangkan X_n , Y_n , dan Z_n merupakan nilai referensi warna putih (*reference white point*). Fungsi f digunakan sebagai fungsi transformasi non linear dalam proses konversi ruang warna XYZ ke LAB.

2.4. Implementasi

Tahap implementasi dilakukan dengan menerapkan rancangan sistem ke dalam program menggunakan bahasa pemrograman Python. Implementasi mencakup proses pengolahan citra, ekstraksi fitur warna, normalisasi data, pelatihan model JST Backpropagation, serta proses klasifikasi tingkat *roasting* biji kopi.

2.5. Metode JST Backpropagation

Jaringan Syaraf Tiruan (JST) adalah pemrosesan komputasi yang tercipta dari cara kerja sistem saraf biologis manusia. JST mampu mengenali kegiatan dengan berbasis data pada masa lalu. Data masa lalu akan dipelajari oleh JST sehingga mampu memiliki kemampuan untuk memberi keputusan terhadap data yang belum pernah dipelajari [16].

Backpropagation merupakan salah satu algoritma pembelajaran terawasi pada jaringan saraf tiruan *multilayer* yang digunakan untuk memperbarui bobot pada setiap *output* di lapisan tersembunyi maupun lapisan keluaran[17]. Dalam impelementasinya, arsitektur dan *hyperparameter* yang digunakan dalam penelitian ini ada empat yaitu, *Hidden Output Layer*, Fungsi Aktivasi, *Learning rate*, dan *Epoch*. Arsitektur jaringan dan parameter yang telah ditentukan selanjutnya diterapkan pada proses pelatihan

JST Backpropagation. Proses pelatihan tersebut terdiri atas tiga tahapan utama, yaitu perambatan maju (*forward propagation*), perambatan balik (*backpropagation*), serta perubahan bobot dan bias [18].

Tahap pertama adalah *forward propogation* yang mana setiap *output* menerima masukan yang dikalikan dengan bobot dan ditambahkan bias untuk menghasilkan keluaran yang ditunjukkan pada persamaan (8) dan (9) berikut.

$$net_j = \sum_{i=1}^n x_i w_{ij} + b_j \quad (8)$$

$$y_j = f(net_j) \quad (9)$$

Keterangan: x_i adalah data masukan *output*, w_{ij} adalah bobot koneksi yang menentukan besar pengaruh data masukan terhadap *output* tujuan, dan b_j merupakan bias yang digunakan untuk menyesuaikan proses pembelajaran jaringan. Nilai net_j menentukan total masukan yang diperoleh, selanjutnya f merupakan fungsi aktivasi yang digunakan untuk memproses nilai masukan sehingga menghasilkan keluaran *output*, sedangkan y_j merupakan hasil kelaoran *output* yang akan diteruskan ke lapisan berikutnya atau digunakan sebagai hasil akhir jaringan.

Tahap kedua adalah Backpropogation yang dilakukan dengan menghitung nilai kesalahan (*error*) antara keluaran jaringan dan target yang diharapkan. Nilai *error* akan digunakan sebagai dasar untuk perbaikan bobot jaringan yang ditunjukkan pada persamaan (10) berikut.

$$e_k = t_k - y_k \quad (10)$$

Keterangan: e_k merupakan nilai *error* yang didapatkan dari selisih anatara target keluaran dan hasil keluaran jaringan, t_k adalah nilai target yang diharapkan, sedangkan y_k meruapakan hasil keluaran jaringan.

Tahap ketiga adalah tahap perubahan bobot dan bias yang dilakukan dengan memperbarui nilai bobot agar kesalahan jaringan menjadi kecil pada iterasi berikutnya. Rumus perubahan bobot dan bias ditunjukkan pada persamaan (11) dan (12) berikut.

$$\Delta w_{ij} = \alpha \delta_j x_i \quad (11)$$

$$w_{ij}(\text{baru}) = w_{ij}(\text{lama}) + \Delta w_{ij} \quad (12)$$

Keterangan: Δw_{ij} merupakan nilai perubahan bobot, α adalah *learning rate* yang mengatur besar pembaruan bobot, δ_j merupakan faktor koreksi kesalahan, x_i adalah masukan *output*, dan w_{ij} merupakan bobot baru hasil pembaruan.

Pada penelitian ini arsitektur dan *hyperparameter* yang digunakan yaitu:

1. Penelitian ini menerapkan dua arsitektur jaringan pada satu *Hidden layer* yaitu, 3-7-4 dan 3-8-4.
2. Fungsi Aktivasi yang digunakan ada dua, *sigmoid* pada lapisan tersembunyi dan fungsi aktivasi *softmax* pada lapisan keluaran.
3. Variasi nilai *learning rate* yang digunakan meliputi 0,005, 0,01, dan 0,05.
4. Jumlah *epoch* atau iterasi yang digunakan adalah 1000, 1500, dan 2000.

