



KLASIFIKASI MUTIARA BANGSRING UNDERWATER BERDASARKAN CACAT LUBANG MENGGUNAKAN ARTIFICIAL NEURAL NETWORK BERBASIS SVM-RFE

Fauzan Firdaus¹⁾, A. Hamdani¹⁾

¹ Teknologi Informasi, Universitas Ibrahimy Sukorejo Situbondo

email: ¹ fauzanfirdaus@ibrahimiy.ac.id, ¹ dan.kidz88@gmail.com

ARTICLE INFO	ABSTRACT
Article History: Recieved : 20 Maret 2026 Accepted : 26 Mei 2026 Published : 30 Juni 2026 Keywords: Thresholding, GLCM, SVM-RFE, ANN, Mutiara Bangsring Underwater, Pengolahan Citra. IEEE style in citing this article: F. Firdaus, A. Hamdani, "Klasifikasi Mutiara Bangsring Underwater Berdasarkan Cacat Lubang Menggunakan Artificial Neural Network Berbasis SVM-RFE", <i>jurnal.ilmiah.informatika</i>, vol. 11, no. 1, pp. 131-138, Juni 2026.	<i>Pearls are highly valued gemstones, where quality is significantly determined by surface integrity, particularly the absence of hole defects. Traditional manual inspection is subjective and inefficient, creating a demand for automated, high-precision detection systems. This research develops an automated framework to identify hole-based defects in pearls sourced from the Bangsring Underwater region using digital image processing and machine learning. The methodology begins with preprocessing and thresholding to isolate pearl objects, followed by texture feature extraction using the Gray Level Co-Occurrence Matrix (GLCM). To handle high-dimensional data, this study utilizes Support Vector Machine - Recursive Feature Elimination (SVM-RFE) for feature selection, while classification is executed using an Artificial Neural Network (ANN). The experimental dataset consists of 240 high-resolution pearl images (120 with hole defects and 120 defect-free), evaluated across training cycles ranging from 100 to 1000. Results show that the stand-alone ANN achieved a peak accuracy of 95.83% at 1000 cycles, whereas integrating SVM-RFE enhanced performance to 97.62% at 900 and 1000 cycles. These findings confirm that the combined SVM-RFE and ANN framework provides a robust solution for automated defect detection, offering a scalable approach for industrial quality inspection in the Bangsring Underwater region.</i>

1. PENDAHULUAN

Indonesia dianugerahi kekayaan sumber daya maritim yang sangat melimpah, di mana salah satu komoditas unggulannya adalah kerang mutiara laut selatan (*Pinctada maxima*). Secara global, Indonesia mendominasi pasar sebagai produsen mutiara terbesar dengan kontribusi pemenuhan lebih dari 40% dari total permintaan dunia, mengungguli negara-negara produsen terkemuka lainnya seperti Australia, Filipina, Myanmar, dan Malaysia. Potensi pengembangan budidaya komoditas ini tersebar luas di berbagai wilayah perairan nusantara, yang meliputi area Sumatera Barat, Lampung, Bali, Nusa Tenggara, Sulawesi, Gorontalo, Maluku, hingga Papua. Sebagai salah satu batu permata bernilai ekonomi tinggi, harga jual sebutir mutiara sangat ditentukan oleh parameter kualitas fisik yang mencakup ukuran, bentuk, tingkat kehalusan permukaan (tekstur), serta ketiadaan cacat lubang (hole defect). Oleh karena itu, proses inspeksi untuk mendeteksi kecacatan fisik mutiara secara cepat dan presisi menjadi tahapan krusial dalam menentukan kelas mutu produk. Seiring dengan disrupsi teknologi, implementasi visi komputer (computer vision) mulai diadaptasi secara luas guna menggantikan metode penyortiran manual yang sangat bergantung pada subjektivitas dan keterbatasan visual manusia, sehingga proses pemilahan mutiara dapat dilakukan secara jauh lebih objektif dan berakurasi tinggi. Sejumlah studi terdahulu telah membuktikan efektivitas sistem otomasi cerdas dalam menganalisis citra mutiara (Qi Xuan dkk, 2018). sukses merancang mesin penyortir otomatis berbasis algoritma Multi-Stream Convolutional Neural Network (MS-CNN) yang dievaluasi menggunakan 52.500 citra multi-view, di mana

