

IMPLEMENTASI METODE *DEEP LEARNING* PADA PROTOTIPE VALIDATOR UANG RUPIAH

Adytia Darmawan¹⁾, I Gusti Nyoman Geri Athallah Widyadhana²⁾, dan Eko Henfri Binugroho³⁾

^{1,2,3}Teknik Mekatronika, Politeknik Elektronika Negeri Surabaya

^{1,2,3}Jl. Raya ITS, Keputih, Sukolilo, Surabaya, 60111

E-mail: adyt@pens.ac.id¹⁾, nyomangeri7@gmail.com²⁾, sragen@pens.ac.id³⁾

ABSTRAK

Validator uang kertas adalah alat untuk memvalidasi keaslian serta nominal uang kertas yang sering digunakan pada mesin penjual otomatis. Ketepatan pendeteksian nominal dan keaslian uang kertas sangat penting pada alat validator ini. Banyak validator uang kertas yang buruk kinerjanya ketika mendeteksi uang yang usang. Untuk meningkatkan ketepatan dilakukan pengembangan validator uang kertas rupiah dengan menggunakan metode *deep learning*. Model yang digunakan tidak hanya dapat memvalidasi keaslian uang rupiah, tetapi juga dapat mengklasifikasikan nilai nominal uang rupiah. Agar sistem *robust*, sistem akan mengidentifikasi uang kertas dua kali menggunakan dua model yang berbeda. Model pertama untuk mengenali nominal uang di bawah sinar *Light Emitting Diode* (LED), sedangkan model kedua digunakan untuk mengenali keaslian dari uang melalui gambar tak kasat mata yang muncul di bawah sinar ultraviolet (UV). Pecahan Rupiah yang digunakan untuk data set adalah Rp1.000,00, Rp2.000,00, Rp5.000,00, dan Rp10.000,00. Uang kertas Rupiah palsu juga digunakan untuk training model. Keseluruhan metode diuji coba pada prototipe validator uang kertas yang telah dibuat. Hasil percobaan menunjukkan masing-masing model memiliki akurasi yang baik dalam mendeteksi uang kertas Rupiah dengan presisi 99% untuk setiap kelas.

Kata Kunci: *Validator Uang, Uang Kertas, Deep Learning, Akurasi, Keaslian, Prototipe Validator.*

1. PENDAHULUAN

Rupiah adalah mata uang resmi yang diakui oleh Negara Republik Indonesia (Watung, 2019). Berdasarkan bentuk fisiknya, uang Rupiah terbagi menjadi dua bentuk yaitu uang kertas dan uang logam (Sumaila, 2020). Kedua jenis tersebut memiliki ciri khas tersendiri untuk menentukan keaslian uang tersebut. Koin dapat dibedakan dari diameternya dan bahan yang digunakan untuk membuat koin tersebut. Sedangkan uang kertas rupiah terbuat dari kertas yang memiliki ciri khas tersendiri yang dapat membedakan uang kertas asli dan palsu. Ciri-ciri tersebut adalah warna, benang pengaman, logo Bank Indonesia, *watermark*, gambar *recto verso*, dan lain-lain. Ada juga ciri-ciri kasat mata yang bisa terlihat saat uang kertas terkena sinar Ultraviolet (UV). Maraknya pembayaran digital menggunakan uang elektronik, tentu merubah kebiasaan masyarakat pada umumnya. Tidak semua masyarakat dapat langsung beralih ke uang digital, sehingga masih diperlukan uang tunai untuk sistem pembayaran. Untuk mendukung program *contactless* diperlukan alat yang mengkombinasikan pembayaran digital dengan pembayaran tunai secara otomatis. Transaksi tunai biasanya dilakukan antar manusia, namun kini manusia dapat melakukan transaksi dengan alat seperti *vending machine*. *Vending machine* adalah mesin yang dapat menjual produk kepada pelanggan secara otomatis berdasarkan pilihan mereka. Proses ini dapat dilakukan tanpa adanya interaksi antar manusia. Karena proses jual

