

# Perbandingan Cacat Ubin Keramik dengan Metode K-Nearest Neighbor dan Support Vector Machine

## *Comparison of Ceramic Tile Defects with K-Nearest Neighbor and Support Vector Machine Method*

Riza Alamsyah<sup>1</sup>, Iman Permana<sup>2</sup>, Maharani Siti Aulieza<sup>3</sup>

<sup>1</sup> Program Studi Sistem Informasi, Universitas Budi Luhur

<sup>2</sup> Program Studi Teknik Informatika, Universitas Budi Luhur

<sup>3</sup> Program Studi Sistem Informasi, Universitas Budi Luhur

E-mail: <sup>1</sup>riza.alamsyah@budiluhur.ac.id, <sup>2</sup>iman.permana@budiluhur.ac.id ,

<sup>3</sup> 2012501025@student.budiluhur.ac.id

### Abstrak

Penentuan kualitas ubin keramik sudah dilakukan secara otomatis dalam beberapa tahun terakhir. Kendala saat penentuan ubin keramik bercacat dapat berpengaruh terhadap penurunan kualitas produk akhir. Isu yang menjadi fokus dalam penelitian yaitu perbandingan metode antara *K-Nearest Neighbor* (KNN) dengan *Support Vector Machine* (SVM) untuk mendeteksi cacat pada ubin keramik untuk mencapai hasil yang lebih akurat. Untuk mengatasi isu ini, proses yang dilakukan meliputi pengumpulan data gambar dari ubin keramik, yang kemudian diikuti oleh tahap *preprocessing* dan ekstraksi fitur berdasarkan tekstur. Data gambar tersebut kemudian diklasifikasikan dengan metode KNN dan SVM. Temuan dari penelitian ini menunjukkan bahwa pengklasifikasian dengan metode KNN pada  $k = 3$  mampu memberikan hasil yang lebih unggul, yaitu mencapai akurasi 98.947%, sedangkan pengklasifikasian dengan metode SVM hanya mencapai akurasi 85.263%.

Kata kunci: KNN, SVM, Ubin Keramik.

### Abstract

*The quality assessment of ceramic tiles has been automated in recent years. Constraints when installing defective ceramic tiles could affect the decreasing of final product quality. The issue that is the focus of this research is the comparison of methods between K-Nearest Neighbor (KNN) and Support Vector Machine (SVM) to detect defects in ceramic tiles to achieve more accurate results. To overcome this problem, the process involved collecting image data from ceramic tiles, which is then followed by the preprocessing stage and feature extraction based on texture. The image data is then classified by the KNN and SVM methods. The results from this study represent that the classification using the KNN method at  $k=3$  is able to provide superior results, namely achieving an accuracy of 98.947%, while the classification using the SVM method only achieves an accuracy of 85.263%.*

*Keywords: KNN, SVM, Ceramic Tiles*

## 1. PENDAHULUAN

Industri manufaktur yang bergerak dalam produksi ubin keramik dituntut untuk menjaga kualitas hasil produksi ubin keramik. Beberapa tahun terakhir, penentuan kualitas ubin keramik sudah menggunakan inspeksi visual secara otomatis. Sementara itu, meskipun pengecekan cacat ubin menggunakan inspeksi visual otomatis tetap akan ada peluang kesalahan dalam proses mendeteksi cacat ubin [1]. Adanya peningkatan terhadap permintaan konsumen, maka pihak manufaktur ubin dituntut untuk menggunakan salah satu teknologi berupa penggunaan proses inspeksi cacat ubin dalam bentuk visual otomatis sehingga kualitas hasil produksi tetap terjaga kualitasnya [2].

Penerapan dari [1] mengimplementasikan algoritma backpropagation dan artificial neural network yang mana penelitian menunjukkan hasil akurasi mencapai 90%. Sedangkan referensi [3] mengimplementasikan pendekatan yang berdasar pada proses identifikasi kecacatan dimensi, metode morfologi, pengambilan ciri bentuk dan data spasial, yang membawa hasil akurasi sebesar 67%.

