

Deteksi Keaslian Uang Kertas Berdasarkan Fitur Gray Level CoOccurrence Matrix (GLCM) Menggunakan K-Nearest Neighbor

by Zilvanhisna Emka Fitri

Submission date: 07-Feb-2023 04:05PM (UTC+0700)

Submission ID: 2008413366

File name: Untitled19.pdf (1.94M)

Word count: 4203

Character count: 24239

Deteksi Keaslian Uang Kertas Berdasarkan Fitur Gray Level Co-Occurrence Matrix (GLCM) Menggunakan *k*-Nearest Neighbor

Defi Tamara¹, M. Haerul Anam², Wike Sri Widari³, Ardan Venora Falahudin⁴,
Widya Yuristika Oktavia⁵, Zilvanhisna Emka Fitri⁶, Aji Seto Arifianto⁷
Program Studi Teknik Informatika, Jurusan Teknologi Informasi, Politeknik Negeri Jember
Jl. Mastrip PO BOX 164, Kabupaten Jember 68121, Jawa Timur, Indonesia
Email: ¹defytamara2610@gmail.com, ²mhaerulanam603@gmail.com,
³wikesriwidari@gmail.com, ⁴ardanspaga@gmail.com, ⁵yuristikawidya@gmail.com,
⁶zilvanhisnaef@polije.ac.id, ⁷ajiset0@polije.ac.id

Abstract. *Rupiah is the currency of Indonesia. One form is rupiah banknotes. The issuance and circulation of rupiah banknotes are under the authority of Bank Indonesia (BI) as the central bank. Currently, many incidents of counterfeiting are troubling the public. One of the characteristics of the authenticity of money that has not yet been found in counterfeit money is invisible ink, which is an invisible print that can only be seen when the money is exposed to ultraviolet light. Behind it, prolonged exposure to ultraviolet light harms eye and skin health. A system for detecting the authenticity of banknotes was created to overcome these problems using image processing techniques. The research stages are literature study, collecting banknote images illuminated by ultraviolet light, image processing (rotation, cropping, and resizing), RGB color component solving, GLCM feature extraction, and classification using the *k*-Nearest Neighbor (KNN) method. The KNN method can classify the authenticity of banknotes with an accuracy of 88% using the values of $K = 3$ and 7 .*

Keywords: *Rupiah Banknotes, Authenticity of Money, Gray Level Co-occurrence Matrix, *k*-Nearest Neighbor*

Abstrak. *Rupiah merupakan mata uang Indonesia. Salah satu bentuknya adalah uang kertas rupiah. Penerbitan dan pengedaran uang kertas rupiah menjadi kewenangan Bank Indonesia (BI) sebagai bank sentral. Meski demikian, saat ini banyak kejadian pemalsuan uang yang meresahkan masyarakat. Salah satu ciri keaslian uang yang sampai saat ini belum ditemukan juga ada pada uang palsu ialah invisible ink, yaitu cetakan tidak kasat mata yang hanya terlihat ketika uang disinari cahaya ultraviolet. Dibalik hal itu, pancaran sinar ultraviolet yang berkepanjangan rupanya berbahaya bagi kesehatan mata dan kulit. Untuk mengatasi permasalahan tersebut, dibuatlah sistem pendeteksi keaslian uang kertas yang memanfaatkan teknik image processing. Tahapan penelitian yaitu studi literatur, pengumpulan citra uang kertas yang disinari sinar ultraviolet, pengolahan citra (rotasi, cropping, dan resize), pemecahan komponen warna RGB, ekstraksi fitur GLCM, dan klasifikasi dengan metode *k*-Nearest Neighbor (KNN). Metode KNN mampu mengklasifikasi keaslian uang kertas dengan perolehan akurasi 88% menggunakan nilai $K = 3$ dan 7 .*

Kata Kunci: *Uang Kertas Rupiah, Keaslian Uang, Gray Level Co-occurrence Matrix, *k*-Nearest Neighbor*

1. Pendahuluan

Kejadian pemalsuan uang saat ini semakin meningkat di Indonesia[1]. Pengertian uang palsu atau rupiah palsu berdasarkan Undang-Undang Nomor 7 Tahun 2011 tentang mata uang, rupiah palsu adalah suatu benda yang bahan, ukuran, warna, gambar, dan/atau desainnya menyerupai rupiah yang dibuat, dibentuk, dicetak, digandakan, diedarkan, atau digunakan sebagai alat pembayaran secara melawan hukum[2]. Uang kertas rupiah memiliki ciri-ciri keaslian yang dapat dilihat dengan dengan 3D (dilihat, diraba, diterawang). Namun hal tersebut masih kurang efektif, terbukti dengan masih banyaknya terjadi kasus penipuan uang kertas palsu di kalangan masyarakat. Penentuan keaslian uang kertas menggunakan panca indra dinilai kurang efektif dikarenakan penilaian setiap orang bersifat subyektif. Selain ciri-ciri yang terlihat secara

langsung, otentikasi keaslian uang kertas juga dapat dilakukan dengan melihat *invisible ink* pada uang asli yang hanya tampak ketika uang kertas disinari sinar *ultraviolet*.

