

MENGENALI KEASLIAN MATA UANG KERTAS RUPIAH DENGAN PENERAPAN METODE SUPPORT VECTOR MACHINE

Fahira Hafiih Sekarani¹, Jayanta², Nurul Chamidah³
Fakultas Ilmu Komputer

Universitas Pembangunan Nasional Veteran Jakarta
Jl. RS. Fatmawati, Pondok Labu, Jakarta Selatan, DKI Jakarta, 12450, Indonesia
fahirahafiih@gmail.com¹, jayanta@upnvj.ac.id², nurul.chamidah@upnvj.ac.id³

Abstrak. Uang kertas rupiah masih tetap digunakan dikala masa uang digital telah masuk di Indonesia. Uang kertas mempunyai nilai karena nominal dan hal itu yang juga terhubung dengan identifikasi keaslian uang itu menjadi suatu alat tukar yang sah. Bisa kita lihat bahwa dengan tetapnya penggunaan uang kertas, masih adanya kasus pemalsuan uang. Untuk menciptakan solusi dari masalah itu, dengan penggunaan pengolahan citra, pada penelitian ini dirancang sebuah model yang dapat digunakan untuk mengetahui keaslian uang kertas rupiah menggunakan metode *Support Vector Machine*. Penelitian ini dilakukan berdasarkan unsur tekstur keseluruhan uang yang dilihat dengan *Gray Level Co-occurrence Matrix* menggunakan empat arah sudut (0° , 45° , 90° , 135°) dengan jarak piksel $d=1$. Hasil penelitian yang telah dilakukan menghasilkan performa yang baik dalam mengenali keaslian uang kertas rupiah. Dari penggunaan kernel *Gaussian* dan *Polynomial*, hasil terbesar didapat dengan kernel *Polynomial* dengan rata-rata akurasi yang didapat sebesar 95%, *sensitivity* sebesar 98%, dan *specificity* sebesar 92%.

Kata Kunci: Uang Kertas Rupiah, *Gray Level Co-occurrence Matix*, *Support Vector Machine*.

1 Pendahuluan

Menggunakan uang elektronik pada masa sekarang ini belum bisa menggantikan sepenuhnya uang tunai kertas. Ada faktor yang paling penting dalam penggunaan uang elektronik, yaitu jaringan yang untuk saat ini masih belum mendukung sepenuhnya penggunaan jaringan karena kualitasnya masih belum cepat secara merata di Indonesia. Karena hal tersebut, mengakibatkan penggunaan uang kertas sebagai alat tukar tetap digunakan masyarakat Indonesia untuk kebutuhan sehari-hari dalam proses transaksi. Namun tanpa kita sadari oknum pemalsuan uang kertas rupiah masih kerap terjadi di Indonesia karena masih besarnya keuntungan dari pemalsuan uang, walaupun ada hukum yang berlaku.

Dalam hal menghindarkan diri kita dari penggunaan ataupun mendapatkan uang palsu, kita harus mengetahui dan memahami keaslian uang berdasarkan ciri keaslian uang yang bisa dilihat secara mendetail melalui unsur-unsur pengaman uang itu sendiri. Dalam satu lembar uang kertas, cukup banyak unsur pengaman yang terkandung didalamnya. Dari banyaknya unsur pengaman tersebut, dalam penelitian ini unsur yang digunakan yaitu bahan dan cetak khusus yang saling terhubung terhadap tekstur yang dilihat. Data yang digunakan yaitu data primer berupa citra uang kertas rupiah Tahun Emisi 2016 sejumlah 100 citra dengan nominal uang yaitu Rp 50.000,00 dan Rp 100.000,00 karena pada nominal tersebut, paling banyak kasus pemalsuan uang ditemukan dan memiliki keuntungan yang lebih besar dibanding nominal uang yang lainnya. Jika kita lihat dari penelitian terdahulu yang dilakukan oleh Asriel et al [1], telah dilakukan penelitian terhadap uang kertas rupiah untuk mengenali nominal dan keaslian uang dari unsur pengaman *visible ink* dengan penyinaran ultra violet dengan metode *Support Vector Machine* dan ekstraksi ciri dengan *Gray Level Co-occurrence Matrix*, didapat hasil yaitu nilai akurasi kernel *Gaussian* sebesar 100% dan *Polynomial* sebesar 99%. Sama halnya dengan penelitian yang dilakukan oleh Neneng, Adi, dan Isnanto [4] dalam mengklasifikasikan citra jenis daging berupa daging kuda, kerbau, kambing dan sapi, dengan penggunaan metode *Support Vector Machine* dan ekstraksi ciri *Gray Level Co-occurrence Matrix* dengan fitur nilai *angular second moment*, *contrast*, *inverse different moment*, *entropy*, dan *correlation* ditambah dengan jarak piksel tetangga dan jarak pengambilan citra yang berbeda dan penggunaan kernel yang dipakai yaitu kernel RBF

(*Gaussian*) menghasilkan sistem pengenalan terbaik dengan tingkat pengenalan sebesar 87,5% dengan jarak pengambilan 20 cm dan jarak piksel $d=2$.