beli sudah otomatis, diperlukan alat tambahan untuk mendeteksi keaslian dan nominal uang kertas yang diberikan nasabah. Sistem yang biasa digunakan untuk mengenali uang pada mesin penjual otomatis memiliki akurasi yang tinggi, tetapi dengan meningkatnya siklus penggunaan uang kertas, beberapa karakteristik mungkin hilang tetapi karakteristik lain seperti keamanan benang, gambar laten, dan *watermark* tidak (Lee dkk, 2017). (Sujana dkk, 2019) telah mengkomparasikan analisis sistem pembayaran uang tunai *cash money* dan *e-money*. Pada intinya fleksibilitas sangat mudah menggunakan *e-money*, akan tetapi tidak semua masyarakat menggunakan *e-money*. Masih banyak orang menggunakan *cash money*. Penggunaan *cash money* perlu difasilitasi agar pengguna tidak terlalu rumit untuk mempersiapkan uang yang harus terkondisi warnanya, tidak terlipat dan tidak terbalik. Beberapa penelitian telah dilakukan untuk menciptakan sistem yang tepat dengan tingkat penerimaan yang tinggi untuk validasi uang kertas. Ada penelitian yang menggunakan sensor warna untuk mendeteksi keaslian uang kertas.

(Andika dkk, 2018) dan (Alifuddin dkk.,2019) menggunakan sensor warna TCS3200 untuk mengumpulkan nilai uang kertas. Kinerja sistem sangat bergantung pada kondisi fisik uang. Jika kondisi uang usang, maka model deteksi dengan sensor warna saja kurang akurat, sehingga sering diabaikan dan tidak bisa digunakan seperti penelitian yang telah dilakukan oleh (Lubis, Z., & Annisa, 2020) yang juga mengalami

kegagalan jika kondisi uangnya usang. Pada penelitian ini dibuatlah prototipe validator uang yang memanfaatkan metode *image processing* dengan mengimplementasikan metode *deep learning*. (Azhar dkk., 2021) telah menggunakan *deep learning* untuk mendeteksi nilai mata uang kertas yang peruntukannya digunakan untuk orang yang mengalami *low vision*. Dari hasil penelitiannya berupa simulasi belum tertanam pada *system embedded* sehingga komputasi keseluruhan algoritma dilakukan di *Personal Computer*. Begitu pula dengan penelitian (Sani dkk., 2016) yang membuat aplikasi di PC yang dapat mendeteksi nominal uang berbasis *deep learning*. Pada implementasinya tidak hanya simulasi akan tetapi di uji pada prototipe alat yang dibuat yang tentunya memiliki keterbatasan spesifikasi karena memanfaatkan raspberry untuk komputasinya sehingga perlu dilakukan optimasi agar metode tersebut dapat diterapkan pada *embedded* sistem yang digunakan.

2. RUANG LINGKUP

Ruang lingkup penelitian ini adalah mengimplementasikan *image processing* dengan metode *deep learning* agar prototipe validator yang dibuat memiliki akurasi yang baik ketika mendeteksi uang usang ataupun tidak. Pada implementasinya tidak hanya simulasi akan tetapi di ujicobakan pada prototipe validator uang kertas yang telah dibuat. Harapannya dengan dibuatnya prototipe alat berbasis *image processing* ini dapat sebagai sumber referensi yang dapat mendukung program pembayaran *contactless* (nirsentuh) dengan kepresisian pendeteksian nilai nominal dan keaslian uang kertas. Pada penelitian ini hanya dilakukan pengujian beberapa nilai mata uang rupiah yaitu uang kertas rupiah Rp1.000, Rp2.000, Rp5.000 dan Rp10.000. Harapannya dengan metode yang dipilih, pendeteksian uang lebih fleksibel dan akurat. Fleksibel yang dimaksud adalah alat tetap mampu mendeteksi uang kertas dengan presisi walau dalam kondisi uang usang/baru, sedikit terlipat, dan posisi tidak beraturan.

3. BAHAN DAN METODE

Pemrosesan gambar merupakan metode yang terbaik untuk membedakan uang asli dan uang palsu. Gambar 1 menunjukkan ciri-ciri uang kertas rupiah dengan *watermark* yang merupakan unsur pengaman yang dapat dilihat dengan diterawang.

