

Rancang Bangun Sistem Pendeteksi Keaslian Uang Kertas Rupiah Menggunakan Sinar *UV* dengan Metode *Machine Learning*

Alvin Daffa Kumara Zulfiansyah, Hendra Kusuma dan Muhammad Attamimi
Departemen Teknik Elektro, Institut Teknologi Sepuluh Nopember (ITS)
e-mail: hendraks@ee.its.ac.id


Abstrak—Sistem pendeteksi keaslian uang kertas rupiah merupakan metode yang dibutuhkan karena uang merupakan materi penting sehingga sering terjadi tindak kriminalitas. Metode yang sering digunakan adalah *image processing* untuk *scaling* dan *color conversion*, segmentasi untuk mendapatkan pola tertentu, atau dengan memperhatikan ciri fisik uang kertas rupiah, seperti tekstur dan pola terawang. Namun, metode-metode tersebut dapat dikatakan kurang efektif apabila terjadi peningkatan pemalsuan uang kertas rupiah dalam bentuk fisik. Sehingga penulis merancang sistem counting yang menggunakan sinar ultraviolet untuk menampilkan *hidden pattern* sebagai fitur khusus mendeteksi keaslian uang dengan metode *machine learning* dan menambahkan sistem counting buatan sendiri dengan fitur *rotation invariant* untuk melakukan pendeteksian lebih dari satu lembar uang kertas rupiah. Perpaduan *image processing* dan *machine learning* pada penelitian ini mampu memberikan hasil *pengujian prototipe* dengan metode *k-NN* dan *CNN* memberikan persentase keberhasilan prediksi sebesar lebih dari 90% dibandingkan dengan *SVM*, *Random Forest*, dan *Naive Bayes* yang kurang dari 85%. Mekanik prototipe ini mampu melakukan pendeteksian kurang dari 4 detik dengan 10 lembar uang kertas yang dideteksi. Dengan meningkatkan metode *detection* yang lebih *expert*, seperti *deep learning* dengan model yang fleksibel jika ingin digunakan dalam pendeteksi mata uang selain rupiah.

Kata Kunci—Sinar Ultraviolet, Rupiah, *Rotation Invariant*, *Image Processing*, *Machine Learning*.

I. PENDAHULUAN

DALAM lingkungan digitalisasi baru saat ini, orang dibatasi oleh teknologi, dan teknologi itu berkembang pesat. Tentu saja, penemuan semacam itu membuat hidup kita lebih mudah. Orang-orang sekarang dapat menyelesaikan tugas mereka dengan sedikit usaha, yang dimungkinkan karena kemajuan teknologi. Namun, beberapa orang menyalahgunakan manfaat teknologi tersebut untuk mencapai tujuan mereka. Ada banyak contoh semacam ini di sekitar [1]. Salah satu kegiatan tersebut adalah produksi mata uang palsu yang dipraktikkan untuk menipu orang [2]. Mata uang palsu digambarkan sebagai mata uang yang diproduksi tanpa persetujuan hukum pemerintah. Untuk mencetak uang palsu, orang-orang yang tidak jujur menggunakan teknik pemindaian dan pencetakan yang paling mutakhir. Perkembangan uang palsu tersebut berdampak pada perekonomian negara manapun [1].

Sistem pengenalan keaslian mata uang kertas merupakan salah satu jenis sistem kecerdasan buatan yang sangat dibutuhkan dan krusial saat ini. Sistem pengenalan ini memiliki berbagai aplikasi potensial yang relevan dalam sistem perbankan elektronik atau, sistem deteksi mata uang, atau untuk mendeteksi uang kertas palsu [3]. Terdapat banyak metode yang digunakan untuk melakukan identifikasi apakah



Gambar 1. *Safety Element* Rupiah.



Gambar 2. *Color Conversion HSV*.

uang tersebut termasuk uang asli atau bukan. Beberapa metode yang paling sering digunakan adalah *image processing*, dengan melakukan deteksi tepi, watermarking, ekstraksi fitur, metode segmentasi atau dengan memperhatikan ciri fisik uang kertas secara langsung [4]. Adapula yang menggunakan metode *Convolution Neural Network (CNN)* untuk meningkatkan akurasi pendeteksian kepalsuan uang kertas [5].

Namun, metode-metode tersebut dapat dikatakan kurang efektif apabila terjadi peningkatan pemalsuan uang kertas dalam bentuk fisik sehingga membuat tingkat akurasi berkurang jika hanya memproses uang kertas secara langsung. Adapun pada mesin ATM untuk setor tunai juga memiliki beberapa kekurangan, seperti jika pada uang kertas terdapat benda asing (*stapler*, *isolasi*, *stiker*, *coretan*, dan lain-lain), lusuh, terlipat, lembab atau lengket maka tidak akan diterima oleh mesin walaupun uang tersebut asli. Oleh karena itu, dalam penelitian ini, saya merancang sistem yang menggunakan sinar ultraviolet untuk membantu pengenalan keaslian uang kertas rupiah. Citra dengan UV digunakan untuk membedakan antara mata uang kertas asli dan palsu, karena di bawah sinar UV visual yang berbeda di area tertentu dari uang kertas asli akan bersinar dan menunjukkan pola tersembunyi [3].