Maka dari itu, dari adanya penelitian yang telah dilakukan sebelumnya yang berkaitan dengan hal mengenali keaslian uang kertas rupiah yang lebih mendalam, dilakukan penelitian ini dengan metode *Support Vector Machine*, yaitu salah satu metode *machine learning* yang bekerja dengan prinsip *Structural Risk Minimization (SRM)*. Metode ini pada prinsipnya digunakan untuk mengklasifikasi secara *linear classifier* dengan menemukan *hyperplane* sebagai fungsi pemisah yang paling optimal. Sebelum dilakukannya proses identifikasi, tentunya perlu dilakukan ekstraksi ciri sebagai imputan kedalam metode agar mendapatkan model penelitian. Ekstraksi ciri yang digunakan menggunakan *Gray Level Co-occurrence Matrix* untuk mendapatkan ciri dari tekstur uang dengan fitur yang digunakan yaitu *contrast*, *correlation*, *energy*, dan *homogeneity* dengan jarak piksel $d=1$ dan sudut yang dipakai yaitu $0^\circ, 45^\circ, 90^\circ, 135^\circ$. Sehingga setelah ciri tersebut dimasukkan kedalam model dengan metode *Support Vector Machine*, dengan menggunakan kernel *Gaussian* dan *Polynomial* akan terlihat bagaimana performa metode *Support Vector Machine* dalam mengidentifikasi uang kertas rupiah yang masuk ke kelas asli atau palsu.

2. Metodologi Penelitian

2.1 Ekstraksi Ciri

Ekstraksi ciri yaitu proses mendapatkan ciri atau informasi yang berasal dari objek yang biasanya dari ciri itu dapat membedakan antara objek satu dengan objek lainnya [8]. Proses ini merupakan proses yang penting dalam mengidentifikasi atau mengklasifikasi suatu citra karena nantinya ciri yang telah didapat akan menjadi variabel input. Dalam mendapatkan ciri untuk metode yang dipakai yaitu dengan penggunaan metode *Gray Level Co-occurrence Matrix (GLCM)* yaitu suatu metode untuk menganalisis tekstur objek sehingga mendapatkan ciri dari objek tersebut, yang digambarkan dalam suatu matriks dari hubungan piksel yang saling berpasangan dalam arah dan jarak tertentu [7]. Pada GLCM terdapat empat arah yang dipakai dalam proses ekstraksi ciri, yaitu 0° (horizontal), 45° (diagonal positif), 90° (vertikal), dan 135° (diagonal negatif). Terdapat tahapan yang dilakukan dalam perhitungan GLCM [10]. Tahapannya adalah sebagai berikut.

1. Pembentukan matriks awal GLCM dari pasangan dua piksel yang sejajar sesuai arah $0^\circ, 45^\circ, 90^\circ, 135^\circ$.
2. Membentuk matriks yang simetris dengan menjumlahkan matriks awal GLCM dengan nilai transposenya.
3. Menormalisasikan matriks GLCM dengan membagi setiap elemen matriks dengan jumlah pasangan piksel.
4. Dari matriks normalisasi, dilakukan penerapan kepada fitur GLCM yaitu *contrast*, *correlation*, *energy*, dan *homogeneity* sesuai jarak dan arah yang diteliti.

Berikut formula yang digunakan untuk fitur GLCM.

1. *Contrast*, yaitu hasil dari jumlah citra yang beragam dalam intensitas keabuan.

$$f_1 = \sum_i \sum_j (i-j)^2 P_d(i,j) \quad (1)$$

2. *Correlation*, yaitu hubungan linear tetangga pada citra *grayscale*.

$$f_2 = \sum_i \sum_j \frac{(i-\mu_i)(j-\mu_j)p(i,j)}{\sigma_i \sigma_j} \quad (2)$$

3. *Energy*, yaitu banyaknya intensitas keabuan yang berbeda dalam citra.

$$f_3 = \sum i, j P_2^d(i, j) \quad (3)$$

4. *Homogeneity*, yaitu intensitas citra dalam variasi yang sama.

$$f_4 = \sum i \sum j \frac{Pd(i, j)}{i + |i - j|} \quad (4)$$

Dimana :

$p(i, j)$ = nilai pada baris i dan kolom j pada matriks kookurensi

Metode GLCM adalah metode yang sudah terbukti menjadi kriteria yang menjelaskan tekstur secara efektif [9] serta kemampuan akurasi yang lebih baik dibandingkan metode ekstraksi tekstur yang lainnya.