2.6. Matriks Evaluasi

Evaluasi dilakukan untuk menilai kinerja model dalam mengklasifikasikan data secara tepat. Pada penelitian ini, pengukuran kinerja model dilakukan menggunakan *confussion matrix*. *Confussion matrix* merupakan metode evaluasi yang digunakan untuk membandingkan hasil prediksi model dengan kelas sebenarnya [19]. Terdapat empat komponen utama dalam *confussion matrix*, yaitu *True Positive* (TP), *True Negatif* (TN), *False Positive* (FP), dan *False Negatif* (FN). Nilai TP menunjukkan jumlah data yang berhasil diklasifikasikan dengan benar sebagai kelas positif, TN menunjukkan jumlah data kelas negatif yang diprediksi dengan benar, FP menunjukkan data negatif yang salah diprediksi sebagai positif, sedangkan FN menunjukkan data positif yang salah diklasifikasikan sebagai negatif. Setelah mendapatkan nilai dari *confussion matrix*, dilakukan perhitungan matriks evaluasi, yaitu *accuracy*, *precision*, *recall*, dan *F1-Score*.

1. *Accuracy* (Akurasi)

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (13)$$

Accuracy mengukur tingkat ketepatan model dalam mengklasifikasikan seluruh data. Nilai akurasi didapatkan dari perbandingan jumlah prediksi yang benar terhadap total data yang telah diuji.

2. *Precision* (Presisi)

$$Precision = \frac{TP}{TP+FP} \quad (14)$$

Precision mengukur hasil prediksi model pada suatu kelas. Nilai presisi menunjukkan seberapa banyak data yang diprediksi ke dalam suatu kelas benar-benar termasuk pada kelas tersebut.

3. *Recall* (Sensitivity)

$$Recall = \frac{TP}{TP+FN} \quad (15)$$

Recall mengukur kemampuan model dalam mengenali seluruh data yang termasuk ke dalam suatu kelas.

4. *F1-Score*

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (16)$$


F1-Score merupakan matriks yang menggabungkan nilai *precision* dan *recall*. Matriks ini digunakan untuk memberikan evaluasi yang lebih seimbang terhadap kinerja model klasifikasi.

3. HASIL DAN PEMBAHASAN

Penelitian ini dilakukan dengan membandingkan ruang warna HSV dan LAB dalam mengklasifikasikan tingkat *roasting* biji kopi menggunakan model Jaringan Syaraf Tiruan dengan algoritma Backpropagation. Hasil setiap penelitian ini.

3.1. Pengolahan Citra dan Segmentasi


Proses pengolahan citra dan segmentasi bertujuan menghasilkan citra objek yang siap digunakan pada tahap ekstraksi fitur. Beberapa proses yang dilakukan pada tahap ini yaitu, konversi dan transformasi ruang warna HSV, *thresholding*, operasi morfologi dan *masking*. Tujuan dari tahapan ini adalah memisahkan objek tingkat *roasting* biji kopi dari *background* sehingga informasi warna yang digunakan pada proses klasifikasi hanya berasal dari area objek. Hasil pengolahan citra dan segmentasi pada ruang warna HSV dan LAB menggunakan sampel citra *medium roast* ditunjukkan pada Gambar 4 berikut.



Gambar 4. Proses *object segmentation* (a) citra asli, (b) HSV, (c) *thresholding*, (d) operasi morfologi, (e) *masking*, (f) hasil segmentasi

Berdasarkan gambar 4, proses pengolahan citra dan segmentasi dilakukan melalui beberapa tahapan. Tahap awal menggunakan citra asli seperti ditunjukkan pada Gambar 4 (a) yang kemudian dikonversi ke ruang warna HSV pada Gambar 4 (b). Penggunaan ruang warna HSV bertujuan mempermudah proses pemisahan objek karena memisahkan komponen warna (*Hue*), kejenuhan (*Saturation*), dan intensitas (*Value*). Selanjutnya dilakukan proses *color thresholding* menggunakan rentang nilai HSV untuk membentuk *mask* objek seperti ditunjukkan pada Gambar 4 (c). Hasil segmentasi awal menunjukkan objek biji kopi telah berhasil dipisahkan dari *background*, namun masih terdapat *noise* dan area kosong pada beberapa bagian objek. Proses untuk memperbaiki hasil segmentasi, dilakukan operasi morfologi pada Gambar 4 (d). Tahapan tersebut menghasilkan objek yang lebih utuh dan mengurangi *noise* di sekitar area objek. Selanjutnya, proses *masking* pada Gambar 4 (e) menghasilkan *mask* yang membedakan objek dan *background*. Gambar 4 (f) menunjukkan hasil akhir citra setelah segmentasi.