Namun cara tersebut juga berdampak buruk bagi kesehatan. Berbagai penyakit seperti kanker kulit dan kerusakan mata, serta penurunan kekebalan tubuh, dapat terjadi akibat pemaparan sinar *ultraviolet* secara terus-menerus[3]. Oleh karena itu penulis melakukan penelitian yang bertujuan untuk mengurangi dampak dari proses pengamatan secara langsung tersebut dengan membuat sebuah sistem yang dapat mempelajari pola keaslian uang kertas berdasarkan *invisible ink* sehingga deteksi keaslian menjadi lebih baik dan akurat. Sistem tersebut menerapkan *image processing* (pengolahan citra) dengan tahapan penelitian yaitu studi literatur, pengumpulan citra uang kertas yang disinari sinar ultraviolet, pengolahan citra (rotasi, *cropping*, dan *resize*), pemecahan komponen warna RGB, ekstraksi fitur GLCM, dan klasifikasi dengan metode KNN sehingga dapat meniru mata manusia dalam menganalisa keaslian citra uang yang akan dideteksi.

2. Tinjauan Pustaka

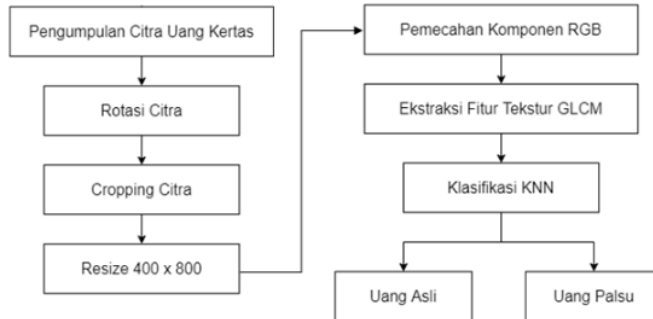
Penelitian ini mengacu pada beberapa penelitian yang dilakukan sebelumnya seperti pemanfaatan sensor warna TCS3200-DB[4] untuk mendeteksi nominal dan keaslian uang[5] untuk orang buta[6], mesin deteksi uang palsu menggunakan sensor LDR[7], Metode sistem cerdas KNN mampu mengklasifikasi keaslian uang dengan tingkat akurasi sebesar 87.75% berdasarkan sudut pengambilan gambar dan ukuran citra[8], identifikasi keaslian mata uang Rupiah menggunakan *Neural Learning*[1] yang memiliki hasil persentase keberhasilan uji coba untuk tahap otentifikasi yang tinggi yaitu sebesar 98.77%. Tetapi pola-pola lain yang ada pada penelitian tersebut seperti pola bacaan yang bukan pola citra uang harus dilatih juga agar sistem tidak dapat membacanya sebagai pola citra uang. Penggunaan Transformasi Fourier Diskrit (TFD) sebagai ekstraksi fitur adalah optimal, akan tetapi membutuhkan waktu yang relatif lama. Penelitian lain, analisis perbandingan metode LVQ dan *Backpropagation* dalam penentuan keaslian uang kertas Rupiah berbasis parameter HSV yang memiliki tingkat akurasi terbaik yaitu 100%[9]. Namun, jika dilihat dari nilai MSE, maka jaringan LVQ memiliki kinerja yang lebih baik karena nilai MSE yang dicapai adalah 0. Selain itu, terdapat penelitian lain yaitu deteksi keaslian uang kertas berdasarkan *watermark* dengan pengolahan citra digital dengan tingkat keberhasilan mencapai 85.71%[10]. Akan tetapi hasil dari deteksi tepinya kurang maksimal dikarenakan penempatan *watermark* yang saling tumpang tindih. Berdasarkan hasil sebuah penelitian, diperoleh kesimpulan bahwa perubahan variasi RST yang terdiri dari rotasi, skala dan translasi pada tekstur masukan (*input*) rupanya memiliki pengaruh yang besar terhadap proses pengenalan suatu tekstur yang menggunakan metode GLCM. Metode GLCM digunakan untuk mengenali ciri keaslian uang kertas rupiah menggunakan empat arah sudut (0°, 45°, 90° dan 135°)[11]. Selain fitur tekstur, proses segmentasi menggunakan penentuan nilai ambang (*threshold value*) juga dilakukan untuk pengenalan nilai nominal dan keaslian uang rupiah[12] begitu pula dengan metode *Local Binary Pattern* (LBP)[13].

Berdasarkan beberapa penelitian tersebut, maka untuk mendeteksi keaslian uang kertas menggunakan fitur tekstur GLCM dapat diterapkan metode klasifikasi yaitu KNN. Metode tersebut digunakan karena metode KNN telah terbukti dapat mengklasifikasi kerusakan mutu tomat[14], mengklasifikasi abnormalitas sel darah putih dengan akurasi sebesar 94.3%[15], mengklasifikasi bakteri tuberkulosis sebesar 94.92%[16], bakteri penyebab ISPA dengan akurasi sebesar 91.67%[17], abnormalitas trombosit[18] dan penyakit daun jeruk siam[19].

3. Metodologi Penelitian

Tahapan penelitian yang dikerjakan terdiri dari: studi literatur, pengumpulan dataset citra uang kertas yang disinari sinar *ultraviolet* (terdiri dari uang asli dan palsu), pengolahan citra (rotasi, *cropping*, dan *resize*), pemecahan komponen warna RGB, ekstraksi fitur GLCM, dan klasifikasi menggunakan metode KNN. Dataset yang digunakan dalam penelitian ini sebanyak 220 data *training*, yang terdiri dari 110 uang asli dan 110 uang palsu yang merupakan data primer yang diambil sendiri oleh peneliti. Pada gambar uang tersebut menunjukkan uang tampak depan

dan juga uang tampak belakang. Data *testing* yang digunakan sebanyak 34 yang terdiri dari dua kelas (kelas uang asli dan kelas uang palsu). Tahapan penelitian lebih jelasnya ditunjukkan oleh Gambar 1.