2.2 Normalisasi Data

Agar pada hasil klasifikasi dan akurasi pada citra diperoleh nilai yang baik, maka data citra dilakukan normalisasi. Hal ini bertujuan untuk nilai pada fitur memiliki nilai rata 0 (*zero mean*). Penggunaan metode normaisasi dengan metode *min-max* dengan persamaan sebagai berikut.

$$\text{Norm} = \frac{Xa - Xmin}{Xmax - Xmin} * (ba - bw) + bw \quad (5)$$

Dimana :

Norm = nilai setelah di normalisasi
Xa = nilai pada data asli (belum di normalisasi)
Xmin = nilai terkecil di atribut
Xmax = nilai terbesar di atribut
ba = batas atas
bw = batas bawah

2.3 K-Fold Cross Validation

K-fold Cross Validation adalah metode menemukan nilai parameter dari rata-rata nilai yang telah menjadi nilai uji dan latih yang terdapat nilai k untuk membagi data dan mengalami proses pengulangan [2]. Dibandingkan dengan memilih secara acak data mana saja yang akan menjadi data uji atau data latih, menggunakan metode ini bisa mendapatkan nilai parameter dari rata-rata nilai yang telah diteliti karena setiap data merasakan menjadi data uji dan data latih. Tujuannya adalah mengetahui apakah sistem berhasil dalam penggunaannya dengan pengulangan data sejumlah k kali dalam prosesnya. Dalam proses pengujian, rasio data menampilkan k yang semakin besar dalam penggunaannya, maka data latih akan semakin banyak, tidak lupa juga pada hasil akurasi dipengaruhi oleh komposisi kelas jumlah data latih dan uji [3]. Dari jumlah keseluruhan data yang digunakan yaitu sebanyak 100 data, pada penelitian ini menggunakan nilai $k=10$, sehingga didapat data latih sebanyak 90 data dan data uji sebanyak 10 data yang dilakukan sebanyak 10 kali secara berulang dengan masing-masing data merasakan menjadi data uji maupun data latih.

2.4 Support Vector Machine

Support Vector Machine adalah metode *learning machine* yang cara kerjanya dengan prinsip *Structural Risk Minimization* (SRM) untuk memperoleh *hyperplane* yang paling optimal pemisah dua buah kelas di input *space* [5]. *Hyperplane* terbaik terletak tepat ditengah dua set objek dari dua kelas. Sebuah data yang letaknya di margin adalah *support vector*. Pada ruang yang dimensi nya tinggi, *hyperplane* yang dicari adalah maksimum jarak antara kelas data yang dapat dihitung

dengan $\frac{2}{\|w\|}$. Untuk memperoleh perhitungan *hyperplane* bisa menggunakan persamaan berikut [6].

$$f: w \cdot x + b = 0 \quad (6)$$

atau

$$f = \sum_{i=1}^m a_i y_i K(x, x_i) + b \quad (7)$$

Dengan menghitung b dan w dengan persamaan berikut.

$$b = -\frac{1}{2} (w \cdot x^+ + w \cdot x^-) \quad (8)$$

$$w = \sum_{i=1}^N \sigma_i y_i x_i \quad (9)$$

Dimana :

- f = fungsi *hyperplane*
- w = garis tegak lurus antara garis *hyperplane* dan titik *support vector*
- b = nilai bias
- x = data input SVM
- m = jumlah *support vector*
- a_i = bobot nilai tiap titik data
- x_i = himpunan data latih
- y_i = label kelas x_i
- $K(x, x_i)$ = fungsi kernel
- N = banyaknya data
- $c, d, \sigma > 0$ = konstanta

Apabila pada data *non linear* menggunakan pendekatan kernel untuk memetakan dimensi rendah ke tinggi. Pada penelitian ini kernel yang digunakan yaitu kernel *Gaussian* dan *Polynomial* dengan formulasi sebagai berikut.