Hasil segmentasi kemudian dikonversi ke dalam ruang warna HSV dan LAB yang ditunjukkan pada Gambar 5 dan 6. Hasil konversi menghasilkan nilai ekstraksi fitur yang merepresentasikan karakteristik warna setiap citra. Hasil ekstraksi fitur warna HSV dan LAB ditampilkan pada Tabel 1 dan 2.




Gambar 5. Hasil segmentasi HSV sampel citra tingkat *roasting* biji kopi (a) *green bean*, (b) *light roast*, (c) *medium roast*, (d) *dark roast*

Tabel 1. Sampel Hasil Ekstraksi Fitur Warna HSV

Kategori	H _{mean}	S _{mean}	V _{mean}
<i>Green bean</i>	26.018	117.504	97.243
<i>Light roast</i>	22.591	103.622	149.057
<i>Medium roast</i>	15.706	143.308	71.404
<i>Dark roast</i>	13.399	102.553	57.284

Gambar 5 menunjukkan hasil segmentasi ruang warna HSV pada setiap sampel tingkat *roasting* biji kopi, yaitu *green bean*, *light roast*, *medium roast*, dan *dark roast*. Hasil segmentasi berhasil memisahkan objek biji kopi dari *background* sehingga informasi warna yang diperoleh hanya berasal dari area objek. Citra hasil segmentasi kemudian digunakan pada proses ekstraksi fitur warna seperti pada Tabel 1 untuk memperoleh nilai rata-rata (*mean*) dari komponen *Hue* (H), *Saturation* (S), dan *Value* (V).



Gambar 6. Hasil segmentasi LAB sampel citra tingkat *roasting* biji kopi (a) *green bean*, (b) *light roast*, (c) *medium roast*, (d) *dark roast*

Tabel 2. Sampel Hasil Ekstraksi Fitur Warna LAB

Kategori	L* _{mean}	a* _{mean}	b* _{mean}
<i>Green bean</i>	97.655	124.545	149.961
<i>Light roast</i>	130.147	130.440	161.865
<i>Medium roast</i>	61.581	132.169	143.232
<i>Dark roast</i>	52.132	130.390	135.185

Gambar 6 menampilkan hasil segmentasi pada ruang warna LAB pada setiap sampel tingkat *roasting* biji kopi. Citra kemudian digunakan pada ekstraksi fitur untuk mendapatkan *mean* dari komponen L*, a*, dan b* seperti pada Tabel 2, nilai hasil ekstraksi selanjutnya dinormalisasi untuk menyamakan rentang nilai setiap fitur sehingga proses pelatihan model dapat berjalan lebih optimal dan stabil pada metode JST Backpropagation.

3.2. Hasil Normalisasi Fitur Warna

Data citra biji kopi *roasting* yang telah melalui tahap segmentasi kemudian direpresentasikan menggunakan fitur warna HSV dan LAB. Nilai fitur selanjutnya dinormalisasi menggunakan metode *StandardScaler* dengan tujuan untuk menyamakan skala antar fitur sehingga dapat meningkatkan efektivitas proses pembelajaran model jaringan. Hasil normalisasi fitur warna HSV dan LAB ditunjukkan pada Tabel 3 dan 4 berikut.

Tabel 3. Sampel Hasil Normalisasi Fitur Warna HSV dan LAB Citra Pelatihan

Data Latih	H	S	V	L*	a*	b*	Label
<i>Green bean</i>							
Data Latih ke-1	1.902	-0.419	-0.122	0.218	-1.883	0.134	0
Data Latih ke-2	1.016	-0.852	1.637	1.818	-1.112	0.420	0
Data Latih ke-3	1.931	-0.597	0.259	0.610	-1.954	0.090	0
<i>Light roast</i>							
Data Latih ke-1	0.678	0.637	1.476	1.364	-0.187	1.594	1
Data Latih ke-2	0.978	0.573	1.319	1.208	-0.161	1.393	1
Data Latih ke-3	0.211	1.032	1.005	0.765	0.759	1.384	1
<i>Medium roast</i>							
Data Latih ke-1	-0.482	0.519	-0.177	-0.313	0.806	0.069	2
Data Latih ke-2	-0.655	0.533	-0.069	-0.241	1.029	0.012	2
Data Latih ke-3	-0.390	0.645	-0.240	-0.349	0.539	0.058	2
<i>Dark roast</i>							
Data Latih ke-1	-0.411	-1.450	-1.444	-1.348	-0.099	-1.489	3
Data Latih ke-2	-1.361	-0.886	-1.478	-1.388	-0.176	-1.429	3
Data Latih ke-3	-1.025	-1.106	-1.219	-1.116	-1.184	-1.301	3