pengujian tersebut berhasil mencetak tingkat akurasi hingga 92,14%. (Qi Xuan dkk, 2019). Setahun kemudian mengusulkan penyempurnaan melalui pendekatan hibrida menggunakan Multiview Generative Adversarial Networks (MVGAN) yang terbukti mampu mendongkrak performa MS-CNN hingga 26,71%, menjadikannya sebagai salah satu pencapaian state-of-the-art pada era tersebut. Pendekatan komputasi lain ditunjukkan oleh Muh Nasirudin Karim pada penelitiannya yang memanfaatkan algoritma Artificial Neural Network (ANN) dengan sokongan metode ekstraksi fitur Gray Level Co-Occurrence Matrix (GLCM) tingkat 2 untuk memisahkan tiga label mutu mutiara. Model jaringan syaraf tiruan ini berhasil mencapai titik akurasi optimal sebesar 96,66% pada rentang pengujian epoch 60 hingga 80 (Nasiruddin, 2022) Berpijak pada tinjauan rujukan tersebut, penelitian ini difokuskan untuk memodelkan sistem klasifikasi kualitas mutiara dengan lokus spesifik pada mutiara hasil budidaya dari perairan Bangsring Underwater. Tahapan prapemrosesan citra akan mengandalkan teknik segmentasi thresholding yang secara otomatis mampu memisahkan latar belakang dan menyoroiti keberadaan cacat lubang melalui konversi citra biner. (Putri & Suwanda, 2023) Proses ini dilanjutkan dengan analisis tekstur menggunakan GLCM guna mengekstraksi nilai kontras, korelasi, energi, serta homogenitas sebagai atribut pembeda karakteristik mutiara. Untuk tahapan pengenalan pola dan penentuan kelas klasifikasi, penelitian ini mengimplementasikan algoritma ANN dengan fungsi pembelajaran backpropagation (Pudjihartono, 2022). Meskipun algoritma ini dikenal andal dalam menemukan dan memetakan pola kompleks dari sebuah training set, backpropagation seringkali dihadapkan

pada kendala konvergensi yang lambat serta rentan terhadap ketidakstabilan akibat masukan fitur yang kurang relevan. Guna menanggulangi kelemahan arsitektur tersebut, sistem ini akan dioptimasi menggunakan metode Support Vector Machine - Recursive Feature Elimination (SVM-RFE) yang bertindak sebagai agen penyeleksi fitur. Integrasi SVM-RFE diharapkan mampu mereduksi dimensi data secara efektif dengan menahan fitur-fitur yang paling esensial, sehingga secara nyata dapat memaksimalkan tingkat akurasi dan kinerja komputasi ANN dalam mengklasifikasikan kecacatan lubang pada mutiara Bangsring Underwater.

2. METODE PENELITIAN


2.1 Objek dan Dataset Penelitian

Penelitian ini mengadopsi pendekatan kuantitatif eksperimental yang secara khusus berfokus pada analisis mendalam dan klasifikasi mutu fisik komoditas kerang mutiara asal perairan Bangsring Underwater. Penggunaan pendekatan ini dinilai paling relevan guna menguji performa sistem otomatisasi dalam membedakan tingkat kualitas berdasarkan karakteristik visual objek secara objektif. Instrumen utama yang diandalkan dalam arsitektur klasifikasi ini adalah algoritma Artificial Neural Network (ANN), yang kinerjanya kemudian dioptimalkan melalui integrasi teknik seleksi fitur tingkat lanjut berupa Support Vector Machine - Recursive Feature Elimination (SVM-RFE) untuk mereduksi dimensi data yang kurang signifikan dan meningkatkan efisiensi komputasi.