1. Kernel *Gaussian*

$$K(x_i, x_j) = \left(\frac{\|x_i - x_j\|^2}{2\sigma^2} \right) \quad (10)$$

2. Kernel *Polynomial*

$$K(x_i, x_j) = ((x_i \cdot x_j) + c)^d \quad (11)$$

Dimana :

- $K(x, x_i)$ = fungsi kernel
- x_i dan x_j = pasangan dua data *training*

$c, d, \sigma > 0$ = konstanta

Menurut Octaviani menyatakan bahwa mendapatkan *hyperplane* yang paling baik bisa memakai metode *Quadratic Programming (QP) Problem* dengan menjadikan nilai minimum $\frac{1}{2}|w|^2$ dengan syarat yaitu $y_i(w \cdot x_i + b) \geq 1$ dengan $i=1,2,3,\dots,n$ [6]. Data *training* dengan $a_i > 0$ berada pada *hyperplane* disebut juga *support vector*, sedangkan yang tidak terletak di *hyperplane* $a_i = 0$. Untuk menentukan data *testing* dapat menggunakan persamaan berikut.

$$f(x_i) = \sum_{s=1}^{n_s} a_s y_s \cdot x_s \cdot x_i + b \quad (12)$$

Dimana:

x_i = data *testing*

x_s = data *support vector*, $s = 1, 2, 3, \dots, ns$

ns = banyak data *support vector*

Sehingga didapat rumus metode *Support Vector Machine* yaitu

1. Kernel *Gaussian*

$$\text{maximize } Ld(\alpha) = \sum_{i=1}^N \alpha_i - \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \left(\frac{\|x_i - x_j\|^2}{2\sigma^2} \right) \text{ Subject to } \sum_{i=1}^N \alpha_i y_i = 0 \text{ with } 0 \leq \alpha_i \leq C, \forall i = 1, \dots, N \quad (13)$$

2. Kernel *Polynomial*

$$\text{maximize } Ld = \sum_{i=1}^N \alpha_i - \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j ((x_i \cdot x_j) + c)^d \text{ Subject to } \sum_{i=1}^N \alpha_i y_i = 0 \text{ with } 0 \leq \alpha_i \leq C, \forall i = 1, \dots, N \quad (14)$$

Setelah data diproses dalam model yang telah dibuat, bisa dilakukan evaluasi terhadap metode *Support Vector Machine* dengan acuan *confusion matrix* seperti Tabel 1 dengan menghasilkan nilai *accuracy*, *sensitivity*, dan *specificity*.

Tabel 3. Model Confusion Matrix

		<i>Predicted Value</i>	
		Positive (0)	Negative (1)
<i>Actual Value</i>	Positive (0)	TP	FN
	Negative (1)	FP	TN

Dimana :

TP = *true positive*, data *positive* yang diprediksi benar

FP = *false positive*, data *negative* yang diprediksi sebagai data *positive*

FN = *false negative*, data *positive* yang diprediksi sebagai data *negative*

TN = *true negative*, data *negative* yang diprediksi benar

Dari metode *confusion matrix*, formula untuk mengevaluasi performa model adalah sebagai berikut.

1. *Accuracy*, yaitu jumlah data pada algoritma yang diprediksi benar

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

2. *Sensitivity*, yaitu jumlah positif aktual yang diidentifikasi benar

$$\text{Sen} = \frac{TP}{(TP+FN)} \quad (14)$$

3. *Specificity*, yaitu jumlah negatif aktual yang diidentifikasi benar

$$\text{Spes} = \frac{TN}{(TN+FP)} \quad (15)$$

2.5 Datasets

Data pada penelitian ini diperoleh dari data primer berupa citra uang kertas rupiah Tahun Emisi 2016 dengan nominal Rp 50.000,00 dan Rp 100.000,00. Citra diambil menggunakan kamera *smartphone* dengan jarak ± 14 cm dengan tambahan cahaya berupa lampu penerangan berwarna putih. Jumlah uang yang dipakai pada penelitian ini adalah 50 lembar dengan nominal Rp 50.000,00 sebanyak 10 lembar uang asli dan 12 lembar uang palsu dan nominal Rp 100.000,00 sebanyak 15 lembar uang asli dan 13 lembar uang palsu. Dengan pengambilan citra berdasarkan dua sisi uang, yaitu sisi depan dan belakang sehingga jumlah total citra yang diteliti sebanyak 100 data dengan rincian 20 citra asli dan 24 citra palsu pecahan Rp50.000,00 ; 30 citra asli dan 26 citra palsu untuk pecahan Rp100.000,00. Contoh citra yang digunakan pada penelitian ini ditampilkan pada Gambar 1 (**Gambar 1. Citra Uang**) yaitu sebagai berikut.