Tabel 4. Sampel Hasil Normalisasi Fitur Warna HSV dan LAB Citra Pengujian

Data Latih	H	S	V	L*	a*	b*	Label
<i>Green bean</i>							
Data Uji ke-1	1.643	-0.849	-0.778	1.168	-1.968	0.261	0
Data Uji ke-2	1.512	-0.189	0.046	0.364	-1.797	0.250	0
Data Uji ke-3	1.729	-0.843	1.128	1.527	-2.133	0.492	0
<i>Light roast</i>							
Data Uji ke-1	0.239	0.970	0.607	0.403	0.661	1.107	1
Data Uji ke-2	0.356	0.940	0.804	0.658	0.297	1.273	1
Data Uji ke-3	0.413	0.748	0.787	0.693	-0.012	1.159	1
<i>Medium roast</i>							
Data Uji ke-1	-0.512	0.661	-0.433	0.666	-0.053	-0.433	2
Data Uji ke-2	-0.733	0.393	-1.093	0.343	-0.590	-1.093	2
Data Uji ke-3	-0.602	0.216	-0.745	0.493	-0.441	-0.745	2
<i>Dark roast</i>							
Data Uji ke-1	-1.272	-0.879	-1.509	-1.431	-0.171	-1.428	3
Data Uji ke-2	-0.839	-1.253	-1.269	-1.158	-0.193	-1.439	3
Data Uji ke-3	-0.137	-1.701	-1.188	-1.039	-0.194	-1.579	3

Pada Tabel 3 dan 4, hasil nilai normalisasi selanjutnya dijadikan sebagai data masukan pada proses klasifikasi menggunakan metode JST Backpropagation. Data hasil normalisasi digunakan sebagai *output* pada lapisan masukan (*input layer*), sedangkan label tingkat *roasting* biji kopi digunakan sebagai target keluaran yang akan dipelajari oleh jaringan selama proses pelatihan dan pengujian.

3.3. Hasil Pelatihan Model JST Backpropagation


Pelatihan dilakukan menggunakan data latih sebanyak 1200 citra yang dibagi 300 untuk setiap kategori *roasting* yaitu *green bean*, *light roast*, *medium roast*, dan *dark roast*. Model JST dibangun dengan arsitektur *input layer*, *Hidden layer*, dan *output layer*. Jumlah *output* pada *input layer* menyesuaikan jumlah fitur yang digunakan, yaitu 3 *output* untuk fitur HSV (H, S, V) dan 3 *output* untuk fitur LAB (L*, a*, b*), sedangkan *output layer* terdiri dari 4 *output* yang merepresentasikan kelas *roasting*. Dalam proses

pelatihan, beberapa kombinasi *hyperparameter* diuji untuk memperoleh kinerja terbaik. Fungsi aktivasi yang digunakan meliputi *sigmoid* dan *softmax*, *Hidden Output* yang diuji adalah 7 dan 8. Jumlah *epoch* yang diuji adalah 1000, 1500, dan 2000 sedangkan nilai *learning rate* yang diuji adalah 0,005, 0,1, dan 0,05. Hasil pelatihan model ditunjukkan pada Tabel 5 berikut.

Tabel 5. Hasil Pelatihan Model

Arsitektur	Learning rate	Epoch	Akurasi Pelatihan	
			HSV	LAB
3-7-4	0,005	1000	98,83%	98,83%
	0,01		98,25%	99,08%
	0,05		98,00%	96,75%
	0,005	1500	98,91%	98,91%
	0,01		98,33%	99,16%
	0,05		97,91%	96,83%
	0,005	2000	98,91%	98,91%
	0,01		98,33%	99,08%
	0,05		98,25%	96,75%
3-8-4	0,005	1000	98,83%	99,08%
	0,01		99,00%	99,00%
	0,05		96,83%	96,50%
	0,005	1500	98,91%	99,41%
	0,01		99,00%	99,25%
	0,05		98,33%	96,75%
	0,005	2000	98,91%	99,41%
	0,01		99,00%	99,08%
	0,05		98,50%	96,50%

Tabel 5 menunjukkan parameter yang digunakan adalah kombinasi terbaik dari pengujian yang dilakukan pada proses pelatihan. Arsitektur jaringan dituliskan dalam bentuk 3-7-4 dan 3-8-4, di mana angka pertama menunjukkan jumlah *output* pada *input layer*, angka kedua menunjukkan jumlah *output* pada *Hidden layer*, dan angka terakhir menunjukkan jumlah *output* pada *output layer*. Pada fitur HSV, arsitektur 3-8-4 dengan *learning rate* 0,01 dan *epoch* 1000, 1500, dan 2000 menghasilkan akurasi pelatihan tertinggi sebesar 99,00%, lebih tinggi dibandingkan arsitektur 3-7-4 yang memperoleh akurasi 98,91%. Sementara fitur LAB, arsitektur 3-8-4 dengan *learning rate* 0,005 dan *epoch* 1500 dan 2000 menghasilkan akurasi sebesar 99,41%.