Penelitian ini juga mengutamakan aspek keakuratan dalam penggunaannya. Oleh karena itu, proses yang akan diolah adalah bagian uang yang hanya memiliki *hidden pattern* untuk mengurangi waktu pemrosesan dan dilanjutkan dengan *features extraction*. Sebelum dimasukkan ke dalam metode *machine learning*, dilakukan terlebih dahulu proses *image pre-processing*, seperti mengurangi *noise*, *edge detection*,



Gambar 3. Thresholding Image.



Gambar 4. Base Prototype.



Gambar 5. (A) Roller Pertama (B) Roller Kedua.

dan *region of interest*. Dengan sistem seperti ini, diharapkan mampu menjadi salah satu metode untuk menghitung sekaligus mendeteksi keaslian uang kertas rupiah secara *rotation invariant* dengan akurat.

II. DASAR TEORI

A. Rupiah

Rupiah adalah satuan moneter dan alat pembayaran yang sah dalam Negara Kesatuan Republik Indonesia, simbol kedaulatan negara yang harus dijunjung tinggi oleh seluruh warga negara. Sesuai dengan mandat pengelolaan rupiah, Bank Indonesia mengemban misi untuk memenuhi kebutuhan uang rupiah masyarakat akan pecahan yang layak, layak edar, disampaikan tepat waktu melalui mekanisme yang didorong oleh bank sentral sejalan dengan arah kebijakan *cashless*, dengan tetap mengutamakan efisiensi dan kepentingan nasional. Salah satu tantangan yang dihadapi Bank Indonesia dalam pengelolaan uang rupiah adalah peredaran uang rupiah palsu.


Pada uang kertas rupiah memiliki ciri khusus yang digunakan sebagai langkah preventif awal untuk mendeteksi apakah uang kertas tersebut asli atau bukan. Hal-hal tersebut meliputi pengecekan sesuai dengan standarisasi uang rupiah seperti ukuran, warna, desain dan fitur keamanan seperti yang ditunjukkan Gambar 1.

B. Ultraviolet

Sinar *ultraviolet* (UV) adalah bentuk radiasi elektromagnetik dengan panjang gelombang yang lebih pendek dari cahaya yang terlihat oleh mata manusia. Sinar UV terbagi menjadi tiga kategori utama: UV-A, UV-B, dan UV-C. UV-A memiliki panjang gelombang terpanjang dan paling dekat dengan cahaya terlihat, sementara UV-B memiliki energi yang lebih tinggi dan dapat menyebabkan kulit terbakar jika terpapar berlebihan. UV-C memiliki energi paling tinggi dan efek sterilisasi yang kuat. Meskipun UV-C



Gambar 6. Holder Lampu Ultraviolet.



Gambar 7. Schematic Modul PCB.

tidak mencapai permukaan Bumi karena diserap oleh atmosfer, lampu UV-C khusus dapat menghasilkan sinar UV-C untuk tujuan sterilisasi dan pengendalian mikroba. Penggunaan lampu UV meliputi sterilisasi, pengobatan medis, dan berbagai industri seperti pencetakan dan elektronik. Namun, penting untuk berhati-hati terhadap paparan berlebihan sinar UV karena dapat menyebabkan kerusakan kulit dan mata.


Biasanya, sinar UV-A digunakan untuk mengungkapkan pola tersembunyi pada uang kertas Rupiah. Pola tersebut terbuat dari tinta khusus yang merespons sinar UV-A dan akan terlihat jelas saat disinari dengan lampu UV-A.

C. OpenCV


OpenCV adalah *computer vision library* lintas platform berdasarkan distribusi lisensi BSD (sumber terbuka). Dapat berjalan di sistem operasi *Linux*, *Windows* dan *Mac OS*. Dapat mengimplementasikan banyak algoritma dalam pemrosesan citra dan *machine vision*, Ini terutama menulis program dalam C++ dan juga berisi banyak antarmuka bahasa umum lainnya. Dalam beberapa tahun terakhir, aplikasi perangkat lunak *OpenCV* telah meluas. Area aplikasi utama adalah interaksi manusia-komputer, pengenalan objek, pemrosesan citra, pengenalan wajah dan gerakan, pelacakan gerak, robotika, Analisis gerak, visi mesin, analisis struktural, dan keselamatan berkendara mobil [6].

Pada *OpenCV* digunakan dua fungsi utama dalam *digital image processing* yang merupakan penggunaan komputer digital untuk memproses citra digital melalui suatu algoritma, yaitu *color space HSV* dan *color segmentation threshold* [7]. HSV memodelkan representasi dengan cara mencampurkan cat dari berbagai warna bersama-sama dengan saturasi dimensi menyerupai berbagai warna cerah berwarna dan nilai dimensi yang menyerupai campuran warna dengan jumlah yang bervariasi dari warna hitam atau putih seperti yang ditunjukkan Gambar 2.