Gambar 99. Citra Uang

3 Hasil dan Pembahasan

3.1 Hasil Ekstraksi Ciri

Setelah proses pengolahan citra dilakukan, proses yang dilakukan yaitu ekstraksi ciri menggunakan metode *Gray Level Co-occurrence Matrix*, sehingga didapat hasil ciri pada objek uang dengan fitur yang dipakai yaitu *energy*, *correlation*, *contrast*, dan *homogeneity* dengan sudut arah $0^\circ, 45^\circ, 90^\circ, 135^\circ$ dan jarak piksel $d=1$ yang ditampilkan pada Tabel 2-5 sebagai berikut.

Tabel 4. Data Hasil Ekstraksi Ciri Grayscale

Data	Variabel Ciri							Kelas
	1	2	3	4	5	...	16	
1	0,142964	0,237275	0,189344	0,257375	0,986238	...	0,915529	1

2	0,109403	0,178725	0,164038	0,220796	0,976984	...	0,924148	1
3	0,207534	0,383241	0,367997	0,489741	0,965781	...	0,883041	1
...
50	0,172563	0,504477	0,387874	0,362544	0,978983	...	0,905599	1
51	0,107526	0,151324	0,106244	0,154095	0,988165	...	0,940092	0
52	0,069741	0,10545	0,078678	0,112466	0,988839	...	0,958102	0
53	0,156582	0,207321	0,133682	0,215833	0,981932	...	0,928943	0
54	0,122828	0,178528	0,132779	0,196963	0,986447	...	0,930703	0
...
100	0,207842	0,4593	0,334714	0,374943	0,97728	...	0,88353	0

Pada Tabel 2 menampilkan hasil proses ekstraksi ciri yang dilakukan pada citra *grayscale* berdasarkan fitur *Gray Level Co-occurrence Matrix* yang telah digabung secara berurut sesuai derajatnya. Pada kolom terakhir juga ditambahkan label kelas yang berisi nilai 1 untuk jenis uang asli dan 0 untuk jenis uang palsu.

Tabel 5. Data Hasil Ekstraksi Ciri Channel Red

Data	Variabel Ciri							Kelas
	1	2	3	4	5	...	16	
1	0,141915	0,238627	0,191833	0,256522	0,989638	...	0,915818	1
2	0,112749	0,182926	0,16453	0,221689	0,983591	...	0,923839	1
3	0,205219	0,376227	0,362587	0,482195	0,974867	...	0,883063	1
...
50	0,173095	0,488241	0,37145	0,348266	0,971601	...	0,904638	1
51	0,107959	0,152989	0,107042	0,155375	0,990652	...	0,941851	0
52	0,069926	0,110693	0,082028	0,116526	0,993029	...	0,959927	0
53	0,157732	0,211564	0,137129	0,219629	0,987647	...	0,929423	0
54	0,123424	0,182244	0,135341	0,200179	0,990525	...	0,932328	0
...
100	0,198736	0,441917	0,329114	0,36529	0,969819	...	0,88289	0

Pada Tabel 3 menampilkan hasil proses ekstraksi ciri yang dilakukan pada citra *channel red* berdasarkan fitur *Gray Level Co-occurrence Matrix* yang telah digabung secara berurut sesuai derajatnya. Pada kolom terakhir juga ditambahkan label kelas yang berisi nilai 1 untuk jenis uang asli dan 0 untuk jenis uang palsu.

Tabel 6. Data Hasil Ekstraksi Ciri Channel Green

Data	Variabel Ciri							Kelas
	1	2	3	4	5	...	16	

1	0,147762	0,244231	0,192707	0,263205	0,983821	...	0,914102	1
2	0,111838	0,186925	0,169675	0,228151	0,972541	...	0,921661	1
3	0,211151	0,388894	0,374236	0,500603	0,959468	...	0,879112	1
...
50	0,175272	0,517441	0,397188	0,371574	0,978612	...	0,904093	1
51	0,105761	0,149262	0,104649	0,151759	0,98777	...	0,940827	0
52	0,067813	0,102917	0,075836	0,108419	0,987672	...	0,959534	0
53	0,154498	0,204019	0,131376	0,212456	0,97941	...	0,929745	0
54	0,121844	0,177643	0,131915	0,19597	0,985009	...	0,930757	0
...
100	0,218753	0,503724	0,366251	0,409339	0,97676	...	0,878623	0

Pada Tabel 4 menampilkan hasil proses ekstraksi ciri yang dilakukan pada citra *channel Green* berdasarkan fitur *Gray Level Co-occurrence Matrix* yang telah digabung secara berurut sesuai derajatnya. Pada kolom terakhir juga ditambahkan label kelas yang berisi nilai 1 untuk jenis uang asli dan 0 untuk jenis uang palsu.