Gambar 7. Grafik training accuracy dan loss

Gambar 7 adalah model JST Backpropagation yang menunjukkan proses pembelajaran yang baik selama pelatihan. Nilai *accuracy* mengalami peningkatan secara signifikan pada awal *epoch* hingga mendekati 1,0 atau 100%, sedangkan nilai *loss* mengalami penurunan secara bertahap hingga mendekati angka 0.

3.4. Hasil Pengujian Model

Pengujian model dilakukan menggunakan 400 data uji yang dibagi 100 untuk masing-masing kategori *roasting*. Pengujian menggunakan model pelatihan sebelumnya, kemudian dievaluasi menggunakan *confussion matrix* serta matriks evaluasi yang ditunjukkan pada Tabel 6 berikut.


Tabel 6. Hasil Pengujian Model

Arsitektur	Learning rate	Epoch	Akurasi Pelatihan	
			HSV	LAB
3-7-4	0,005	1000	98,75%	98,75%
	0,01		97,50%	99,25%
	0,05		97,50%	96,50%
	0,005	1500	99,00%	99,00%
	0,01		97,50%	99,25%
	0,05		97,25%	96,75%
	0,005	2000	99,00%	99,00%
	0,01		98,00%	99,00%
	0,05		97,50%	96,75%
3-8-4	0,005	1000	99,00%	99,25%
	0,01		99,00%	99,25%
	0,05		96,25%	95,75%
	0,005	1500	99,00%	99,75%
	0,01		99,00%	99,50%
	0,05		98,00%	96,50%
	0,005	2000	99,25%	99,75%
	0,01		99,00%	99,00%
	0,05		98,25%	96,00%


Tabel 6 menunjukkan kombinasi parameter *learning rate*, *epoch*, dan jumlah output *Hidden layer* memengaruhi hasil akurasi pengujian pada kedua jenis fitur. Secara umum, fitur LAB memberikan kinerja yang lebih tinggi dibandingkan HSV, dengan akurasi tertinggi sebesar 99,75% pada arsitektur 3-8-4 dengan *learning rate* 0,005 pada *epoch* 1500 dan 2000. Sementara itu, fitur HSV memperoleh akurasi tertinggi sebesar 99,25% pada arsitektur 3-8-4 dengan *learning rate* 0,005 dan *epoch* 2000, namun nilainya masih berada di bawah fitur LAB. Selain itu, penggunaan *learning rate* 0,05 pada kedua arsitektur cenderung menurunkan akurasi pengujian, terutama pada fitur LAB dengan *epoch* 1000 yang hanya mencapai 95,75%, sehingga menunjukkan bahwa *learning rate* yang terlalu besar dapat menyebabkan proses pengujian kurang stabil.

3.5. Hasil Evaluasi

Hasil *confussion matrix* pengujian fitur HSV dan LAB yang ditunjukkan pada Gambar 8 dan 9 berikut.






Gambar 8. Confussion matrix HSV




Gambar 9. Confussion matrix LAB

Confussion matrix pada Gambar 8 menunjukkan pada fitur HSV dengan akurasi 99,25%, kesalahan klasifikasi terjadi pada kelas *medium roast* yang salah prediksi 1 citra sebagai *light roast* dan 2 citra sebagai *dark roast*, sedangkan pada fitur LAB dengan akurasi 99,75%, kesalahan klasifikasi terjadi pada kelas *medium roast* yang salah prediksi 1 citra sebagai *light roast*. Hasil kesalahan prediksi citra dari *confussion matrix* fitur HSV dan LAB ditunjukkan pada Tabel 7 dan 8 berikut.

Tabel 7. Kesalahan Prediksi Fitur HSV

RGB	HSV	Aktual	Prediksi
Data Uji 11			
		Medium roast	Dark roast
Data Uji 67			
		Medium roast	Dark roast
Data Uji 76			
		Medium roast	Light roast

Tabel 8. Kesalahan Prediksi Fitur LAB

RGB	LAB	Aktual	Prediksi
Data Uji 76			
		Medium roast	Light roast

Tabel 7 menunjukkan citra yang salah diprediksi menggunakan fitur HSV, pada data uji 11 dan 76, citra *medium roast* diprediksi sebagai *dark roast* karena memiliki intensitas warna yang lebih gelap dan tingkat kecerahan yang rendah, karakteristik tersebut menyebabkan citra memiliki kemiripan dengan pola warna yang dimiliki oleh kelas *dark roast* sehingga model mengelompokkannya ke dalam kelas tersebut. Sementara itu, data uji 76 diprediksi sebagai *light roast* karena memiliki tingkat kecerahan yang lebih tinggi sehingga karakteristik warnanya mendekati kelas *light roast*. Pada Tabel 8 kesalahan prediksi fitur LAB terletak pada data uji 76 sama dengan HSV, kesalahan terjadi karena citra memiliki nilai komponen *lightness* (L^*) yang tinggi dibandingkan citra lain pada kelas *medium roast*, tingkat kecerahan yang lebih tinggi menyebabkan karakteristik warna citra menjadi lebih mendekati kelas *light roast*. Hasil evaluasi dengan akurasi tertinggi untuk HSV dan LAB ditunjukkan pada Tabel 9 berikut.