Color segmentation threshold adalah proses segmentasi citra berdasarkan warna menggunakan nilai ambang tertentu. Proses ini melibatkan pengaturan nilai ambang untuk setiap saluran warna (misalnya, merah, hijau, biru). Nilai ambang ini digunakan untuk memisahkan piksel citra menjadi dua



Gambar 8. Diagram Blok Alat.



Gambar 9. Diagram Algoritma Machine Learning.

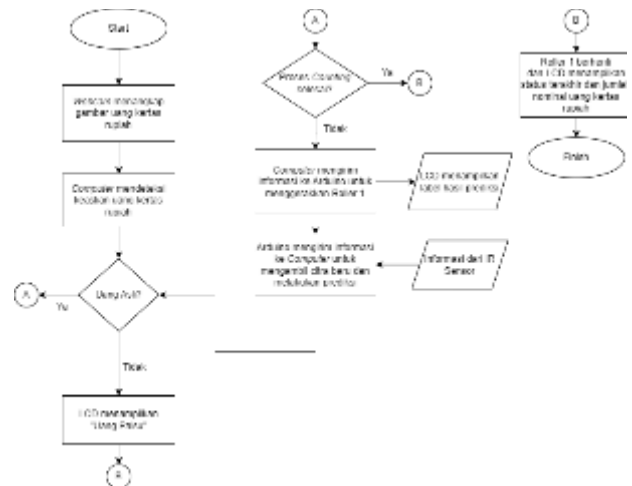
kelompok berdasarkan nilai intensitasnya. Pixel dengan nilai intensitas di atas nilai ambang akan diberi label satu kelompok, sedangkan pixel dengan nilai intensitas di bawah nilai ambang akan diberi label kelompok lain seperti pada Gambar 3.

D. Machine Learning

Machine Learning adalah studi ilmiah tentang algoritme dan model statistik yang digunakan sistem komputer untuk melakukan tugas tertentu tanpa diprogram secara eksplisit. Mempelajari algoritme di banyak aplikasi yang kita gunakan sehari-hari. Algoritma ini digunakan untuk berbagai tujuan seperti penambahan data, pemrosesan citra, analitik prediktif. Keuntungan utama menggunakan pembelajaran mesin adalah, setelah algoritme mempelajari apa yang harus dilakukan dengan data, algoritme dapat melakukan tugasnya secara otomatis. Dalam makalah ini, ulasan singkat dan prospek masa depan dari aplikasi besar algoritma pembelajaran mesin telah dibuat [8]. Pada penelitian ini, digunakan beberapa metode sebagai langkah evaluasi dan pencarian metode terbaik pada bidang machine learning untuk mendeteksi keaslian uang kertas rupiah.

k-NN (k-Nearest Neighbors) machine learning adalah salah satu algoritma machine learning yang digunakan untuk klasifikasi dan regresi. Algoritma ini termasuk dalam kelompok metode pembelajaran malas (lazy learning), yang artinya tidak membangun model dari data training, melainkan hanya menyimpan data training tersebut. Pada saat melakukan prediksi, algoritma kNN mencari k tetangga terdekat dari data uji dan memprediksi label data uji berdasarkan mayoritas label dari K tetangga terdekat tersebut. Jumlah k yang dipilih dapat diatur oleh pengguna. Algoritma k-NN dapat digunakan untuk berbagai jenis data, seperti data numerik, kategorikal, dan citra. Beberapa penelitian juga telah mengembangkan variasi dari algoritma kNN, seperti AE-kNN yang menggunakan autoencoder untuk reduksi dimensi [9].

Support Vector Machine (SVM) machine learning adalah algoritma machine learning yang digunakan untuk klasifikasi




Gambar 10. Flowchart Kerja Sistem.

dan regresi. Algoritma ini didasarkan pada teori pembelajaran statistik dan bekerja dengan mencari hyperplane terbaik yang memisahkan dua kelas pada input space. SVM dapat digunakan untuk berbagai jenis data, seperti data numerik, kategorikal, dan teks. Algoritma SVM mencari hiperplane yang dapat memaksimalkan margin, yaitu jarak antara hiperplane dan titik-titik data terdekat dari kedua kelas. Titik-titik data yang paling dekat dengan hiperplane disebut sebagai vektor pendukung (support vector), yang memberikan nama bagi algoritma ini. SVM berupaya untuk membangun hiperplane yang memisahkan kelas dengan margin terbesar, sehingga memiliki kemampuan yang baik untuk menggeneralisasi pada data yang belum pernah dilihat sebelumnya.