Gambar 1. Diagram Blok Deteksi Keaslian Uang Kertas Menggunakan KNN

3.1 Pengumpulan Citra Uang Kertas

Uang kertas Rupiah yang diterbitkan dan diedarkan oleh Bank Indonesia (BI) memiliki ciri-ciri berupa tanda-tanda khusus sebagai pengaman uang rupiah dari upaya pemalsuan[8]. Data pada penelitian ini merupakan data primer yang terdiri dari citra uang kertas Rupiah motif baru (tahun emisi 2016) mulai dari nominal Rp. 1.000 hingga Rp. 100.000 seperti pada Gambar 2.

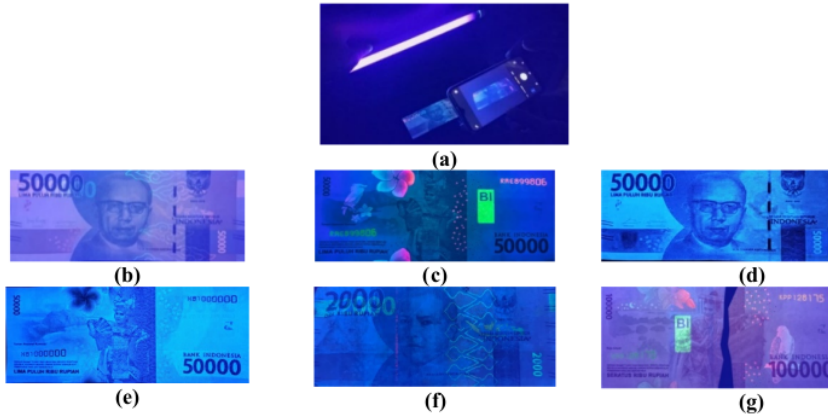


Gambar 2. Uang Kertas Rupiah Tahun Emisi 2016

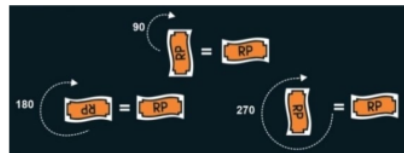
Proses pengambilan citra uang kertas dilakukan menggunakan kamera *smartphone* resolusi 13 MP berlatarbelakang gelap di ruangan tertutup. Untuk pencahayaan, menggunakan lampu *ultraviolet* (UV) Neon T5 8 Watt. Jarak pengambilan gambar atau citra antara objek uang kertas dengan kamera yaitu ± 13 cm. Uang yang kami gunakan terdiri dari uang asli sisi depan dan belakang, uang palsu sisi depan dan belakang, uang lusuh, serta uang terpotong hasil *editing* yang ditunjukkan oleh Gambar 3.

3.2 Rotasi Citra

Rotasi citra adalah teknik yang digunakan untuk merubah posisi citra (lihat Gambar 4). Pada saat melakukan rotasi, terdapat perubahan posisi piksel, namun tidak pada intensitasnya. Sebagai contoh pada sudut rotasi 90° , maka piksel baris disalin ke piksel kolom pada arah rotasi 90° . Selanjutnya rotasi 180° dapat dilakukan dengan menerapkan rotasi 90° sebanyak dua kali. Begitu juga pada rotasi 270° dapat dilakukan dengan menerapkan rotasi 90° sebanyak tiga kali.



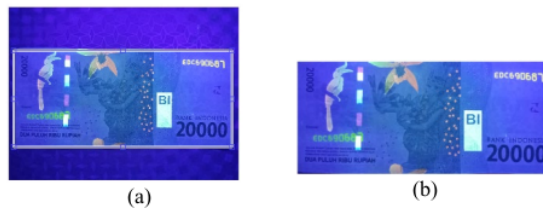
Gambar 3. (a) Proses Pengambilan Gambar atau Citra Uang Kertas (b) Uang Asli Tampak Depan (c) Uang Asli Tampak Belakang (d) Uang Palsu Tampak Depan (e) Uang Palsu Tampak Belakang (f) Uang Luluh (g) Uang Terpotong



Gambar 4. Gambaran Sudut Rotasi Image

3.3 Cropping Citra

Proses pemotongan (*cropping*) pada pengolahan citra diartikan sebagai memotong salah satu bagian dari citra sehingga didapatkan citra sesuai kebutuhan. Proses ini kemudian menghasilkan citra dengan ukuran sesuai bagian yang diambil[1]. Jenis *cropping* yang digunakan pada penelitian ini adalah bentuk segi empat (*rectangle*). Ukuran hasil *cropping* mengikuti bentuk uang yang sedang dideteksi, karena ukuran uang kertas setiap nominal berbeda-beda. Proses *cropping* citra dapat dilihat pada Gambar 5.



Gambar 5. (a) Proses Cropping Rectangle (b) Hasil Cropping

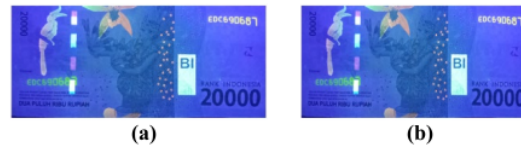
3.4 Resize

Proses *resize* atau mengubah ukuran dilakukan untuk menyamakan setiap citra inputan yang akan diproses[13]. Oleh karena itu, tahap ini dilakukan untuk menyamakan ukuran citra uang kertas yang akan dideteksi menjadi 400x800 piksel. Proses *resize* dapat dilihat pada Gambar 6.