Tabel 7. Data Hasil Ekstraksi Ciri Cahnnel Blue

Data	Variabel Ciri							Kelas
	1	2	3	4	5	...	16	
1	0,143833	0,237203	0,189266	0,257731	0,985351	...	0,914365	1
2	0,108589	0,170027	0,1531	0,206268	0,974146	...	0,926397	1
3	0,205119	0,379327	0,363137	0,483425	0,967167	...	0,884347	1
...
50	0,164009	0,438089	0,333365	0,325428	0,99066	...	0,912016	1
51	0,100872	0,139497	0,098447	0,142474	0,984671	...	0,942768	0
52	0,064673	0,094019	0,071178	0,101304	0,977249	...	0,958757	0
53	0,151453	0,197447	0,126612	0,205754	0,975573	...	0,930438	0
54	0,119512	0,171423	0,128015	0,190078	0,980059	...	0,929944	0
...
100	0,136948	0,288655	0,218888	0,252244	0,992954	...	0,91854	0

Pada Tabel 5 menampilkan hasil proses ekstraksi ciri yang dilakukan pada citra *channel blue* berdasarkan fitur *Gray Level Co-occurrence Matrix* yang telah digabung secara berurut sesuai derajatnya. Pada kolom terakhir juga ditambahkan label kelas yang berisi nilai 1 untuk jenis uang asli dan 0 untuk jenis uang palsu.

3.2 Hasil Performa Metode Support Vector Machine Dalam Mengenali Keaslian Uang Kertas Rupiah

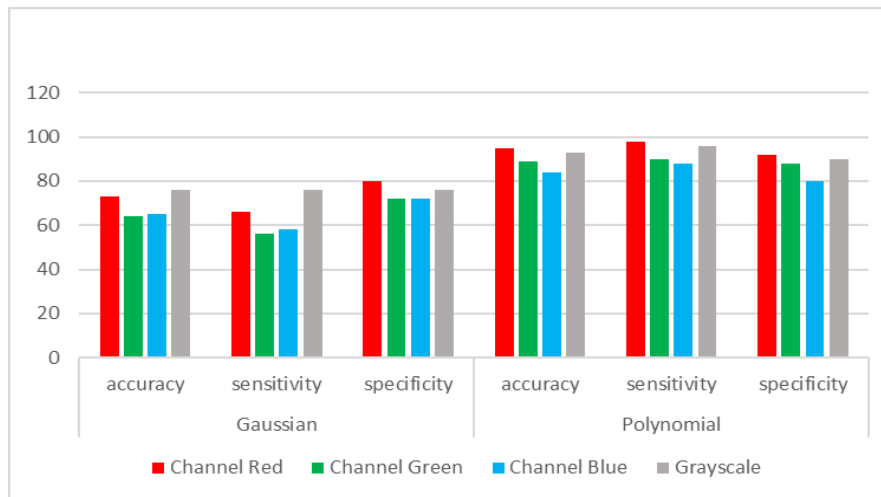
Setelah proses ekstraksi ciri dilakukan, nilai pada tiap data di normailisasi sesuai metode *min-max* yang bertujuan agar tetap pada interval yang telah ditentukan. Dari hasil normalisasi tersebut, seluruh data diproses kembali dengan metode *k-fold cross validation* untuk membagi data mana saja yang menjadi data uji dan data latih dari jumlah data sebanyak 100 data, terbagi sebanyak 90 data untuk data latih dan 10 data untuk data uji yang diproses sebanyak 10 kali dari penggunaan $k=10$. Setelah proses pembagian data selesai, maka dilakukan pelatihan terhadap metode *Support Vector Machine* untuk menghasilkan model dengan penggunaan kernel *Gaussian* dan *Polynomial*. Dari pelatihan tersebut yang menghasilkan suatu model, maka data dilakukan pengujian dari data uji yang sudah ditentukan sehingga menghasilkan hasil akhir dari model dalam mengenali keaslian mata uang kertas rupiah. Dalam akhir proses identifikasi kita bisa mengetahui performa dari metode *Support Vector Machine* dalam mengenali keaslian uang kertas rupiah berdasarkan nilai *accuracy*, *sensitify*, dan *specificity* dari *confution matrix* yang didapat. Berikut hasil Performa Metode *Support Vector Machine* yang bisa dilihat dalam Tabel 6.