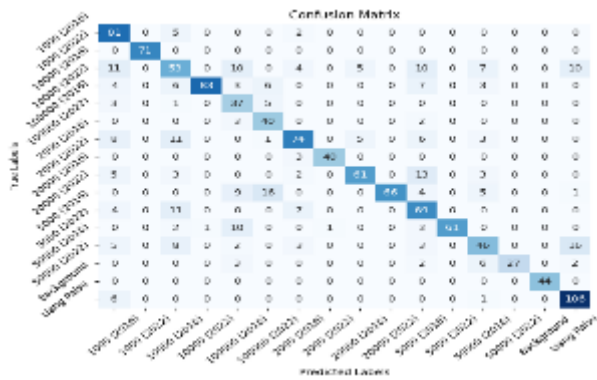
Random Forest (RF) machine learning adalah teknik ensemble yang dikembangkan oleh Breiman untuk klasifikasi dan regresi. RF bekerja dengan menggabungkan prediksi dari beberapa pohon keputusan yang dibuat secara acak pada subset data training yang berbeda. RF memiliki kelebihan seperti dapat menangani data yang sangat besar, memiliki kemampuan untuk mengatasi overfitting, dan dapat digunakan untuk berbagai jenis data. Selain itu, RF juga mudah digunakan dan memiliki akurasi yang tinggi. Beberapa penelitian telah dilakukan untuk meningkatkan kinerja RF, seperti dengan menggunakan teknik clustering untuk menghilangkan pohon yang redundan [10].

Naive Bayes machine learning adalah salah satu metode klasifikasi pada machine learning yang menggunakan teorema Bayes untuk menghitung probabilitas kemunculan suatu data pada setiap kelas. Metode ini cukup sederhana dan efisien serta dapat memberikan hasil yang cukup baik pada beberapa jenis data seperti data teks. Hal ini terbukti dari banyaknya penelitian yang menggunakan metode Naive Bayes sebagai salah satu metode klasifikasi dalam mengolah data [11]. Naive Bayes adalah algoritma yang relatif sederhana dan cepat untuk pelatihan dan prediksi, dapat dioptimalkan dengan hiperparameter untuk meningkatkan ketepatan klasifikasi dan waktu berjalan, dapat digunakan dengan Bayesian Networks untuk meningkatkan akurasi klasifikasi citra, dan Naive Bayes dapat menangani input berdimensi tinggi dan tahan terhadap noise pada data input [12].

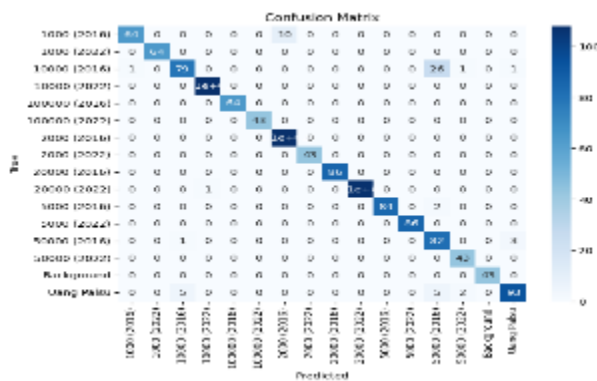
Neural network adalah jenis algoritma machine learning yang dimodelkan berdasarkan struktur dan fungsi otak



Gambar 14. Confusion Matrix Random Forest.



Gambar 15. Confusion Matrix Naive Bayes.



Gambar 16. Confusion Matrix CNN.

memberikan perintah untuk proses *counting* dan *LCD* untuk melakukan *display* keterangan “asli/ palsu” dan memunculkan jumlah nominal yang di hitung seperti pada diagram Gambar 8 dan Gambar 9.

Terdapat IR Sensor (*Infrared Sensor*) yang dihubungkan dengan Arduino yang digunakan untuk mengetahui posisi uang kertas rupiah sehingga dapat mengetahui terjadinya perpindahan uang untuk melakukan *counting*. *Webcam* digunakan untuk menangkap sisi dan bagian tertentu dari uang kertas rupiah yang memiliki *hidden pattern*.

D. Flowchart Kerja Sistem

Gambar 10 menunjukkan Flowchart Kerja Sistem. Ketika uang kertas rupiah dimasukkan atau diposisikan di dalam prototipe. Ketika tombol start ditekan maka sistem akan bergerak, dimana webcam akan menangkap citra dari uang kertas rupiah. Computer/ Rasp Pi akan mendeteksi apakah uang rupiah tersebut asli atau palsu sekaligus melakukan klasifikasi nominal tersebut menggunakan metode machine learning. Jika “asli” maka computer akan mengirimkan informasi kepada arduino untuk menggerakkan roller 1

Tabel 1. Pengujian Awal pada Setiap Metode.

Metode	Kebenaran prediksi dan waktu yang dibutuhkan		
	5 lembar	10 lembar	15 lembar
k-NN	5/5	10/10	6/15
	1.7927 detik	3.7559 detik	5.02515 detik
SVM	5/5	10/10	11/15
	1.8636 detik	3.419 detik	4.9602 detik
Random	2/5	5/10	9/15
Forest	1.874 detik	3.048 detik	4.6389 detik
Naive	3/5	5/10	10/15
Bayes	1.8576 detik	3.3928 detik	4.967295 detik
CNN	4/5	10/10	9/15
	2.1341 detik	3.743 detik	5.4668 detik

sehingga menggerakkan DC Motor supaya dapat memindahkan uang kertas ke posisi final. Dalam proses pemindahan, uang kertas akan melewati IR Sensor yang akan memberikan informasi dari arduino kepada computer untuk menangkap citra baru yang merupakan uang kertas selanjutnya. Begitu seterusnya hingga semua uang kertas sudah dideteksi. Pada output LCD merupakan “asli/ palsu” uang kertas tersebut dan nominal setelah melewati proses deteksi. Jika “palsu” maka computer akan mengirimkan informasi kepada arduino untuk menggerakkan roller 1 sampai dapat terjangkau oleh roller 2. Setelah itu sistem counting akan berhenti dan LCD akan menampilkan “uang palsu”.