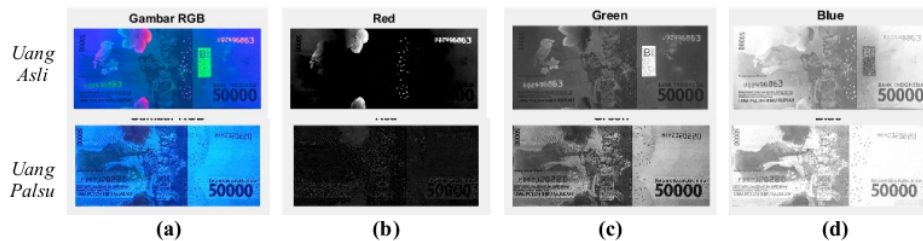
3.5 Pemecahan Komponen RGB

Citra yang diambil dengan kamera *smartphone* umumnya memiliki warna RGB. RGB merupakan model ruang warna yang memiliki 3 komponen warna yaitu : merah (*red*), hijau (*green*) dan biru (*blue*) pada setiap pikselnya. Ukuran citra RGB relatif besar yaitu 24 bit sehingga menyulitkan

proses segmentasi citra dan perlu dikonversikan ke ruang warna lain terlebih dahulu[11]. Pengurangan warna ini dapat mempermudah tahap selanjutnya yaitu proses ekstraksi fitur. Dari pemecahan komponen RGB pada Gambar 7, terlihat bahwa citra *green* lebih baik dalam menampilkan *invisible ink* pada citra uang asli. Oleh karena itu, citra kanal *green*-lah yang akan digunakan pada penelitian ini.



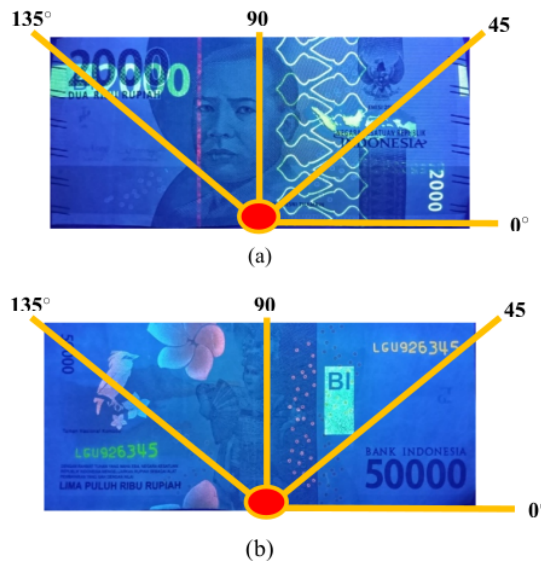
Gambar 6. (a) Citra Awal dan (b) Citra Hasil Resize



Gambar 7. (a) Citra RGB (b) Citra Red (c) Citra Green) dan (d) Citra Blue

3.6 Ekstraksi Fitur Tekstur GLCM

Gray Level Co-Occurrence Matrix (GLCM) merupakan salah satu metode ekstraksi fitur tekstur dengan adanya transisi *gray level* antara dua piksel menggunakan matriks *co-occurrence*. Matriks tersebut menunjukkan gambaran frekuensi munculnya pasangan 2 piksel dengan suatu intensitas dalam jarak d serta arah sudut θ tertentu[11]. Pengambilan empat sudut juga didasarkan pada letak *invisible ink* dengan ilustrasi yang dapat dilihat pada Gambar 8.



Gambar 8. Contoh Sudut Pada (a) Uang Tampak Depan dan (b) Uang Tampak Belakang

Berikut ini adalah berapa persamaan untuk mencari fitur GLCM[6]:

- a. ASM merupakan ukuran homogenitas citra atau penjumlahan pangkat dari elemen matriks GLCM (lihat Persamaan 1).

$$ASM = \sum_{i=1}^L \sum_{j=1}^L (GLCM(i,j))^2 \quad (1)$$

- b. Kontras atau disebut *inertia*, merupakan suatu ukuran intensitas aras keabuan antar piksel dengan lokasi relative (lihat Persamaan 2).

$$Kontras = \sum_{i=1}^L \sum_{j=1}^L (i-j)^2 GLCM(i,j) \quad (2)$$

- c. IDM atau disebut juga *homogeneity*, ialah homogenitas local yang berkaitan dengan kontras. Bobot IDM atau *homogeneity* adalah kebalikan dari bobot kontras (lihat Persamaan 3).

$$IDM = \sum_{i=1}^L \sum_{j=1}^L \frac{GLCM(i,j)}{1+(i-j)^2} \quad (3)$$

- d. Korelasi dalam ekstraksi fitur GLCM merupakan proses mengukur ketergantungan linear dari aras keabuan dalam ketetapan piksel citra (lihat Persamaan 4).

$$Korelasi = \frac{\sum_{i=1}^L \sum_{j=1}^L (i - \mu_i) * (j - \mu_j) * GLCM(i,j)}{\sigma_i * \sigma_j} \quad (4)$$

- e. Entropi adalah ukuran ketidakaturan dari aras keabuan yang ada pada suatu citra (lihat Persamaan 5).