Tabel 9. Evaluasi Hasil Pengujian Model

Fitur	Akurasi Pengujian	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
HSV	99,25%	99,26%	99,25%	99,25%
LAB	99,75%	99,75%	99,75%	99,75%

Tabel 9 menunjukkan bahwa fitur LAB menghasilkan kinerja evaluasi yang lebih tinggi dibandingkan HSV pada seluruh matriks pengujian. Fitur LAB memperoleh nilai *precision*, *recall*, dan *F1 score* sebesar 99,75% menunjukkan model mampu mengklasifikasikan seluruh data dengan baik. Sementara itu, fitur HSV juga memberikan hasil yang tinggi dengan nilai *precision* 99,26%, *recall*, dan *F1 score* sebesar 99,25%, namun masih sedikit berada di bawah fitur LAB. Berdasarkan hasil evaluasi pengujian model, selanjutnya dilakukan analisis statistik menggunakan McNemar pada aplikasi SPSS untuk mengetahui apakah ada perbedaan secara signifikan berdasarkan uji statistik yang ditunjukkan pada Gambar 10 berikut.

HSV * LAB Crosstabulation						
Count		LAB		Total	Value	Exact Sig. (2-sided)
HSV	0	1	2	3	McNemar Test	.500 ^a
	1	0	397	397		
Total		1	399	400	N of Valid Cases	400

a. Binomial distribution used.


Gambar 10. Hasil uji statistik McNemar

Hasil uji McNemar yang dilakukan menggunakan hasil klasifikasi pada data uji yang sama. Hasil pengujian menunjukkan nilai statistik McNemar sebesar 0,500 dengan nilai $p > 0,05$. Hasil tersebut menunjukkan bahwa perbedaan akurasi antara HSV (99,25%) dan LAB (99,75%) tidak signifikan secara statistik pada taraf signifikansi 5%.

Perolehan nilai akurasi pengujian yang tetap tinggi pada fitur HSV dan LAB dan mendekati akurasi pelatihan menunjukkan bahwa model mampu mempertahankan kinerjanya pada data yang tidak digunakan selama proses pelatihan. Dengan demikian, tidak ditemukan indikasi kuat bahwa model hanya menghafal data pelatihan (*overfitting*). Tingginya *performa* akurasi yang diperoleh juga dipengaruhi oleh karakteristik dataset yang relatif mudah diklasifikasikan, dimana seluruh citra diperoleh pada kondisi pencahayaan yang hampir serupa, *background* citra yang seragam, serta perbedaan karakteristik warna *roasting* biji kopi yang cukup jelas antar kelas sehingga fitur warna HSV dan LAB mampu menghasilkan perbedaan antar kelas dengan baik. Kondisi tersebut menyebabkan fitur warna yang diekstraksi merepresentasikan karakteristik setiap tingkat *roasting* dengan baik sehingga pola yang dipelajari pada data pelatihan dapat dikenali kembali pada data pengujian. Upaya meminimalkan terjadinya *overfitting* dilakukan melalui beberapa tahapan meliputi penggunaan *StandardScaler* untuk menyetarakan skala fitur masukan JST Backpropagation, pemisahan data menjadi data latih dan data uji sehingga evaluasi *performa* dilakukan menggunakan data yang tidak pernah digunakan dalam proses pelatihan model, serta pemilihan arsitektur jaringan yang sederhana sehingga model tetap mampu melakukan generalisasi dengan baik terhadap data baru.

3.6. Perbandingan Fitur HSV dan LAB

Penelitian ini fokus pada perbandingan kinerja HSV dan LAB untuk mengetahui hasil klasifikasi menggunakan metode JST Backpropagation. Perbandingan dilakukan berdasarkan hasil pelatihan dan pengujian model yang diperoleh pada masing-masing fitur. Hasil perbandingan kinerja fitur HSV dan LAB ditampilkan pada Gambar 11 berikut.