E. Integrasi Sistem Detection dan Counting

Penggunaan ROS disini sebagai media komunikasi antara program Python dan Arduino sebagai *pubsub (Publisher – Subscriber)*. Python akan melakukan *publish* hasil prediksi yang akan di-*subscribe* oleh Arduino. Sedangkan Arduino akan melakukan *publish* berupa informasi dari infrared sensor dan akan di-*subscribe* oleh Python sebagai sebuah *trigger* untuk menangkap atau merekam citra selanjutnya dan melakukan prediksi selanjutnya hingga selesai seperti pada Gambar 11.

IV. HASIL DAN PEMBAHASAN

A. Confusion Matrix

Confusion matrix (matriks kebingungan) adalah suatu tabel yang digunakan untuk menggambarkan kinerja suatu model klasifikasi pada data yang diketahui secara pasti. Matriks ini memperlihatkan jumlah prediksi yang benar dan salah yang dilakukan oleh model untuk setiap kelas yang ada dalam data.

Pada Gambar 12 metode k-NN dapat dilihat bahwa terdapat beberapa nilai *False Positive* dan *False Negatif*. Hal tersebut dapat terjadi karena metode *k-NN* menghitung jarak antara titik data menggunakan metrik jarak, seperti jarak Euclidean. Jika fitur dalam data memiliki skala yang berbeda-beda, maka fitur dengan skala yang lebih besar akan mendominasi perhitungan jarak. Hal ini dapat mengakibatkan prediksi yang tidak akurat.

Support Vector Machine dengan *kernel* polinomial memberikan nilai *accuracy*, *precision*, *Recall*, dan *F1 Score* terbaik daripada *kernel* lainnya seperti yang ditunjukkan Gambar 13. Hal tersebut dapat terjadi karena kelas-kelas pada data training memiliki nilai-nilai internsitas pixel yang relatif mirip sehingga dibutuhkan hubungan yang non-linier atau pola yang rumit untuk membedakan model antar suatu kelas

Tabel 2.
Pengujian Prototipe secara Berkala .

No	Metode	Skenario	Jumlah Keberhasilan Pengujian									
			10	20	30	40	50	60	70	80	90	100
1	k-NN	Homogen	10/	19/	29/	38/	48/	58/	67/	77/	87/	96/
			10	20	30	40	50	60	70	80	100	100
		Heterogen	9/	18/	28/	37/	47/	56/	65/	75/	84/	93/
			10	20	30	40	50	60	70	80	90	100
2	SVM	Homogen	10/	18/	28/	37/	46/	54/	61/	70/	79/	88/
			10	20	30	40	50	60	70	80	90	100
		Heterogen	9/	17/	26/	35/	43/	51/	60/	68/	78/	85/
			10	20	30	40	50	60	70	80	90	100
3	Random Forest	Homogen	7/	15/	25/	31/	40/	48/	56/	61/	69/	79/
			10	20	30	40	50	60	70	80	90	100
		Heterogen	5/	13/	22/	31/	40/	47/	53/	61/	66/	74/
			10	20	30	40	50	60	70	80	90	100
4	Naive Bayes	Homogen	8/	17/	26/	35/	44/	52/	60/	67/	75/	79/
			10	20	30	40	50	60	70	80	90	100
		Heterogen	7/	15/	24/	33/	42/	49/	57/	65/	73/	77/
			10	20	30	40	50	60	70	80	90	100
5	CNN	Homogen	9/	19/	29/	39/	48/	57/	66/	75/	85/	94/
			10	20	30	40	50	60	70	80	100	100
		Heterogen	9/	17/	27/	37/	45/	55/	64/	74/	83/	91/
			10	20	30	40	50	50	70	80	90	100

dengan kelas yang lain. *Kernel* polinomial memungkinkan *SVM* untuk memperluas dimensi fitur dan mempertimbangkan interaksi yang kompleks, yang dapat meningkatkan kemampuan *SVM* dalam memisahkan kelas yang saling tumpang tindih sehingga dapat membantu model *SVM* menangkap interaksi ini dengan lebih baik.

Confusion Matrix Random Forest memiliki nilai yang berbeda-beda tergantung dengan *n_estimators* atau jumlah pohon keputusan yang dipilih seperti pada Gambar 14. Semakin tinggi nilai *n_estimators* maka semakin bagus juga *confusion matrix* seperti pada Gambar 15. Namun dengan penambahan pohon, model dapat menangkap pola yang lebih kompleks dalam data, namun juga meningkatkan waktu pelatihan. Dan juga jumlah pohon yang terlalu banyak dapat mengakibatkan *overfitting*. Oleh karena itu, nilai *n_estimators* yang optimal tergantung pada kompleksitas masalah dan jumlah data yang dimiliki. Pada *Confusion Matrix* di atas menggunakan *n_estimators* = 50, *max_depth* = 10, *max_features* = 'sqrt' sesuai dengan penjelasan sebelumnya, disini dipilih *n_estimators* 50 untuk hasil yang maksimal.