$$Entropy = \sum_{i=1}^L \sum_{j=1}^L GLCM(i,j) \log GLCM(i,j) \quad (5)$$

3.7 *k-Nearest Neighbor (KNN)*

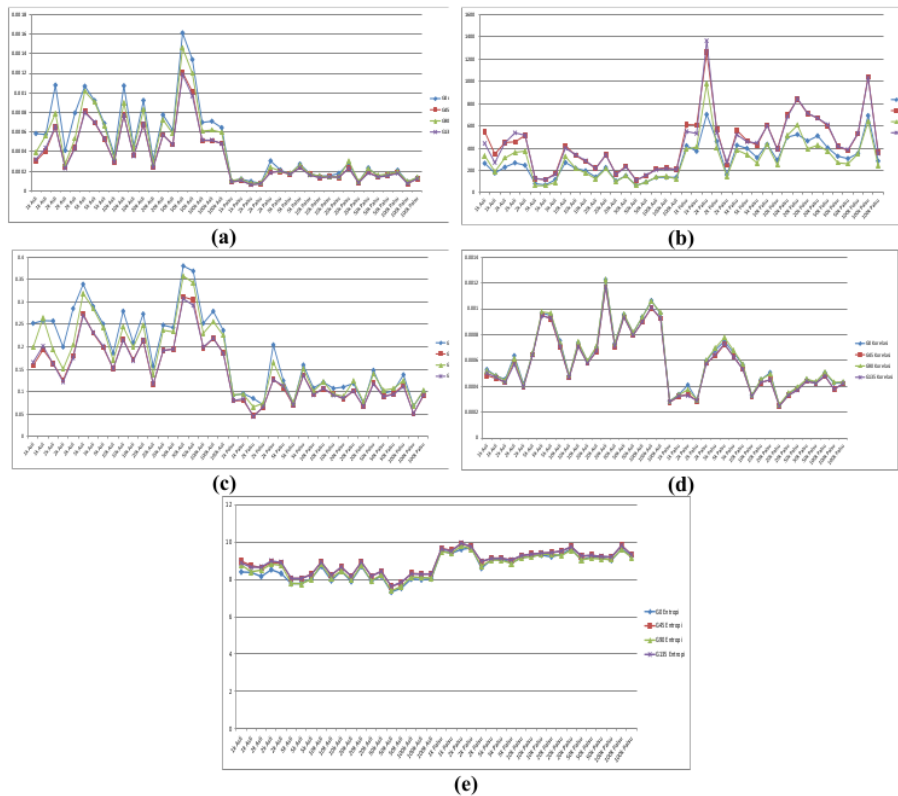
Metode KNN termasuk metode klasifikasi *supervised learning* dimana target pembelajarannya sudah diketahui. Metode KNN merupakan metode klasifikasi data berdasarkan parameter nilai *k* dengan perhitungan jarak terdekat. Perhitungan jarak terdekat tersebut umumnya dilakukan dengan persamaan rumus *Euclidean*[12] yang dapat dilihat pada Persamaan 6.

$$ED(A_i, A_j) = \sqrt{\sum_{r=1}^n (A_{ir} - A_{jr})^2} \quad (6)$$

dimana A_{ir} adalah data uji dan A_{ij} adalah data latih. Pada penelitian ini digunakan 14 parameter tersebut dijadikan inputan dalam perhitungan algoritma KNN, kemudian untuk output terdiri dari 2 kelas yaitu kelas uang asli dan kelas uang palsu.

4. Hasil dan Diskusi

Citra uang kertas yang akan dideteksi adalah citra yang sudah di-*cropping* dan di-*resize* menjadi ukuran 400x800 piksel. *Resize image* ini dilakukan untuk menyamakan ukuran citra yang akan diolah, karena ukuran uang kertas dari nominal Rp. 1.000 hingga Rp. 100.000 berbeda-beda serta hal tersebut dapat mempengaruhi proses komputasi. Selanjutnya pada proses pemecahan komponen warna RGB (lihat Gambar 7), citra yang paling baik dalam menampilkan *invisible ink* yaitu citra *green*. Selanjutnya citra *green* akan diekstraksi fitur teksturnya menggunakan ekstraksi fitur GLCM. Proses ekstraksi tersebut akan menghasilkan 14 parameter dengan total 4 fitur yaitu ASM, IDM, kontras, dan korelasi seperti yang ditunjukkan Tabel 1. Namun peneliti harus melakukan seleksi fitur untuk menentukan apakah kelima fitur tersebut cocok untuk digunakan pada citra uang, agar nantinya akurasi sistem ini lebih baik dengan fitur yang tepat. Gambar 9 menjelaskan hasil ekstraksi kelima fitur diambil dari 4 sudut.



Gambar 9. (a) ASM, (b) Kontras, (c) IDM, (d) Korelasi, (e) Entropi

Dari keempat grafik pada Gambar 9, ASM, kontras dan IDM akan digunakan dari keempat sudutnya karena perbedaannya sangat signifikan. Korelasi hanya akan diambil dari sudut 90° dan 135°, karena grafiknya terlihat berhimpitan. Kedua sudut tersebut sudah mewakili dua sudut lainnya yakni 0° dan 45°. Sedangkan entropi tidak akan digunakan karena grafiknya cenderung mendatar dan tidak ada perbedaan signifikan antara hasil fitur pada uang asli dan palsu.