Studi yang dilakukan dalam [4] menerapkan suatu algoritma dimana gambar keramik dibagi menjadi beberapa bagian dan bagian yang cacat diidentifikasi. Hasil dari simulasi ini mendapatkan tingkat akurasi sebesar 72%. Penelitian yang dilakukan oleh peneliti [5] menerapkan pendekatan pendeteksian dengan operator "Rotation Invariant Measure of Local Variance" dan diklasifikasikan dengan SVM. Hasilnya, diperoleh tingkat akurasi mencapai 93.4%. Sedangkan studi yang dilakukan oleh [6] melibatkan sistem inspeksi otomatis yang berdasarkan pada teknik pengolahan gambar, yang mampu mendeteksi variasi warna dan kecacatan. Tingkat akurasi yang dicapai oleh metode ini adalah 96,36%.

Berdasarkan hal tersebut, dapat dikatakan bahwa kesulitan dalam mendeteksi keramik yang cacat dapat mempengaruhi penurunan kualitas produk akhir. Penelitian yang dilakukan sebelumnya adalah deteksi cacat pada ubin keramik dengan menggunakan metode *K-Nearest Neighbor* (KNN) [7]. Sedangkan tujuan dari penelitian ini yaitu untuk membandingkan antara metode *K-Nearest Neighbor* (KNN) dengan metode lain yaitu metode *Support Vector Machine* (SVM) dalam mendeteksi cacat pada ubin keramik dan diharapkan dapat mengetahui metode mana yang mampu memperoleh tingkat akurasi yang lebih tinggi sehingga dapat membantu meningkatkan kualitas hasil produksi.

## 2. METODE PENELITIAN

Menurut [8], algoritma KNN adalah suatu metode klasifikasi untuk suatu objek yang didasarkan pada data *training* yang memiliki jarak terdekat dengan objek tersebut. KNN merupakan metode *supervised learning* dimana hasil dari *query instance* yang baru diklasifikasikan berdasarkan mayoritas dari kategori pada algoritma KNN, dimana kelas yang paling banyak muncul nantinya akan menjadi kelas hasil dari klasifikasi. Dari kedua definisi tersebut sejalan dengan penjelasan bahwa KNN adalah metode klasifikasi yang menggunakan data tetangga terdekat untuk mengklasifikasikan suatu objek berdasarkan jaraknya dari objek tersebut dalam data *training*.

$$D_{xy} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

Persamaan di atas merupakan persamaan jarak Euclidean yaitu kedekatan dalam satuan jarak matrik, yang mana:

D = Jarak Euclidean antara data *training* (x) dan data *testing* (y).

$x_i$  = Nilai atribut ke-i dari data training (x).

$y_i$  = Nilai atribut ke-i dari data testing (y).

n = Jumlah atribut individu 1 sampai n.

Algoritma pembelajaran SVM pertama kali dikembangkan bertujuan untuk masalah klasifikasi biner berdasarkan teori pengenalan pola statistik. *Support Vector Machine* bertujuan untuk meminimalkan batas atas kesalahan umum, batas atas ini mewakili kesalahan yang dapat mengakibatkan data yang tidak terlihat untuk pengklasifikasian [5].

Untuk ruang fitur non-linier, *Support Vector Machine* pada awalnya memetakan fitur input ke ruang fitur berdimensi tinggi ( $x \rightarrow \varphi(x)$ ) dan kemudian *Support Vector Machine* menghasilkan klasifikasi *hyper-plane* berdasarkan margin maksimum di ruang fitur. Persamaan *hyper-plane* yang sudah ditentukan oleh parameter b dan w ditunjukkan oleh persamaan 2.

$$f(x) = w \cdot \varphi(x) + b \quad (2)$$

dimana  $w$  adalah vektor normal ke hyper-plane,  $x$  adalah vektor fitur dari defect dan  $\phi$  merupakan pemetaan vektor fitur ke ruang dimensi tinggi. Fungsi Kernel dari *Support Vector Machine* mendefinisikan pemetaan, *hyper-plane* menggambarkan batas yang memaksimalkan margin antara sampel data yang termasuk dalam dua kelas sehingga dapat digeneralisasi dengan baik pada data yang tidak diketahui [5].