Karena data yang digunakan merupakan citra yang memiliki fitur numerik dan spasial yang kompleks. *Naive Bayes* memiliki asumsi bahwa setiap fitur adalah independen secara kondisional terhadap kelas, namun asumsi ini tidak berlaku dalam citra di mana fitur-fitur spasial yang berdekatan dapat saling terkait erat. *Naive Bayes* tidak mampu menangkap hubungan spasial dan struktur citra dengan baik. Namun, *Naive Bayes* merupakan salah satu metode yang cepat karena komputasi yang sederhana dan efisien.

Pengaruh *epoch* pada *confusion matrix* dapat membantu dalam memahami bagaimana model *neural network* memperbaiki kemampuannya dalam mengklasifikasikan citra-citra dan mengurangi kesalahan prediksi. Dalam setiap *epoch*, model berupaya untuk memperbaiki penempatan citra-citra pada matriks keputusan (*confusion matrix*) sehingga lebih akurat mencerminkan kelas-kelas yang benar. Dalam pengujian digunakan 100 epoch dan batch size sebesar 32 yang sudah memberikan nilai maksimum dengan delapan *layer* untuk membentuk model, yaitu *Conv2D layer* dengan 32

filter dan ukuran filter 3x3, *MaxPooling2D layer* dengan ukuran filter pooling 2x2, *Conv2D layer* dengan 64 filter dan ukuran filter 3x3, *MaxPooling2D layer* dengan ukuran filter pooling 2x2, *Conv2D layer* dengan 64 filter dan ukuran filter 3x3, *Flatten layer* untuk mengubah output menjadi vektor satu dimensi, *Dense layer* dengan 64 unit neuron, dan *Dense layer* terakhir dengan jumlah unit neuron sesuai dengan jumlah kelas pada dataset seperti yang ditunjukkan Gambar 16.

B. Hasil Pengujian Prototipe secara Berkala

Tabel 1 merupakan data keberhasilan prediksi dan waktu yang dibutuhkan dalam keseluruhan sistem dengan menggunakan keseluruhan metode. Pada pengujian dilakukan dengan beberapa skenario pemilihan uang kertas rupiah, dengan tujuan untuk mengevaluasi model *machine learning* yang sudah dibuat. Skenario pertama adalah uang dengan nominal yang sama atau homogen, skenario kedua adalah uang dengan nominal yang berbeda atau heterogen dan Tahun Emisi yang berbeda.

Metode *k-NN*, *SVM*, dan *CNN* berhasil memprediksi dan mekanik bekerja hingga akhir terutama pada 5 dan 10 lembar uang kertas dimana masing-masing membutuhkan waktu sekitar 1.8 detik dan 3.7 detik atau dengan kata lain 0.37 detik pada setiap kali proses pendeteksian. Sedangkan metode *Random Forest* dan *Naive Bayes* memiliki keakuratan prediksi yang rendah karena berkaitan dengan teknik komputasi yang tidak sesuai dengan dataset dan kelas yang ada.

Pada pengujian 15 lembar uang kertas, sering terjadi kesalahan pada proses *detection* maupun *counting* pada semua metode. Hal tersebut dipengaruhi oleh dimensi alat yang minimalis, jarak antar webcam ke uang kertas, dan base prototipe yang digunakan terkadang melakukan error, seperti uang kertas yang ditarik *double/* lebih dari satu lembar, *paper jam*, dan *timing* penarikan yang tidak tepat.

Selanjutnya dilakukan pengujian dengan skenario sebelumnya, yaitu homogen dan heterogen sebanyak 100 kali untuk mendapatkan hasil tetap dan spesifikasi dari prototipe yang telah dibuat. Pengujian dilakukan dengan jumlah lembar uang kertas rupiah adalah tidak lebih dari 10 lembar untuk

mendapatkan spesifikasi prototipe seperti yang ditunjukkan pada Tabel 2.

Hasil yang didapatkan tidak hanya hasil dari pengujian keaslian, tetapi juga pengujian nominal yang berhasil dideteksi serta menggunakan mekanik dari prototipe. Perhitungan pada tabel akan berhitung 1 pada setiap pengujian apabila:

1. Pengujian keaslian uang kertas rupiah **berhasil** dideteksi sekaligus nominal dan Tahun Emisinya.
2. Pengujian mekanik **berhasil** dilakukan hingga uang kertas mencapai posisi akhir pengumpulan.

Misalnya, "19/20" memiliki arti jika 19 kali pengujian dengan setiap pengujian ditumpuk uang kertas sebanyak 8-10 uang kertas berhasil dideteksi dan prototipe bekerja sampai akhir. Dan terdapat 1 kali pengujian yang gagal baik itu pengujian keaslian atau mekanik atau keduanya.