Tabel 1. Contoh Hasil Ekstraksi Fitur GLCM

	ASM	IDM	Kontras	Korelasi
0°	0.00223527	0.385975	68.3206	-
45°	0.00185716	0.339717	106.371	-
90°	0.00218063	0.383097	58.4137	0.000891886
135°	0.00184466	0.337372	106.279	0.000871649

Hasil ekstraksi fitur tekstur GLCM yang terdiri dari 14 parameter, akan digunakan sebagai inputan dalam perhitungan algoritma *k-Nearest Neighbor* (kNN). Setiap nilai akan dibandingkan dengan hasil ekstraksi fitur pada 220 data *training*. Selanjutnya akan dilakukan perankingan berdasarkan jarak *Euclidean* yang terdekat sesuai *k* yang ditentukan. Untuk mengklasifikasikan data, langkah pertama yang harus dilakukan adalah menghitung nilai jarak terdekat antara data baru dapat dilihat pada Tabel 3 dengan masing-masing data training dapat dilihat pada Tabel 2 menggunakan persamaan rumus *Euclidean*. Selanjutnya hasil perhitungan diurutkan mulai dari nilai jarak terkecil sampai nilai jarak terbesar dan dapat dilihat pada Tabel 4. Setelah itu tentukan nilai *k* sebagai parameter dalam metode KNN, kemudian data tersebut akan diklasifikasikan sesuai kelas prioritas yang termasuk ke dalam parameter nilai *k*.

Tabel 2. Contoh Hasil Ekstraksi Fitur dan Klasifikasi Pada Data Training 90°

ASM	Kontras	IDM	Korelasi	Kelas
0.002338858	43.57184418	0.412091162	0.001039499	Asli
0.002140254	53.13299895	0.385478336	0.000874493	Asli
0.002214285	33.72960668	0.426426402	0.001073856	Asli
0.001210005	55.02880002	0.346016459	0.00098641	Asli
0.001564292	21.66094885	0.402401819	0.001275322	Asli
0.000170116	431.7442633	0.101389303	0.000570411	Palsu
0.000153066	249.5053463	0.122161232	0.000331925	Palsu
0.00014139	515.9804977	0.094993309	0.00045304	Palsu
0.000143303	607.2015151	0.08971713	0.000493894	Palsu
0.000302878	393.7147674	0.124261034	0.000258495	Palsu

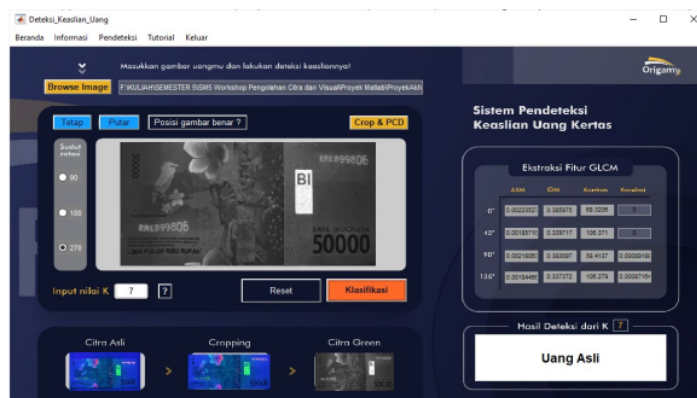
Tabel 3. Contoh Data yang Belum Diklasifikasikan

ASM	Kontras	IDM	Korelasi	Kelas
0.00218063	58.4137	0.383097	0.000891886	?

Tabel 4. Contoh Hasil Perhitungan Jarak Euclidean

Data ke-	Jarak Euclidean (ED)	Nilai Jarak Euclidean	Kelas
41	ED1	136.9929426	Asli
52	ED2	137.1787095	Asli
59	ED3	137.2796718	Asli
69	ED4	138.077249	Asli
36	ED5	138.3019574	Asli
66	ED6	138.5092026	Asli
57	ED7	138.9958551	Asli
61	ED8	139.5743339	Asli
68	ED9	139.6111138	Asli
50	ED10	139.8695527	Asli
...
201	ED218	2067.442705	Palsu
101	ED219	2104.831638	Asli
113	ED220	2111.40295	Palsu

Diasumsikan k ditentukan dengan nilai 7, maka dari hasil pengurutan jarak *Euclidean* di atas, sistem akan mengambil kelas prioritas dari 7 jarak terdekat atau teratas. Pada Tabel 4, kita dapat melihat bahwa 7 kelas terdekat semuanya termasuk kelas Asli. Maka data pada Tabel 3 akan diklasifikasikan ke dalam kelas Asli. Sebaliknya apabila pada kasus berbeda dengan $k = 7$, dan diperoleh 4 kelas Palsu dan 3 kelas Asli, maka kelas yang akan dipilih sebagai hasil klasifikasi adalah kelas prioritas atau kelas terbanyak yaitu Palsu. Tampilan aplikasi deteksi keaslian uang ditunjukkan oleh Gambar 10.



Gambar 10. Tampilan Menu Pendeteksi Keaslian Uang

Penelitian ini menggunakan beberapa parameter nilai k yang terdiri dari: 3, 5, 7, 9, 11, 13, dan 15. Penggunaan nilai k ganjil dikarenakan data *training* yang berjumlah genap. Nilai k ganjil dapat memudahkan memilih kelas prioritas, sebagai contoh jika pada $k = 3$ terdapat 2 kelas Asli dan 1 kelas Palsu, maka sistem akan memilih kelas Asli sebagai kelas prioritas. Berbeda halnya jika menggunakan k genap, maka bisa terdapat kemungkinan besaran prioritas yang sama antara 2 kelas. Penentuan nilai k yang berbeda-beda juga dilakukan untuk melihat akurasi terbaik dari penerapan metode KNN. Dari hasil perhitungan metode KNN yang dilakukan (dapat dilihat pada Tabel 5), diperoleh akurasi sistem terbaik pada data *training* dan data *testing* yaitu dengan $k = 3$, dengan persentase akurasi sebesar 94% dan 88%. Akurasi terbaik pada data testing juga terdapat pada $k = 7$, dimana memiliki nilai akurasi serupa dengan $k = 3$ yaitu 88% pada data testing.