Kumpulan data (dataset) primer yang dievaluasi secara keseluruhan terdiri dari 240 citra mutiara berformat digital yang diperoleh melalui proses akuisisi menggunakan kamera beresolusi tinggi dengan jarak dan sudut bidik terkontrol.

Keseluruhan data tersebut dipartisi secara proporsional dan seimbang ke dalam dua kategori label mutu fisik utama, yakni sebanyak 120 citra untuk kelas mutiara dengan indikasi cacat berlubang serta 120 citra untuk kelas mutiara berkualitas baik tanpa cacat lubang. Penentuan proporsi data yang berimbang ini bertujuan untuk menghindari bias model saat fase pelatihan berlangsung. Representasi visual yang lebih detail dari masing-masing kategori sampel citra mutiara tersebut dapat diamati secara langsung pada Tabel 1 di bawah ini.

Tabel 1.
Contoh Citra Mutiara Berdasarkan Label


No	Label	Citra mutiara	
1	Cacat berlubang		
			
2	Tidak berlubang		
			

2.2 Proposed Method

Pengumpulan data dalam riset ini dilakukan melalui metode observasi dan studi pustaka, dengan memanfaatkan dataset primer berupa citra digital kerang mutiara Bangsring Underwater yang diambil menggunakan kamera digital berdasarkan jarak dan sudut pandang terkontrol. Dataset ini terdiri dari 240 frame citra yang dikelompokkan ke dalam dua kategori label mutu, yaitu mutiara dengan cacat berlubang dan mutiara tidak berlubang. Secara garis besar, tahapan

penelitian ini meliputi pengumpulan data, pra-pemrosesan, ekstraksi fitur, pelatihan model, hingga evaluasi hasil,

sebagaimana digambarkan gambar 1 pada alur penelitian berikut:



Gambar 1. Alur Diagram pada Sistem

2.3 Pra-pemrosesan Citra

Guna mempersiapkan data visual agar kompatibel dengan sistem komputasi dan meminimalisasi gangguan (noise), seluruh citra mentah melewati serangkaian prosedur prapemrosesan. Tahapan ini diawali dengan pemotongan (cropping) untuk menyeragamkan dimensi citra menjadi bujur sangkar, sehingga anomali lubang dapat terekspos lebih dominan. Selanjutnya, proses rotasi spasial (90 derajat ke kanan, 90 derajat ke kiri, dan 180 derajat ke bawah) diterapkan sebagai

metode augmentasi guna memperkaya jumlah variasi data. Tahap prapemrosesan diakhiri dengan penghapusan dan penggantian warna latar belakang untuk mereduksi bintik derau yang berpotensi mendisrupsi proses segmentasi.

2.4 Segmentasi dan Ekstraksi Fitur

Proses pemisahan antara area piksel objek mutiara, area cacat lubang, dan area latar belakang dieksekusi menggunakan teknik segmentasi thresholding. Melalui penentuan nilai ambang batas tertentu, matriks citra berwarna (RGB) dikonversi

menjadi representasi citra biner. Metode ini mempermudah sistem dalam mengidentifikasi region kecacatan pada permukaan mutiara secara otomatis.

2.5 Seleksi Fitur dan Klasifikasi

Dataset fitur yang dihasilkan dari proses GLCM dibagi menjadi dua subset, yakni 70% dialokasikan sebagai data pelatihan (training set) dan 30% sebagai data pengujian (testing set). Mengingat dimensi fitur yang diekstraksi dapat membebani kinerja algoritma komputasi, metode Support Vector Machine - Recursive Feature Elimination (SVM-RFE) diintegrasikan untuk mereduksi redundansi. SVM-RFE bertugas menyeleksi dan mempertahankan subset atribut tekstur yang memiliki bobot relevansi tertinggi.