Gambar 11. Perbandingan fitur HSV dan LAB

Gambar 11 menunjukkan bahwa pada tahap pelatihan, fitur HSV menghasilkan akurasi sebesar 99,00%, sedangkan fitur LAB mencapai 99,41%. Tahap pengujian fitur HSV memperoleh akurasi 99,25% dan fitur LAB 99,75%. Meskipun demikian, hasil uji McNemar pada gambar 10 menunjukkan bahwa perbedaan tersebut tidak signifikan secara statistik dengan nilai 0,500 ($p > 0,05$), namun berdasarkan hasil *confussion matrix* ruang warna LAB menghasilkan jumlah kesalahan klasifikasi yang lebih sedikit dibandingkan HSV. Hal ini dikarenakan ruang warna LAB mampu merepresentasikan warna pada sumbu *chromaticity* (a^* dan b^*) yang lebih sesuai untuk menggambarkan perubahan warna secara bertahap selama proses *roasting*, mulai dari warna hijau (*green bean*) hingga cokelat gelap (*dark roast*). Sedangkan pada ruang warna HSV, komponen *Hue* menjadi kurang stabil pada warna dengan saturasi rendah atau warna yang mendekati gelap, sehingga pada hasil *confussion matrix* kesalahan prediksi terjadi lebih banyak pada biji kopi *medium roast*. Kondisi tersebut menyebabkan karakteristik warna antar tingkat *roasting* menjadi kurang terpisah secara optimal, sehingga akurasi klasifikasi yang dihasilkan lebih rendah dibandingkan ruang warna LAB.

4. KESIMPULAN

Penelitian ini berhasil melakukan klasifikasi tingkat *roasting* biji kopi menggunakan fitur HSV dan LAB dengan metode JST Backpropagation pada empat kelas *roasting* yaitu *green bean*, *light roast*, *medium roast*, dan *dark roast*. Hasil penelitian menunjukkan bahwa fitur LAB menghasilkan akurasi pengujian sebesar 99,75%, *precision* 99,75%, *recall* 99,75%, dan *F1-Score* 99,75%. Sementara pada fitur HSV memperoleh akurasi pengujian sebesar 99,25%, *precision* 99,26%, *recall* 99,25%, dan *F1-Score* 99,25%. Berdasarkan hasil *confussion matrix*, fitur LAB menghasilkan jumlah kesalahan klasifikasi yang lebih sedikit dibandingkan HSV, namun hasil uji McNemar menunjukkan perbedaan kinerja antara kedua ruang warna tersebut tidak signifikan secara statistik dengan nilai 0,500 ($p > 0,05$). Meskipun penelitian ini memberikan hasil yang baik, penelitian masih memiliki keterbatasan karena hanya menggunakan satu jenis metode klasifikasi dan dataset dengan kondisi citra yang relatif seragam. Oleh karena itu, penelitian selanjutnya dapat dikembangkan dengan menggunakan metode *deep learning* lainnya, menambahkan variasi kondisi pencahayaan dan jenis biji kopi, serta melakukan implementasi sistem secara *real time* agar hasil klasifikasi dapat digunakan secara lebih luas pada proses industri kopi.

REFERENCES

- [1] R. A. Lubis, and N. A. B. Rahmani, "Pengaruh Nilai Tukar Rupiah, Harga Kopi Internasional Terhadap Nilai Ekspor Kopi Indonesia Dengan Inflasi Sebagai Variabel Intervening Periode 2002-2021," *Jurnal Ekonomi Pendidikan dan Kewirausahaan*, vol. 11, no. 2, pp. 135-152, 2023, doi: <https://doi.org/10.26740/jepk.v11n2.p135-152>.
- [2] H. Syofya, "Analisis Ekspor Kopi Indonesia," *Jurnal Ilmiah Indonesia*, vol. 8, no. 8, 2023, doi: [dx.doi.org/10.36418/syntax-literate.v6i6](https://doi.org/10.36418/syntax-literate.v6i6).
- [3] R. Darmawan, *Pusat Data dan Sistem Informasi Pertanian: Outlook Kopi 2023*, Jakarta, Indonesia: Kementerian Pertanian, 2023.
- [4] M. T. Pamungkas, Masrukan, and Kuntjahjawi, "Pengaruh Suhu Dan Lama Penyangraian (*Roasting*) Terhadap Sifat Fisik Dan Kimia Pada Seduhan Kopi Arabika (*Coffea Arabica L.*) Dari Kabupaten Gayo, Provinsi Aceh," *AGROTECH*, vol. 3, no. 2, pp. 1-10, 2021, doi: <https://doi.org/10.37631/agrotech.v3i2.278>.
- [5] E. H. Windari et al., *Budidaya Kopi Modern : Teknik, Inovasi, Dan Keberlanjutan*. Padang, Indonesia: Lingkar Edukasi Indonesia, 2025.
- [6] I. G. P. A. Saputra, P. W. Rahayu, and I. M. D. Ardiada, "Analisis Tingkat Kematangan Sangraian Biji Kopi Menggunakan Ekstraksi Fitur Warna," *J-INTECH (Journal of Information and Technology)* no. 204, pp. 123-128, 2024, doi: <https://doi.org/10.32664/j-intech.v12i1.1258>.
- [7] H. A. Rabbani, M. A. Rahman, and B. Rahayudi, "Perbandingan Ruang Warna RGB dan HSV dalam Klasifikasi Kematangan Biji Kopi," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 6, pp. 2243-2248, 2021, doi: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/9013>.
- [8] D. M. J. Musdar, N. S. Eriyani, S. Azis, A. B. Kaswar, and S. Sasmita, "Implementasi Jaringan Saraf Tiruan Backpropagation Untuk Klasifikasi Tingkat Kesegaran Wortel Berbasis Pengolahan Citra Digital Disertai Operasi Morfologi," *JlPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 9, no. 3, pp. 1518-1533, 2024, doi: [10.29100/jlpi.v9i3.5672](https://doi.org/10.29100/jlpi.v9i3.5672).
- [9] C. Rozikin, A. Susilo, and Y. Irawan, "Klasifikasi Jenis Buah Mangga dengan Metode Backpropagation,"