Tekstur merupakan suatu karakteristik dari daerah atau bagian dalam gambar yang memiliki pola atau struktur tertentu yang berulang secara alami. Karakteristik tekstural ini muncul karena daerah tersebut memiliki elemen-elemen visual yang konsisten dan berulang, seperti pola, warna, atau bentuk, yang dapat diidentifikasi dan diukur [9]. Peneliti [10] mengusulkan beberapa jenis ciri tekstural didapat dari matriks konkurensi antara lain adalah *Angular Second Moment* (ASM) atau *Energy* (3), *Con* (*Contrast*) (4), *Cor* (*Correlation*) (5), atau *Inverse Difference Moment* (IDM) atau *Homogeneity* (6).

$$ASM = \sum_i \sum_j \{p(i,j)\}^2 \quad (3)$$

$$Con = \sum_k k^2 \left[ \sum_i \sum_j p(i,j) \right], \quad |i-j| = k \quad (4)$$

$$Cor = \frac{\sum_i \sum_j (ij) \cdot p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (5)$$

$$IDM = \sum_i \sum_j \frac{1}{1 + (i-j)^2} p(i,j) \quad (6)$$

Teknik morfologi terdiri dari serangkaian operasi yang mengubah gambar sesuai dengan teori himpunan. Teknik morfologi pada awalnya dikembangkan untuk citra biner dan kemudian diperluas ke citra tingkat keabuan. Ide dasar dalam morfologi biner adalah untuk memeriksa sebuah gambar dengan mudah, penentuan bentuk awal yang disebut elemen terstruktur, menggambarkan kesimpulan bagaimana mencocokkan atau menghapus bentuk dalam gambar [3].

Dilasi dan erosi adalah dua teknik morfologi operasi dasar. Dilasi menambahkan piksel pada batas objek dalam sebuah gambar, sedangkan erosi menghilangkan piksel pada batas objek. Jumlah piksel yang ditambahkan atau dihilangkan dari objek pada gambar tergantung pada ukuran dan bentuk formasi elemen yang digunakan untuk memproses gambar. Dilasi dan erosi sering digunakan dalam kombinasi untuk operasi pemrosesan gambar. Teknik morfologi biasanya digunakan dalam pemrosesan gambar untuk mengurangi noise, meningkatkan kualitas gambar dan deteksi fitur. Selain itu, teknik ini dapat digunakan untuk pra-pemrosesan gambar, deteksi tepi, segmentasi dan pengenalan objek [3].

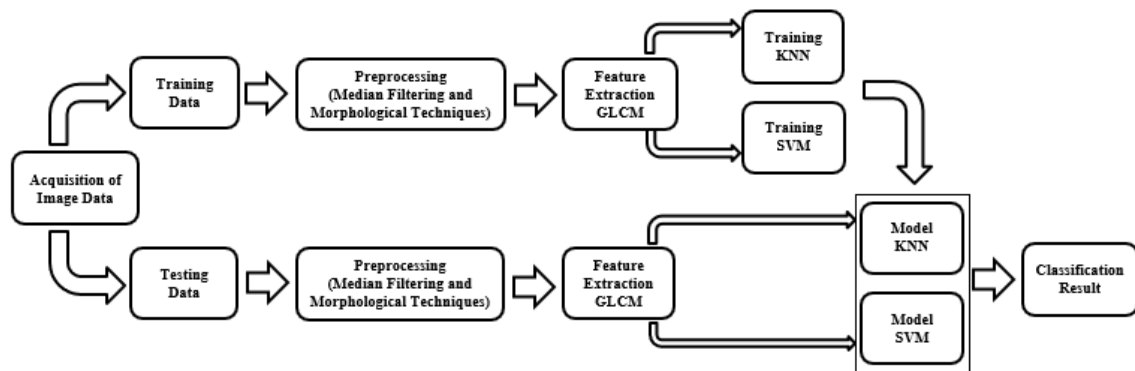
Empat operasi dasar dalam Teknik morfologi adalah *erosion*, *dilation*, *opening* dan *closing*. *Erosion* gambar input  $A$  dengan elemen pembentuk  $B$  didefinisikan sebagai  $A \ominus B = \{x : B + x \subseteq A\}$ . Urutan untuk melakukan *erosion*  $A$  oleh  $B$  adalah menerjemahkan  $B$  dengan  $x$  yang terdapat di  $A$ . Himpunan semua titik  $x$  yang sesuai dengan kondisi seperti itu dituliskan sebagai  $A \ominus B$ . *Erosion* suatu gambar juga dapat ditemukan pada perpotongan semua terjemahan gambar input dengan elemen pembentukan refleksi  $A \ominus B = \cap \{A + b : b \in B\}$  [3].