Atribut-atribut optimal hasil seleksi tersebut kemudian dimasukkan ke dalam arsitektur klasifikasi Artificial Neural Network (ANN). Pengklasifikasi ANN, yang digerakkan oleh algoritma propagasi balik (backpropagation), akan mengenali pola dari data pelatihan untuk membangun model prediksi penentuan kelas mutu mutiara.

2.6 Evaluasi Kinerja Model

Validasi akhir dari sistem klasifikasi yang diusulkan diukur menggunakan teknik matriks kebingungan (confusion matrix). Pengujian ini secara komprehensif memetakan perbandingan antara kelas prediksi yang dihasilkan oleh model dengan kelas aktual dari data pengujian. Kinerja keandalan model dievaluasi secara kuantitatif berdasarkan tiga parameter performa utama, yaitu tingkat akurasi (accuracy), presisi (precision), dan perolehan kembali (recall).

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Penelitian ini memanfaatkan data primer yang bersumber dari riset

terdahulu karya Muh. Nasirudin dkk, yang dilakukan penelitiannya pada tahun 2021 dimana pada awalnya memuat 360 sampel citra mutiara. Guna menyesuaikan dengan fokus kajian, kumpulan data tersebut kemudian diseleksi ulang dan diklasifikasikan ke dalam dua kategori karakteristik utama: mutiara dengan cacat fisik berupa lubang dan mutiara berwujud normal (tanpa lubang). Citra hasil penyortiran tersebut dialokasikan ke dalam dua direktori terpisah, di mana masing-masing direktori menyimpan 120 citra mutiara berlubang dan 120 citra mutiara normal. Dengan demikian, total keseluruhan dataset yang dioperasikan pada tahap selanjutnya berjumlah 240 citra. Representasi visual dari sampel masing-masing klasifikasi tersebut dapat diamati lebih lanjut pada Tabel 3.1 berikut ini.

Tabel 3.1
Folder citra mutiara berdasar label

No	Nama folder	Folder	Contoh citra	Jumlah
1	Cacat berlubang			120
2	Tidak berlubang			120
Total				240

3.2 Preprocessing

Penelitian ini mengeksekusi fase pra-pemrosesan (preprocessing) guna memperbaiki sekaligus menyempurnakan kualitas dari 240 data citra mutiara Bangsring Underwater berformat JPG. Peneliti mengawalinya dengan operasi cropping untuk memosisikan citra pada dimensi persegi yang presisi, sehingga fokus pengamatan pada objek cacat lubang mutiara menjadi lebih tajam. Untuk memperkaya jumlah citra pada dataset, metode rotasi gambar turut

diaplikasikan, yakni dengan memutar citra 90 sampai 180 derajat. peneliti membersihkan area latar belakang gambar (erase) guna menghilangkan bintik-bintik noise demi mempermudah dan mengoptimalkan tahap segmentasi. Keseluruhan hasil dari tahapan perbaikan kualitas citra ini divisualisasikan melalui Tabel 4.1 berikut ini.

Tabel 3. 2

Erase dan mengganti warna backgroud				
No	Sebelum	Sesudah	Label	Jumlah
1			Cacat berlubang	120
2			Tidak berlubang	120
Total				240

3.3 Seleksi Fitur GLCM

Gray Level Co-Occurrence Matrix (GLCM) adalah metode ekstraksi fitur yang memanfaatkan kemunculan matriks yang sama dalam piksel citra untuk mendapatkan nilai kontras, korelasi, energi, dan homogenitas.

Pada tahap ini dilakukan ekstraksi fitur menggunakan metode usulan menggunakan GLCM sehingga mendapatkan nilai 4 fitur berdasarkan Kontras, Korelasi, dan Homogenitas Energi dengan sudut yang digunakan, seperti terlihat pada tabel 3.3 diperoleh nilai fitur pada mutiara.