Tabel 5. Hasil Akurasi Sistem Berdasarkan Variasi Nilai K

Fitur	Persentase Akurasi Tertinggi (%)			
	Nilai k	Training	Nilai k	Testing
ASM, IDM, Kontras + Korelasi 90° dan 135°	3	94%	3	88%
ASM, IDM, Kontras + Korelasi 90° dan 135°	5	90%	5	85%
ASM, IDM, Kontras + Korelasi 90° dan 135°	7	89%	7	88%
ASM, IDM, Kontras + Korelasi 90° dan 135°	9	89%	9	82%
ASM, IDM, Kontras + Korelasi 90° dan 135°	11	86%	11	82%
ASM, IDM, Kontras + Korelasi 90° dan 135°	13	85%	13	82%
ASM, IDM, Kontras + Korelasi 90° dan 135°	15	84.1%	15	82%

Perhitungan akurasi pengujian dengan *confusion matrix* pada 34 data uji dengan variasi nilai $k = 3$ ditunjukkan pada Tabel 6.

Tabel 6. Confusion Matrix pada Data Uji

Hasil Klasifikasi		Target
Uang Asli	Uang Palsu	
15	2	Uang Asli
2	15	Uang Palsu

TP = 15 ; TN = 15 ; FP = 2 ; FN = 2

$$\text{Akurasi Sistem} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% = \frac{15 + 15}{15 + 15 + 2 + 2} \times 100\% = \frac{30}{34} \times 100\% = 88\%$$

Tabel 6 menunjukkan bahwa dari 17 data uang asli, sebanyak 15 data diklasifikasikan benar sesuai target yaitu uang asli dan 2 data diklasifikasikan tidak sesuai target yaitu uang palsu. Kemudian dari 17 data uang palsu, sebanyak 15 data diklasifikasikan benar sesuai target yaitu uang palsu dan 2 data diklasifikasikan tidak sesuai target yaitu uang asli. Dari hasil perhitungan akurasi, dapat disimpulkan bahwa metode KNN dapat melakukan klasifikasi keaslian uang kertas rupiah dengan baik. Kesalahan-kesalahan KNN dalam mengklasifikasi citra uang kertas disebabkan oleh adanya perbedaan citra yang dideteksi, dimana terdapat uang lusuh yang *invisible ink*-nya tidak begitu tampak. Oleh karena itu, diperlukan penambahan data training yang lebih banyak dan bervariasi khususnya citra uang lusuh, sehingga uang tersebut dapat terdeteksi dengan baik. Selain itu, juga dapat ditambahkan fitur hasil ekstraksi sehingga masing-masing kelas dapat memiliki lebih banyak parameter yang beragam untuk memudahkan metode KNN dalam mengenali pola serta mengidentifikasi keaslian uang kertas dengan lebih spesifik. Kemudian juga dapat dilakukan perbandingan menggunakan metode klasifikasi selain KNN guna menghasilkan akurasi yang lebih baik.

5. Kesimpulan dan Saran

Pada penelitian ini, jumlah data yang digunakan yaitu 220 data *training* dan 34 data *testing* yang terdiri dari dua kelas (kelas uang asli dan kelas uang palsu). Dari hasil klasifikasi sistem, diperoleh kesimpulan bahwa metode KNN dapat melakukan klasifikasi keaslian uang kertas dengan akurasi 88% menggunakan nilai $k = 3$ dan 7. Kesalahan klasifikasi disebabkan kurangnya variasi data training, terdapat kemiripan nilai hasil ekstraksi fitur pada masing-masing kelas, dan kurang optimalnya pengenalan *invisible ink* pada uang lusuh. Oleh karena itu, maka dibutuhkan penambahan data training yang lebih banyak dan bervariasi, serta adanya penambahan maupun perbaikan fitur agar pengenalan pola dan pengindentifikasian uang kertas menjadi lebih tepat. Selain itu perlu dilakukan perbandingan dengan metode klasifikasi selain metode KNN supaya didapatkan metode terbaik dan paling akurat dalam melakukan klasifikasi keaslian uang kertas.