Tabel 8. Hasil Performa Model *Support Vector Machine* dalam Mengenali Keaslian Mata Uang Kertas Rupiah

Confusion Matrix	Channel Red		Channel Green		Channel Blue		Grayscale	
	Gaussian	Polynomial	Gaussian	Polynomial	Gaussian	Polynomial	Gaussian	Polynomial
TP	33	49	28	45	29	44	38	48
FN	17	1	22	5	21	6	12	2
FP	10	4	14	6	14	10	12	5
TN	40	46	36	44	36	40	38	45
Accuracy (%)	73	95	64	89	65	84	76	93
Sensitivity (%)	66	98	56	90	58	88	76	96
Specificity (%)	80	92	72	88	72	80	76	90

Pada Tabel 6 menampilkan hasil *confusion matrix* berupa nilai *true positive*, *false negative*, *false positive*, dan *true negative* pada masing-masing *channel* yaitu *channel red*, *channel green*, *channel blue*, dan *grayscale* pada kernel *Gaussian* dan *Polynomial*. Sehingga dari nilai *confusion matrix* tersebut bisa mendapatkan nilai *accuracy* yang menjelaskan seberapa baik model memprediksi jawaban benar dari keseluruhan data yang ada, *sensitify* yang menjelaskan seberapa banyak rasio model memprediksi data benar positif dari jumlah semua data benar positif, dan *specificity* yang menjelaskan seberapa banyak rasio model memprediksi data benar negatif dibandingkan dengan jumlah semua data benar negatif. Bisa kita lihat juga bahwa dalam penggunaan kedua kernel, nilai terbesar di diperoleh oleh *channel red* dengan nilai *accuracy* 95%, sama halnya dengan nilai *sensitify* sebesar 98%, dan *specificity* dengan nilai 92% yang semuanya berada di kernel *Polynomial*.

Dari semua hasil yang didapat, terlihat bahwa dari kedua kernel menghasilkan nilai yang beragam. Perbandingan yang dihasilkan dari kedua jenis kernel bisa dilihat dalam bentuk grafik dibawah ini.



Gambar 100. Grafik Performa Support Vector Machine dari Pengujian Model

Dari gambar grafik diatas (**Gambar 2. Grafik Performa Support Vector Machine dari Pengujian Model**), bisa kita lihat bahwa pengujian data uji dengan model yang telah dibuat menghasilkan performa yang baik dalam hal mengenali keaslian uang kertas rupiah (khusus uang Tahun Emisi 2016). Rata-rata akurasi terbaik didapat dari model *Support Vector Machine* mencapai 95% dengan penggunaan kernel *Polynomial* di *channel red*. Rata-rata *sensitivity* terbaik didapat sebesar 98% dengan penggunaan kernel *Polynomial* di *channel red*. Rata-rata *specificity* terbaik didapat sebesar 92% dengan penggunaan kernel *Polynomial* di *channel red*. Nilai tersebut didapat dari hasil *confusion matrix* dari pengujian model berupa nilai *true positive*, *false negative*, *false positive*, dan *true negative* sehingga bisa didapatkan nilai *accuracy*, *sensitivity* dan *specificity* di masing-masing *channel* dengan kernel *Gaussian* ataupun *Polynomial*. Sehingga dapat disimpulkan untuk metode *Support Vector Machine* menghasilkan performa yang baik dalam hal mengenali keaslian mata uang kertas rupiah.