Tabel 3.3 Nilai fitur label cacat berlubang

Nama file	Kontras	Korelasi	Energi	Homogenitas
1.jpg	0.028968	0.98988	0.98988	0.99947
2.jpg	0.039623	0.98617	0.94068	0.99928
3.jpg	0.026069	0.9869	0.95884	0.99929
4.jpg	0.036764	0.036764	0.95972	0.99934
5.jpg	0.042011	0.99064	0.9075	0.9075
6.jpg	-----	-----	-----	-----
7.jpg	-----	-----	-----	-----

120.jpg	0.02911	0.98709	0.95337	0.99947
---------	---------	---------	---------	---------

3.4 Klasifikasi Artificial Neural Network

Uji coba pertama diterapkan murni menggunakan arsitektur ANN terhadap 16 ekstraksi fitur GLCM tanpa proses penyeleksian fitur tambahan. Skenario eksperimen dilakukan melalui peningkatan jumlah siklus training mulai dari 100 hingga 1000. Parameter pengaturan meliputi nilai learning rate sebesar 0.1, momentum 1.0, dan implementasi 10-fold cross validation.

Hasil menunjukkan bahwa akurasi terus berfluktuasi naik seiring bertambahnya iterasi. Titik akurasi puncak didapatkan pada jumlah iterasi 1000, di mana ANN berhasil mengidentifikasi pola dengan ketepatan 95,83% (Precision: 95,84%, Recall: 95,83%). Rincian kinerja terbaik dari ANN untuk masing-masing kelas ditunjukkan pada Tabel 3.4.


Tabel 3.4 Performa Puncak Klasifikasi ANN

Label Citra	Precision	Recall	Jumlah Data
Cacat Berlubang	95,29%	96,43%	120
Tidak Berlubang	96,39%	95,24%	120

Akurasi Keseluruhan (Accuracy): 95,83%

Berdasarkan tabel di atas diperoleh waktu yang lebih cepat dan peningkatan akurasi pada masing masing tahap percobaan klasifikasi ANN+SVM-RFE, adapun 6 fitur terbaik yang di pertahankan dari 16 fitur yang di eliminasi oleh SVM-RFE dapat dilihat pada gambar 3.1 di bawah ini

Gambar 3.1 Fitur terbaik hasil SVM-RFE




Untuk memaksimalkan kapabilitas ANN, 16 atribut awal disaring oleh algoritma SVM-RFE. Dari proses rekursif, model berhasil menyingkirkan 10 atribut yang dinilai redundan dan mempertahankan 6 atribut terbaik.

Hasil uji coba yang sama diulang menggunakan model hybrid ANN + SVM-RFE. Reduksi dimensi fitur nyatanya berdampak sangat positif dalam mengatasi overfitting dan underfitting. Hasil komputasi merekam lonjakan performa secara sistematis, di mana pada fase pelatihan 900 dan 1000 siklus, model berhasil mencapai rekor akurasi tertinggi sebesar 97,62% seperti table 3.5 dibawah ini.

Tabel 3.5 Hasil Klasifikasi

Label Citra	Precision	Recall	Jumlah Data
Cacat Berlubang	98,78%	96,43%	120
Tidak Berlubang	96,51%	98,81%	120
Akurasi Keseluruhan (Accuracy): 97,62%			


Penerapan seleksi fitur SVM-RFE pada algoritma ANN menghasilkan peningkatan akurasi yang substansial dalam mengklasifikasikan kecacatan lubang mutiara Bangsring Underwater. Nilai akurasi maksimal sebesar 97,62% berhasil dicapai pada iterasi pelatihan ke-900 dan 1000, sebagaimana diilustrasikan pada Gambar 3.2 di bawah ini.