*Dilation* gambar input  $A$  dengan elemen pembentuk  $B$  didefinisikan sebagai  $A \oplus B = \{B + a : a \in A\}$ . Urutan untuk melakukan dilatasi  $A$  oleh  $B$  adalah menerjemahkan  $B$  ke semua titik yang terkandung dalam  $A$ . Gabungan dari semua translasi ini dituliskan sebagai  $A \oplus B$ . *Opening* gambar input  $A$  ke elemen pembentuk  $B$  didefinisikan sebagai  $A \bullet B = (A \ominus B) \oplus B$  atau sama dengan  $A \bullet B = \{B + x : B + x \subseteq A\}$ . Urutan pembukaan  $A$  oleh  $B$  adalah pertama-tama menerjemahkan  $B$  ke semua titik  $x$  yang terdapat di  $A$ . Gabungan dari semua translasi dituliskan sebagai  $A \bullet B$ . *Closing* gambar input  $A$  ke  $B$  membentuk elemen yang didefinisikan sebagai  $A \cdot B = (A \oplus B) \ominus B$  [3].

*Median filtering* adalah proses yang fokus pada nilai tengah atau *median* dari semua nilai piksel di sekelilingnya yang dimana proses ini dimulai dengan pengurutan nilai piksel tetangganya, setelah itu dipilih nilai tengahnya [11].

Untuk penelitian ini, data primer diperoleh dengan cara mengambil foto ubin keramik yang kemudian dijadikan sebagai dataset. Dataset tersebut kemudian akan dibagi menjadi dua kelompok, yaitu data *training* dan data *testing*. Pada penelitian ini, terdapat 190 data *training* dimana 86 data adalah untuk kelas gambar ubin keramik dengan kualitas yang baik dan 104 data adalah untuk kelas gambar ubin keramik dengan kualitas cacat. Adapun data *testing* berjumlah sebanyak 95 data yang dimana dari 43 data adalah untuk kelas gambar ubin keramik berkualitas baik dan 52 data adalah untuk kelas gambar ubin keramik berkualitas cacat.

Pada Gambar 1 yang ada di bawah ini, merupakan gambar rancangan model dalam menyelesaikan masalah pada penelitian.



Gambar 1. Rancangan Model Penelitian

Pengumpulan data dilakukan dengan cara mengambil gambar melalui kamera ponsel. Setelah itu, data dibagi menjadi dua kelompok: yang mana terdiri dari kelompok data *training* dan kelompok satunya adalah data *testing*. Langkah *preprocessing* diterapkan untuk memproses gambar dan mengekstrak karakteristiknya, menghapus *noise* dengan *median filtering* dan dilakukan teknik morfologi yang akan memperbaiki hasil dari segmentasi gambar. Selanjutnya, ciri-ciri diekstraksi berdasarkan tekstur dengan menggunakan metode Gray Level Co-Occurrence Matrix (GLCM) yang kemudian dilakukan klasifikasi menggunakan algoritma KNN dan SVM. Dengan cara ini, penelitian ini menghasilkan klasifikasi gambar ubin keramik tersebut apakah termasuk dalam kategori ubin keramik berkualitas baik ataukah berkualitas cacat, dan dapat mengetahui metode mana yang mampu memperoleh tingkat akurasi yang lebih tinggi sehingga dapat membantu meningkatkan kualitas hasil produksi.