C. Pembahasan

Pada sistem *detectiom* keaslian uang kertas rupiah digunakan beberapa metode, yaitu *k-Nearest Neighbors*, *Support Vector Machine*, *Random Forest*, *Naïve Bayes*, dan *Convolution Neural Network*. Pada metode *k-Nearest Neighbors* memiliki akurasi pendeteksian sebesar 93% dalam sekali pembacaan dengan menggunakan " $k = 1$ ". Pemilihan k berdasarkan tingkat akurasi yang tinggi karena model sangat sensitif terhadap detail lokal dalam data dan dataset tidak terlalu rumit dikarenakan posisi dan saturasi cahaya relatif tidak terlalu berbeda. Namun jika terdapat tumpang tindih antara kelas di sekitar batas keputusan, yaitu ada beberapa sampel yang dekat dengan batas keputusan dan memiliki label yang berbeda, maka *K-NN* dengan " $k = 1$ " dapat menghasilkan kesalahan prediksi yang disebabkan ada beberapa bagian uang kertas yang tidak memiliki *hidden pattern* ketika disinari sinar.

Pada *Support Vector Machine*, kernel *poly* memberikan hasil prediksi lebih baik daripada kernel lainnya. Hal tersebut karena kemampuannya untuk mengatasi masalah *non-linear* dalam data. Gambar atau citra yang digunakan memiliki struktur yang kompleks dan tidak linier, dan kernel polinomial memungkinkan SVM untuk memodelkan hubungan *non-linear* antara fitur-fitur yang ada dalam citra. Namun, ada juga beberapa citra yang *misprediction*. Hal tersebut dapat terjadi karena kernel polinomial dapat meningkatkan dimensi fitur untuk menciptakan pemisah yang lebih kompleks. Namun, jika fitur-fitur yang digunakan tidak cukup representatif atau tidak mampu membedakan kelas yang berbeda dengan baik. Persentase keberhasilan SVM pada sekali pembacaan adalah 85% .

Random Forest tidak secara khusus mempertimbangkan struktur spasial dalam citra. Ini berarti model tidak memiliki pengetahuan tentang letak relatif fitur dalam citra, seperti hubungan spasial antara piksel-piksel tetangga. Oleh karena itu, untuk tugas yang sangat bergantung pada struktur spasial, seperti segmentasi objek, *Random Forest* mungkin tidak memberikan hasil yang optimal. Terdapat juga kekurangan lain, seperti *Random Forest* bekerja dengan baik pada dataset citra dengan jumlah fitur yang relatif sedikit. Namun, dalam

menggunakan sinar UV dengan metode *machine learning*. Kemudian juga telah dilakukan pengujian terhadap metode dan peralatan yang digunakan. Berdasarkan hasil pengujian yang telah dilakukan, dapat ditarik beberapa kesimpulan

citra dengan resolusi tinggi atau banyak saluran warna, jumlah fitur bisa sangat besar. Hal ini dapat menyebabkan peningkatan waktu komputasi dan kebutuhan memori yang signifikan, yang dapat menghambat performa dan skalabilitas algoritma. Pada metode *Random Forest* ini mendapatkan kebenaran hasil pengindentifikasian uang kertas rupiah sebesar 74%.

Naïve Bayes memiliki keterbatasan dalam memodelkan hubungan *non-linear* antara fitur dan label. Karena asumsi independensi fitur dan penggunaan model probabilitas sederhana, *Naïve Bayes* cenderung memberikan performa yang lebih baik pada masalah klasifikasi yang memiliki hubungan linier atau mendekati linier antara fitur dan label sehingga memiliki tingkat *misprediction* yang sangat tinggi. *Naive Bayes* memberikan nilai keberhasilan sebesar 77%.

Sehingga dipilih metode terakhir sebagai metode validasi untuk metode *machine learning*, yang sangat akurat dalam *image classification* dengan persentase sebesar 91%, yaitu *Convolution Neural Network*. CNN dirancang khusus untuk memproses data grid seperti citra. Dengan menggunakan operasi konvolusi, CNN dapat mengekstraksi fitur-fitur lokal dengan mempertahankan informasi spasialnya. Ini memungkinkan CNN untuk secara efektif menangkap pola, tekstur, dan struktur spasial yang kompleks dalam citra. CNN memiliki kecenderungan untuk menjadi invarian terhadap pergeseran dan skala dalam citra. Dengan menggunakan operasi konvolusi dan operasi penggabungan (*pooling*), CNN dapat mengidentifikasi fitur-fitur yang relevan dengan tidak tergantung pada posisi atau ukuran yang tepat dalam citra. Ini memungkinkan CNN untuk mengenali objek yang sama dalam citra yang memiliki perbedaan dalam posisi atau ukuran.

Setelah dilakukannya *detection*, maka mekanisme *counting* memiliki peran penting. Dengan digunakannya mekanisme serupa seperti mekanisme penarikan kertas yang ada pada printer pada umumnya. Penggunaan mekanisme ini membutuhkan 2 roller sebagai mekanisme penggerak dan pemindah uang kertas rupiah. Pada roller pertama sering terjadi kesalahan pada saat penarikan, hal tersebut dapat terjadi jika penempatan uang kertas rupiah tidak lurus dan simetris sehingga pada saat roller pertama berputar uang tidak menuju ke arah roller kedua melainkan menuju arah lain.