Gambar 3.2 Hasil Klasifikasi ANN


3.6 Evaluasi Kinerja Model

Pengujian model menggunakan algoritma Artificial Neural Network (ANN) murni menghasilkan tingkat akurasi maksimal sebesar 95,83% yang tercapai pada iterasi (training cycles) ke-1000. Berdasarkan rincian performa per kelas (sebagaimana diilustrasikan pada Gambar 3.3), kelas mutiara dengan cacat lubang mencatatkan nilai presisi 95,29% dan recall 96,43%. Sementara itu, kelas mutiara normal (tanpa lubang) memperoleh nilai presisi 96,39% dan recall 95,24%.




Gambar 3.3 Hasil Klasifikasi ANN berdasarkan Label

Di sisi lain, integrasi metode penyeleksian fitur SVM-RFE dengan ANN menunjukkan lonjakan performa yang substansial. Akurasi puncak model gabungan ini menyentuh angka 97,62% pada iterasi pelatihan ke-900 dan 1000 (merujuk pada grafik Gambar 3.4). di mana kategori mutiara berlubang meraih nilai presisi 98,78% dan recall 96,43%.



Gambar 3.4 Hasil Comperasi ANN dan SVM

Analisis matriks konfusi dari model hibrida ANN+SVM-RFE (Gambar 3.5) memvalidasi keunggulan algoritma ini. Terjadi peningkatan prediksi benar pada kategori cacat lubang menjadi 111 citra (dari total 120 data). Prediksi pada kelas mutiara normal juga meningkat tajam, dengan 119 citra berhasil diklasifikasikan secara tepat (hanya 1 kesalahan prediksi dari 120 data).



Gambar 3.5 Confusion Matrix ANN

Berdasarkan komparasi hasil tersebut, dapat ditarik kesimpulan akhir bahwa penerapan metode seleksi fitur SVM-RFE sangat efektif dalam mengoptimalkan kapabilitas model ANN, sehingga berdampak langsung pada peningkatan akurasi sistem dalam mengenali cacat lubang pada mutiara Bangsring Underwater.

4. KESIMPULAN

Berdasarkan rangkaian analisis dan pengujian sistem otomatisasi klasifikasi cacat lubang pada Mutiara Bangsring Underwater, dapat disimpulkan beberapa poin penting. Pertama, penggabungan teknik thresholding untuk segmentasi dan metode GLCM terbukti handal dalam menangkap atribut tekstur pembeda cacat fisik pada citra mutiara. Kedua, implementasi penyeleksian fitur berbasis algoritma SVM-RFE sukses mereduksi 16 fitur awal menjadi 6 fitur paling esensial.

Optimasi ruang fitur ini membawa dampak langsung terhadap kinerja Artificial Neural Network (ANN), dengan lonjakan akurasi klasifikasi dari 95,83% (model dasar) menjadi 97,62% (model teroptimasi). Temuan ini membuktikan bahwa hibridisasi metode penyeleksian fitur (SVM-RFE) efektif meningkatkan kapasitas komputasi jaringan saraf tiruan dalam mengenali standar kelayakan inspeksi produk akuakultur secara otomatis.

5. REFERENSI

- [1] B. Li, G. E. Li, Y. Wang, X. Wang, dan W. Wang, "A Classification Method Of Pearl Shape Based On Zernike Moment."
- [2] G. Castellano, L. Bonilha, L. M. Li, dan F. Cendes, "Texture Analysis Of Medical Images," *Clinical Radiology*, vol. 59, no. 12, pp. 1061–1069, Dec. 2004, doi: 10.1016/j.crad.2004.07.008.
- [3] L. A. Putri dan Suwanda, "Implementasi Metode Artificial Neural Network (ANN) Algoritma Backpropagation Untuk Klasifikasi Kualitas Udara Di Provinsi DKI Jakarta Tahun 2021," *Bandung Conference Series: Statistics*, vol. 3, no. 2, pp. 184–191, Jul. 2023, doi: 10.29313/bcss.v3i2.7826.
- [4] M. L. Huang, Y. H. Hung, W. M. Lee, R. K. Li, dan B. R. Jiang, "SVM-RFE Based Feature Selection and Taguchi Parameters Optimization For Multiclass SVM Classifier," *Scientific World Journal*, vol. 2014, 2014, doi: 10.1155/2014/795624.
- [5] M. N. Karim, R. A. Pramunendar, M. A. Soeleman, P. Purwanto, dan B. Imran, "Classification Of Bangsring Underwater Pearls Using GLCM Feature Extraction and Artificial Neural Networks (ANN)," *Ilkom Jurnal Ilmiah*, vol. 14, no. 3, pp. 209–