Referensi

- [1] S. Annisa, Z. Lubis, dan A. Najmita, "Perancangan Aplikasi Jaringan Syaraf Tiruan (Neural Networks) Untuk Pedeteksi Keaslian Uang Kertas," *J. Electr. Technol.*, vol. 5, no. 1, hal. 1–8, Feb 2020.
- [2] T. Rakhmadsyah dan A. Hadi, "Tindak Pidana Pemalsuan Uang Sebagai Kejahatan Terorganisir (Suatu Penelitian di Wilayah Hukum Pengadilan Negeri Banda Aceh)," *J. Ilm. Mhs. Bid. Huk. Pidana*, vol. 2, no. 2, hal. 287–296, Mei 2018.
- [3] J. M. Jabar dan S. Nursafitri, "Tingkat Pengetahuan Petani Tentang Sinar UV Terhadap Kesehatan Mata," *J. Sehat Masada*, vol. 13, no. 1, hal. 32–39, 2019.
- [4] R. Albar dan A. Darmawan, "Alat Deteksi Nominal Uang Kertas Rupiah & Dollar Bagi Penyandang Tunanetra Berbasis Arduino Uno," *J. Informatics Comput. Sci.*, vol. 7, no. 1, hal. 46–55, 2021.
- [5] M. Muhammad, M. Yusro, dan P. Yuliatmojo, "Simple smart glasses based on microcontrollers as money detector of nominal and authenticity," *J. Phys. Conf. Ser.*, vol. 1402, no. 4, 2019, doi: 10.1088/1742-6596/1402/4/044016.
- [6] W. Kunto Aji, M. Ulum, dan A. N. Afifah, "Money Authenticity Detector Design Using Artificial Neural Network Method for Blinds," *J. Phys. Conf. Ser.*, vol. 1569, no. 3, 2020, doi: 10.1088/1742-6596/1569/3/032082.
- [7] S. Maharani, J. E. Hutagalung, dan A. K. Syahputra, "Mesin Pendeteksi Uang Palsu Dengan Sensor LDR Berbasis Kecerdasan Buatan," vol. 4, no. 2, hal. 740–748, 2022, doi: 10.47065/bits.v4i2.2102.
- [8] C. Rahmad, E. Rohadi, dan R. A. Lusiana, "Authenticity of money using the method KNN (K-Nearest Neighbor) and CNN (Convolutional Neural Network)," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 1073, no. 1, hal. 012029, 2021, doi: 10.1088/1757-899x/1073/1/012029.
- [9] D. M. Adhitama, "Perancangan Detektor Nominal Dan Keaslian Uang Kertas Dengan Menggunakan Template Matching Dan K-Nearest Neighbor (KNN)," Universitas Telkom, Bandung, 2013.
- [10] A. R. Pambudi, Garno, dan Purwantoro, "Deteksi Keaslian Uang Kertas Berdasarkan Watermark dengan Pengolahan Citra Digital," *JIP (Jurnal Inform. Polinema)*, vol. 6, no. 4, hal. 69–74, 2020.
- [11] F. H. Sekarani, Jayanta, dan N. Chamidah, "Mengenali Keaslian Mata Uang Kertas Rupiah dengan Penerapan Metode Support Vector Machine," in *Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA)*, 2020, hal. 574–584.
- [12] R. Ramadhan, J. Y. Sari, dan I. P. Ningrum, "Identification of Authenticity and Nominal Value of Indonesia Banknotes Using Fuzzy KNearest Neighbor Method," *IJNMT (International J. New Media Technol.)*, vol. 6, no. 1, hal. 32–37, 2019, doi: 10.31937/ijnmt.v6i1.989.
- [13] M. Miladiyah, R. Umar, dan I. Riadi, "Implementasi Local Binary Pattern untuk Deteksi Keaslian Mata Uang Rupiah," *J. Edukasi dan Penelit. Inform.*, vol. 5, no. 2, hal. 197, 2019, doi: 10.26418/jp.v5i2.32721.

- [14] N. E. Paulina, Z. E. Fitri, A. Madjid, dan A. M. Imron, "Klasifikasi Kerusakan Mutu Tomat Berdasarkan Seleksi Fitur Menggunakan K-Nearest Neighbor," *MIND (Multimedia Artif. Intell. Netw. Database) J.*, vol. 6, no. 2, hal. 144–154, Des 2021, doi: 10.26760/mindjournal.v6i2.144-154.
- [15] Z. E. Fitri dan A. M. N. Imron, "Classification of White Blood Cell Abnormalities for Early Detection of Myeloproliferative Neoplasms Syndrome Using Backpropagation," in *Proceedings of the 1st International Biomedical Engineering, on Electronics, Conference and Health Informatics*, 2021, vol. 746, hal. 499–507, [Daring]. Tersedia pada: <https://link.springer.com/10.1007/978-981-33-6926-9>.
- [16] L. N. Sahenda, M. H. Pumomo, I. K. E. Pumama, dan I. D. G. H. Wisana, "Comparison of Tuberculosis Bacteria Classification from Digital Image of Sputum Smears," *2018 Int. Conf. Comput. Eng. Netw. Intell. Multimedia, CENIM 2018 - Proceeding*, hal. 20–24, 2018, doi: 10.1109/CENIM.2018.8711386.
- [17] Z. E. Fitri, L. N. Sahenda, P. S. D. Puspitasari, P. Destarianto, D. L. Rukmi, dan A. M. N. Imron, "The Classification of Acute Respiratory Infection (ARI) Bacteria Based on K-Nearest Neighbor," *Lontar Komput.*, vol. 12, no. 2, hal. 91–101, Agu 2021.
- [18] Z. E. Fitri, I. K. E. Pumama, E. Pramunanto, dan M. H. Purnomo, "A comparison of platelets classification from digitalization microscopic peripheral blood smear," *2017 Int. Semin. Intell. Technol. Its Appl. Strength. Link Between Univ. Res. Ind. to Support ASEAN Energy Sect. ISITIA 2017 - Proceeding*, vol. 2017-Janua, hal. 356–361, 2017, doi: 10.1109/ISITIA.2017.8124109.
- [19] R. H. Ariesdianto, Z. E. Fitri, A. Madjid, dan A. M. N. Imron, "Identifikasi Penyakit Daun Jeruk Siam Menggunakan K-Nearest Neighbor," *J. Ilmu Komput. dan Inform.*, vol. 1, no. 2, hal. 133–140, Des 2021, [Daring]. Tersedia pada: <https://jiki.jurnal-id.com>.

Deteksi Keaslian Uang Kertas Berdasarkan Fitur Gray Level CoOccurrence Matrix (GLCM) Menggunakan K-Nearest Neighbor

GRADEMARK REPORT

FINAL GRADE

/0

GENERAL COMMENTS

Instructor

PAGE 1

PAGE 2

PAGE 3

PAGE 4

PAGE 5

PAGE 6

PAGE 7

PAGE 8

PAGE 9

PAGE 10

PAGE 11