- Techné: Jurnal Ilmiah Elektroteknik*, pp. 1–12, doi: <https://doi.org/10.31358/techne.v20i1.231>.
- [10] I. Alfiantama *et al.*, “Klasifikasi Tingkat Roasting Biji Kopi Dengan Metode CNN,” *Prosiding Seminar Nasional Teknologi Dan Sains*, vol. 3, pp. 285–290, 2024.
- [11] A. G. Arumsari, R. Surya, S. Irmasuryani, and W. Sapitri, “Analisis Proses Roasting pada Kopi,” *Jurnal Beta Kimia*, vol. 1, no. November, pp. 98–101, 2021, doi: <https://doi.org/10.35508/jbk.v1i2.5586>.
- [12] Ryansyah, “Identifikasi Tingkatan Warna Pada Kopi Roasting Menggunakan Metode HSV Berbasis Mobile,” *TIN: Terapan Informatika Nusantara*, vol. 1, no. 10, pp. 520–526, 2021, doi: <https://ejurnal.seminar-id.com/index.php/tin>.
- [13] N. Mudhofar and S. Agustin, “Klasifikasi Penyakit Daun Apel Menggunakan Ekstraksi Fitur Warna RGB,” *Repeater: Publikasi Teknik Informatika dan Jaringan*, vol. 2, no. 3, 2024, doi: <https://doi.org/10.62951/repeater.v2i3.120>.
- [14] M. R. Syahputra, and Y. R. Nasution, “Klasifikasi Tingkat Kematangan Kopi Gayo Berdasarkan Fitur Citra Warna Kulit Menggunakan Metode Transformasi Ruang Warna HSV,” *JCBD: Journal Of Computers And Digital Business*, vol. 5, pp. 49–58, 2026, doi: <https://doi.org/10.56427/jcbd.v5i2.985>.
- [15] M. R. Mulia, A. B. Kaswar, D. D. Andayani, and A. Sadri, “Klasifikasi Kandungan Nutrisi Buah Pisang Berdasarkan Fitur Tekstur Dan Warna Lab Menggunakan Jaringan Syaraf Tiruan Berbasis Pengolahan Citra Digital,” *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 11, no. 3, pp. 507–518, 2024, doi: [10.25126/jtiik.938332](https://doi.org/10.25126/jtiik.938332).
- [16] P. Lestari, Zulfauzi, and B. Santoso, “Klasifikasi Tingkat Kematangan Roasting Kopi Menggunakan Deep Learning,” *Jurnal Digital Teknologi Informasi*, vol. 07, no. 01, pp. 1–5, 2024, doi: <https://doi.org/10.32502/digital.v7i1.5655>.
- [17] Khairullah, and E. D. Putra, “Identifikasi Kematangan Cabai Menggunakan Operasi Morfologi (Opening dan Closing) dan Metode Backpropagation,” *SISTEMASI: Jurnal Sistem Informasi*, vol. 10, pp. 96–105, 2021, doi: <https://doi.org/10.32520/stmsi.v10i1.1094>.
- [18] A. M. I. Tafsir, Sulfayanti, and N. Nur, “Pendekatan Backpropagation Artificial Neural Network Untuk Prediksi Kemurnian Madu,” *Techno.COM*, vol. 24, no. 4, pp. 1199–1210, 2025, doi: <https://doi.org/10.62411/tc.v24i4.14855>.
- [19] A. W. Putri, “Implementasi Artificial Neural Network (ANN) Backpropagation Untuk Klasifikasi Jenis Penyakit Pada Daun Tanaman Tomat,” *MATHunesa*, vol. 09, no. 02, pp. 344–350, 2021, doi: <https://doi.org/10.26740/mathunesa.v9n2.p344-350>.
- [20] A. F. Setiadi F., A. A. Kurniawan, A. D. Hartanto, and Hartatik, “Implementasi Metode CNN dan Deep Learning untuk Menentukan Tingkat Roasting Biji Kopi,” *Intechno J. (Information Technol. Journal)*, vol. 4, no. 2, pp. 48–54, 2022, doi: <https://doi.org/10.24076/intechnojournal.2022v4i2.1563>.