- 217, Dec. 2022, doi: 10.33096/ilkom.v14i3.1317.209-217.
- [6] M. Ohsaki, P. Wang, K. Matsuda, S. Katagiri, H. Watanabe, dan A. Ralescu, "Confusion-Matrix-Based Kernel Logistic Regression For Imbalanced Data Classification," *IEEE Transactions on Knowledge and Data Engineering*, vol. 29, no. 9, pp. 1806–1819, Sep. 2017, doi: 10.1109/TKDE.2017.2682249.
- [7] N. Pudjihartono, T. Fadason, A. W. Kempa-Liehr, dan J. M. O'Sullivan, "A Review Of Feature Selection Methods For Machine Learning-Based Disease Risk Prediction," *Frontiers In Bioinformatics*, vol. 2, Jun. 2022, doi: 10.3389/fbinf.2022.927312.
- [8] Q. Xuan et al., "Automatic Pearl Classification Machine Based On A Multistream Convolutional Neural Network," *IEEE Transactions On Industrial Electronics*, vol. 65, no. 8, pp. 6538–6547, Aug. 2018, doi: 10.1109/TIE.2017.2784394.
- [9] Q. Xuan, Z. Chen, Y. Liu, H. Huang, G. Bao, dan D. Zhang, "Multiview Generative Adversarial Network and Its Application In Pearl Classification," *IEEE Transactions On Industrial Electronics*, vol. 66, no. 10, pp. 8244–8252, Oct. 2019, doi: 10.1109/TIE.2018.2885684.
- [10] S. Van Cranenburgh dan A. Alwosheel, "An Artificial Neural Network Based Approach To Investigate Travellers' Decision Rules," *Transportation Research Part C: Emerging Technologies*, vol. 98, pp. 152–166, Jan. 2019, doi: 10.1016/j.trc.2018.11.014.
- [11] T. S. Huang, W. F. Schreiber, dan O. J. Tretiak, "Image Processing," 1971.
- [12] X. Deng, Q. Liu, Y. Deng, dan S. Mahadevan, "An Improved Method To Construct Basic Probability Assignment Based On The Confusion Matrix For Classification Problem," *Information Sciences*, vol. 340–341, pp. 250–261, May 2016, doi: 10.1016/j.ins.2016.01.033.
- [13] X. Liu, S. Jin, Z. Yang, G. Królczyk, dan Z. Li, "Measuring Shape Parameters Of Pearls In Batches Using Machine Vision: A Case Study," *Micromachines*, vol. 13, no. 4, Apr. 2022, doi: 10.3390/mi13040546.
- [14] Z. K. Huang dan K. W. Chau, "A New Image Thresholding Method Based On Gaussian Mixture Model," *Applied Mathematics and Computation*, vol. 205, no. 2, pp. 899–907, Nov. 2008, doi: 10.1016/j.amc.2008.05.130.
- [15] Z. Li, C. Liu, G. Liu, Y. Cheng, X. Yang, dan C. Zhao, "A Novel Statistical Image Thresholding Method," *AEU - International Journal Of Electronics and Communications*, vol. 64, no. 12, pp. 1137–1147, Dec. 2010, doi: 10.1016/j.aeeu.2009.11.011.