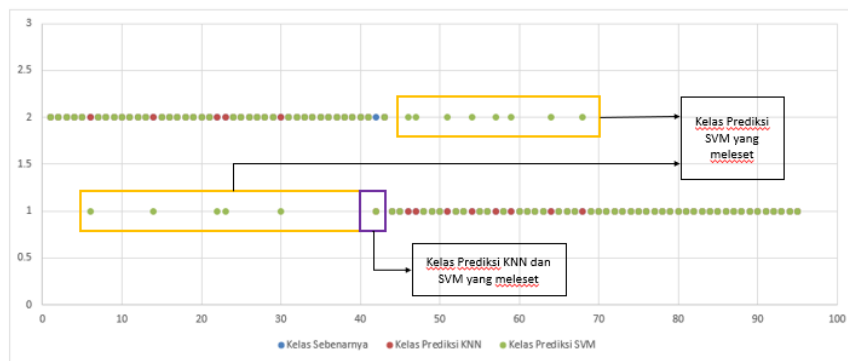
### 3. HASIL DAN PEMBAHASAN

Setelah dilakukan penelitian, baik pada data *training* maupun data *testing*, proses *preprocessing* dijalankan untuk mengekstrak karakteristiknya. Langkah-langkah ini termasuk penghilangan noise dengan median filtering guna meningkatkan kualitas gambar dan perbaikan hasil segmentasi gambar dengan teknik morfologi. Setelah itu, ekstraksi fitur berdasarkan tekstur dilakukan dengan GLCM. Selanjutnya, klasifikasi dilakukan dengan menggunakan algoritma KNN dan SVM untuk menentukan apakah gambar ubin keramik tersebut termasuk dalam kategori ubin keramik baik atau cacat.

Tabel 1. Contoh Hasil Klasifikasi Deteksi Cacat Ubin Keramik

No	Citra Asli	Median Filtering	Teknik Morfologi	GLCM				Hasil Klasifikasi
				Contrast	Correlation	Energy	Homogeneity	
1				0.1380	0.9558	0.6832	0.9888	Baik
2				0.4034	0.9549	0.2518	0.9685	Cacat

Tabel 1 yang ditampilkan merupakan hasil yang diperoleh dari klasifikasi pendeteksian cacat ubin keramik, di mana ubin keramik dengan nomor satu dikategorikan sebagai ubin keramik berkualitas baik dan ubin keramik dengan nomor dua dikategorikan sebagai ubin keramik yang memiliki kualitas cacat. Selanjutnya, hasil penelitian model deteksi secara keseluruhan dapat dilihat pada Gambar 2 di bawah ini.



Gambar 2. Grafik Hasil Penelitian Model Deteksi KNN dan SVM

Berdasarkan Gambar 2 dapat dikatakan bahwa dari 95 data uji terdapat 1 kesalahan prediksi pada metode KNN dan 14 kesalahan prediksi pada metode SVM.

Setelah model deteksi cacat pada ubin keramik terbentuk kemudian dilakukan pengujian terhadap model tersebut menggunakan metode *confusion matrix*. Selanjutnya, hasil pengujian model deteksi cacat pada ubin keramik menggunakan metode klasifikasi KNN untuk semua nilai  $k$  yang diuji dan metode klasifikasi SVM dapat dilihat dalam Tabel 3.

Tabel 3. Tingkat Akurasi Metode *K-Nearest Neighbor*

		KNN						SVM	
		Kelas Prediksi $k = 3$		Kelas Prediksi $k = 5 \text{ \& } 7$		Kelas Prediksi $k = 9, 11 \text{ \& } 13$		Kelas Prediksi	
		Baik	Cacat	Baik	Cacat	Baik	Cacat	Baik	Cacat
Kelas Sebenarnya	Baik	42	1	42	1	42	1	37	6
	Cacat	0	52	4	48	5	47	8	44
Tingkat Akurasi		98.947%		94.737%		93.684%		85.263%	

Berdasarkan yang tertera pada Tabel 3 di atas maka dapat disimpulkan bahwa diperoleh model deteksi cacat pada ubin keramik dengan klasifikasi KNN mencapai nilai yang memiliki akurasi tertinggi sebesar 98.947% saat nilai  $k=3$ . Artinya, model ini berhasil mengklasifikasikan hampir semua gambar ubin keramik dengan akurat.

Di sisi lain, model deteksi cacat ubin keramik dengan klasifikasi SVM mencapai nilai akurasi sebesar 85.263%. Meskipun nilai akurasi ini masih cukup baik, namun nilainya masih lebih rendah dibandingkan dengan KNN.

Hasil ini menunjukkan bahwa model *K-Nearest Neighbor* lebih unggul dalam mendeteksi cacat pada ubin keramik dalam penelitian ini, dengan akurasi yang lebih baik dan hasil yang lebih tinggi bila dibandingkan dengan model lain yaitu model *Support Vector Machine*.