4 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, maka kesimpulan yang bisa diambil yang pertama adalah model *Support Vector Machine* didapat dari hasil pelatihan bisa digunakan untuk mengenali keaslian mata uang kertas rupiah. *Support Vector Machine* bisa diterapkan untuk mengenali keaslian mata uang kertas rupiah dengan ciri yang digunakan yaitu ciri tekstur *Gray Level Co-occurrence Matrix*. Dalam proses identifikasi yang dilakukan, *Support Vector Machine* menghasilkan performa yang baik dengan nilai rata-rata akurasi yang didapat mencapai 95%, *sensitivity* mencapai 98%, dan *specificity* mencapai 92%. Nilai tersebut didapat dari *channel Red* dengan penggunaan kernel yaitu *Polynomial*. Performa *Support Vector Machine* yang dihasilkan dipengaruhi oleh jenis kernel yang digunakan. Dengan menggunakan kernel yang sesuai dengan data, akan menghasilkan nilai yang baik pula. Yang kedua adalah *Gray Level Co-occurrence Matrix* diterapkan untuk ekstraksi ciri tekstur pada mata uang kertas rupiah dengan melakukan proses pengolahan data terlebih dahulu seperti praproses data, segmentasi, dan mengambil *channel* warna. Setelah citra siap digunakan maka citra akan melalui proses ekstraksi ciri dengan tahapan yang pertama mengubah citra RGB menjadi *grayscale*, kemudian membuat matriks *co-occurrence* dan dilanjut dengan membuat matriks simetris, setelahnya dibuat matriks normalisasi sehingga hasil matriks normalisasi tersebut dilakukan penerapan kepada fitur *Gray Level Co-Occurance Matrix* yang ada, sesuai arah sudut dan jarak yang ingin diteliti, sehingga ciri yang didapat sebanyak 16 variabel ciri dari masing-masing *channel Red*, *Green*, *Blue*, dan *Grayscale*.

Adapun saran bagi penelitian yang bisa penulis berikan untuk penelitian selanjutnya adalah yang pertama dalam proses ekstraksi ciri dengan menggunakan tekstur, bisa menggunakan metode yang lain selain *Gray Level Co-Occurance Matrix*, seperti *Local Binary Pattern (LBP)*, *Lacunarity*, *Tamura* atau *Gabor*. Yang kedua adalah dari banyaknya unsur pengaman yang ada pada uang kertas rupiah, bisa menggunakan unsur lain selain unsur tekstur keseluruhan dari uang kertas, contohnya seperti warna, kode tuna netra, ataupun

tinta berubah warna. Yang ketiga adalah dalam proses identifikasi, bisa menggunakan metode klasifikasi yang lain selain *Support Vector Machine*, seperti *Artificial Neural Network Artificial (ANN)* atau Jaringan Syaraf Tiruan, *Naïve Bayes*, *Decission Tree*, atau *Fuzzy*.

Referensi

- [1] Asriel, B. *et al.* (2014) 'Identification of Nominal Value and Authenticity of Rupiah sUsing Support Vector Machine', 3(1), pp. 13–20.
- [2] Athoillah, M., Irawan, M.I., dan Imah, E.M. (2015). *Study Comparison of SVM, K-NN, and Backpropagation-Based, Classifier for Image Retrieval*. Journal of Computer Science and Information. Volume 8, Issue 1, February 2015.
- [3] Fadilah, N. I., Rahayudi, B. and Furqon, M. T. (2018) 'Implementasi Algoritme Support Vector Machine (SVM) Untuk Klasifikasi Penyakit Dengan Gejala Demam', 2(11), pp. 5619–5625.
- [4] Neneng, N., Adi, K. and Isnanto, R. (2016) 'Support Vector Machine Untuk Klasifikasi Citra Jenis Daging Berdasarkan Tekstur Menggunakan Ekstraksi Ciri Gray Level Co-Occurrence Matrices (GLCM)', *Jurnal Sistem Informasi Bisnis*, 6(1), p. 1. doi: 10.21456/vol6iss1pp1-10.
- [5] Nugroho, A.S., Witarto, A.B., Handoko, D. (2003). *Application of Support Vector Machine in Bioinformatics*. Proceeding of Indonesian Scientific Meeting in Central Japan. December 20, 2003. Gifu-Japan.
- [6] Octaviani. *et al.* (2014) 'Penerapan Metode Klasifikasi Support Vector Machine (Svm) Pada Data Akreditasi Sekolah Dasar (Sd) Di Kabupaten Magelang', *None*, 3(4), pp. 811–820.
- [7] Prasetyo, E., (2011). *Pengolahan Citra Digital Dan Aplikasinya Menggunakan Matlab*. Yogyakarta: Penerbit Andi.
- [8] Putra, D., 2010. *Pengolahan Citra Digital*. Yogyakarta: ANDI.
- [9] Siqueira, F.R.D., Schwartz, W.R., dan Pedrini, H., (2013). *Multi-scale Gray Level Co-occurrence Matrices for Texture Description*. Neurocomputing, Volume 120, pp. 336-345.
- [10] Widodo, R., Widodo, A. W. and Supriyanto, A. (2018) 'Pemanfaatan Ciri Gray Level Co-Occurrence Matrix (GLCM) Citra Buah Jeruk Keprok (Citrus reticulata Blanco) untuk Klasifikasi Mutu', *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2(11), pp. 5769–5776. Available at: <http://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/3420/1336>.