Berdasarkan hasil yang didapatkan, uang kertas dengan tumpukan lebih dari 10 lembar memberikan hasil prediksi yang hampir semuanya tidak tepat hal tersebut terjadi karena banyaknya tumpukan memengaruhi posisi atau jarak uang kertas terhadap *webcam*.

Karena prototipe dirancang dengan dimensi minimum maka uang kertas yang *overload* akan mengganggu proses *counting*. Jumlah uang kertas yang dapat ditampung untuk mendapatkan hasil prediksi yang baik adalah < 10 lembar.

V. KESIMPULAN

Dari hasil kegiatan tugas akhir ini, dirancang sebuah prototipe sistem pendeteksi keaslian uang kertas rupiah

sebagai berikut: (1) Prototipe berhasil memprediksi keaslian uang kertas rupiah sekaligus nominal beserta dengan Tahun Emisinya, dengan *k-NN* dan *CNN* memberikan hasil lebih dari 90%, *SVM* lebih dari 85%, *Random Forest* dan *Naive*

Bayes kurang dari 80%. (2) Prototipe berhasil mengoperasikan proses *counting* secara maksimal dengan batas maksimal uang kertas pada prototipe adalah tidak lebih dari 10 lembar. (3) Pada keadaan ekstrim, prototipe hanya memberikan prediksi yang benar pada kondisi lusuh dan tercoret/ rusak dengan tingkat kebenaran lebih dari 80%.

DAFTAR PUSTAKA

- [1] S. V. Viraktamath, K. Tallur, R. Bhadavankar, and others, "Review on Detection of Fake Currency using Image Processing Techniques," in *2021 5th International Conference on Intelligent Computing and Control Systems (ICICCS)*, 2021, pp. 865–870.
- [2] A. Bhatia, V. Kedia, A. Shroff, M. Kumar, B. K. Shah, and others, "Fake Currency Detection with Machine Learning Algorithm and Image Processing," in *2021 5th international conference on intelligent computing and control systems (ICICCS)*, 2021, pp. 755–760.
- [3] A. P. Pujiputra, H. Kusuma, and T. A. Sardjono, "Ultraviolet Rupiah Currency Image Recognition using Gabor Wavelet," in *2018 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, 2018, pp. 299–303.
- [4] S. Arya and M. Sasikumar, "Fake Currency Detection," in *2019 International Conference on Recent Advances in Energy-efficient Computing and Communication (ICRAECC)*, 2019, pp. 1–4.
- [5] R. Sumalatha, B. J. Reddy, and T. V. R. Reddy, "Identification of Fake Indian Currency using Convolutional Neural Network," in *2022 6th International Conference on Computing Methodologies and Communication (ICCMC)*, 2022, pp. 1619–1623.
- [6] M. Wang, Y. Sun, and F. Xia, "Workpiece Image Mosaic Technology Based on OpenCV Image Processing," in *2021 International Conference on Control Science and Electric Power Systems (CSEPS)*, 2021, pp. 71–74.
- [7] R. C. Gonzales and P. Wintz, *Digital Image Processing*. New York: Addison-Wesley Longman Publishing Co., Inc., 1987.
- [8] J. Alzubi, A. Nayyar, and A. Kumar, "Machine learning from theory to algorithms: an overview," in *Journal of physics: conference series*, 2018, vol. 1142, p. 12012.
- [9] F. J. Pulgar, F. Charte, A. J. Rivera, and M. J. Del Jesus, "AEkNN: an autoencoder kNN-based classifier with built-in dimensionality reduction," *arXiv Prepr. arXiv1802.08465*, 2018.
- [10] K. Fawagreh, M. M. Gaber, and E. Elyan, "On extreme pruning of random forest ensembles for real-time predictive applications," *arXiv Prepr. arXiv1503.04996*, 2015.
- [11] N. Kalcheva, M. Todorova, and G. Marinova, "Naive Bayes Classifier, Decision Tree and AdaBoost Ensemble Algorithm--Advantages and Disadvantages," in *Proceedings of the 6th ERAZ Conference Proceedings (part of ERAZ conference collection)*, Online, 2020, pp. 153–157.
- [12] B. Vikramkumar and T. Vijaykumar, "Bayes and naive bayes classifier," *arXiv 10.48550/ARXIV.1404.0933*, 2014.
- [13] A. Avramović, D. Sluga, D. Tabernik, D. Skočaj, V. Stojnić, and N. Ilc, "Neural-Network-Based Traffic Sign Detection and Recognition in High-Definition Images using Region Focusing and Parallelization," *IEEE Access*, vol. 8, pp. 189855–189868, 2020.
- [14] R. Chauhan, K. K. Ghanshala, and R. C. Joshi, "Convolutional Neural Network (CNN) for Image Detection and Recognition," in *2018 1st International Conference on Secure Cyber Computing and Communication (ICSCCC)*, 2018, pp. 278–282.
- [15] V. Gurevich, *Electric Relays: Principles and Applications*. New York: CRC press, 2018, ISBN : 0-8493-4188-4..