#### 4. KESIMPULAN DAN SARAN

Berdasarkan hasil tersebut maka disimpulkan bahwa model yang dibangun dengan menggunakan metode KNN lebih akurat dalam mendeteksi cacat pada ubin keramik. Model KNN mampu memperoleh nilai akurasi sebesar 98.947% dengan nilai  $k=3$ , yang menunjukkan kemampuan yang sangat baik dalam mengklasifikasikan gambar ubin keramik dengan akurat.

Dalam perbandingan, metode SVM memperoleh nilai akurasi sebesar 85.263%, yang masih baik namun lebih rendah dibandingkan dengan KNN. Oleh karena itu, hasil dari penelitian menampilkan bahwa model KNN merupakan pilihan yang lebih baik untuk mendeteksi cacat pada ubin keramik dengan akurasi yang lebih tinggi dibandingkan dengan SVM.

Dengan demikian, penggunaan metode KNN dalam penelitian ini telah berhasil meningkatkan akurasi deteksi cacat pada ubin keramik, menjadikannya pilihan yang lebih unggul dalam melakukan klasifikasi gambar dengan tingkat ketepatan yang lebih tinggi.

#### DAFTAR PUSTAKA

- [1] D. Nazelliana dan P. Widodo, "Deteksi Cacat Ubin Keramik Dengan Metode Jaringa Saraf Tiruan dan Algoritma Backpropagation," *Fakt. Exacta*, vol. 7, no. 2, pp. 154–164, 2014.
- [2] K. Ragab dan N. Alsharay, "Developing Parallel Cracks and Spots Ceramic Defect Detection and Classification Algorithm using CUDA," in *2017 IEEE 13th International Symposium on Autonomous Decentralized System (ISADS)*, 2017, pp. 255–261.
- [3] R. Gonydjaja, Bertalya dan T. M. Kusuma, "Rectangularity Defect Detection for Ceramic Tile Using Morphological Techniques," *ARNP J. Eng. Appl. Sci.* 2014, vol. 9, no. 11, pp. 2052–2056, 2014.
- [4] K. Ragab dan N. Alsharay, "An Efficient Defect Classification Algorithm for Ceramic Tiles," in *ACIIDS 2017 : Advanced Topics in Intelligent Information and Database Systems*, 2017, vol. 710, pp. 235–247.
- [5] S. H. Hanzaei dan A. Afshar, "Automatic Detection and Classification of the Ceramic Tiles' Surface Defects," *Pattern Recognit.*, vol. 66, pp. 174–189, 2016.
- [6] Y. Samarawickrama dan C. Wickramasinghe, "Matlab based Automated Surface Defect Detection System for Ceramic Tiles using Image Processing," in *2017 6th National Conference on Technology and Management (NCTM)*, 2017, pp. 34–39.
- [7] R. Alamsyah, A.D. Wiranata dan Rafie, "Deteksi Cacat Ubin Keramik Dengan Metode K-Nearest Neighbor," *Techno.COM*, vol. 18, no. 3, pp. 245-250, 2019.
- [8] A. Johar, D. Yanosma dan K. Anggriani, "Implementasi Metode K-Nearest Neighbor (KNN) dan Simple Additive Weighting (SAW) dalam Pengambilan Keputusan Seleksi Penerimaan Aggota Paskibraka", *Jurnal Pseudocode*, vol. 3, no. 2, 2016.

- [9] R. Anggraini, B. Hidayat, dan S. Darana, “Klasifikasi Jenis Kualitas Keju Dengan Menggunakan Metode Gray Level Co-occurrence Matrix (GLCM) dan Support Vector Machine (SVM) Pada Citra Digital,” in *e-Proceeding of Engineering*, 2017, vol. 4, no. 2, pp. 2035–2042.
- [10] R. M. Haralick, K. Shanmugam, dan I. Dinstein, “Textural Features for Image Classification,” *IEEE*, vol. SMC-3, no. 6, pp. 610–621, 1973.
- [11] S. Iriyanto dan T. Zaini, *Pengolahan citra digital*. Bandar Lampung: Anugrah Utama Raharja, 2016.