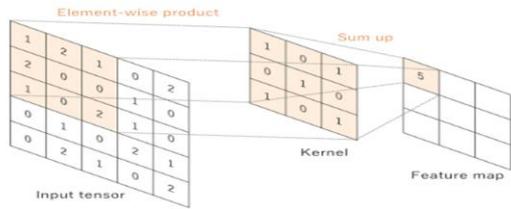


Gambar 1. Watermark uang 10000 (Bank Indonesia, 2022)

(Apoloni dkk, 2022) menggunakan *Optical Character Recognition* untuk mendeteksi teks pada uang kertas dan *K-means clustering* untuk mendeteksi nilai warna uang kertas dengan rata-rata validasi sistem mencapai 95,86%. (S. Dhanya dkk, 2016) membuat gambar *template* uang asli dan membandingkannya dengan input menggunakan LabView. Rushikesh Jadhav, et. Al. (Jadhav dkk, 2022), mengimplementasikan *Convolution Neural Network* sebagai model *deep learning* untuk mendeteksi uang kertas dengan akurasi 95%. Model yang dibuat tidak hanya berfungsi sebagai pengenalan tetapi juga sebagai kalkulator karena menambahkan semua denominasi mata uang yang dikenalnya. Pembelajaran transfer juga bisa menjadi solusi untuk mengenali uang kertas. Dengan basis seperti *ResNet152v2*, *MobileNet*, dan *NASNetMobile* ditambah dengan arsitektur *Convolutional Neural Network* baru dapat memberikan akurasi yang tinggi (Linkon dkk,2020). Dari referensi tersebut dilakukan penelitian lebih lanjut dan diuji pada prototipe yang dibuat. Pada implementasinya sangat diperlukan kajian penerapan *Convolutional Neural Network* (CNN) yang diproses menggunakan *embedded PC*. Pada penelitian ini memanfaatkan *YOLOv4-tiny* yang di proses pada prototipe validator yang telah dibuat dengan processor raspberry 4 disertai module kamera untuk mengambil gambar uang yang akan dideteksi.

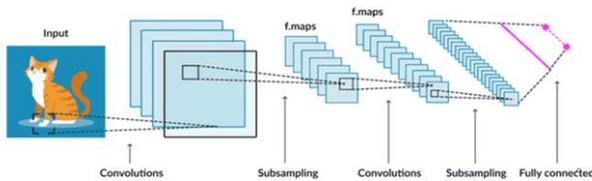
3.1 Convolutional Neural Network

Convolutional Neural Network (CNN) adalah jaringan saraf yang dirancang khusus untuk memproses data piksel dari gambar (Rahman dkk., 2021). CNN terdiri dari tiga layer, yaitu *convolutional layer*, *pooling layer*, dan *fully connected layer*. Tugas lapisan konvolusi adalah mengekstraksi fitur-fitur pada citra masukan. Filter *kernel* akan bergerak di sekitar citra melakukan *dot multiplier* dan nilai keseluruhan yang dicapai dapat disebut *feature maps*, seperti yang ditunjukkan pada Gambar 2.



Gambar 2. Contoh hasil konvolusi (Yamashita dkk, 2018)

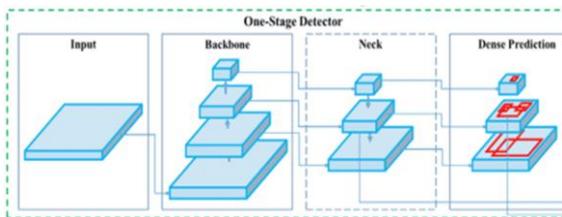
Pooling layer adalah untuk mengurangi dimensi dan total parameter. Pooling layer juga dapat digunakan untuk mengekstraksi fitur dominan. Feature map yang dibuat dari convolution layer dan pooling layer masih dalam array multidimensional, oleh karena itu perlu dibentuk ulang menjadi vektor. Vektor ini akan menjadi masukan dari lapisan yang terhubung sepenuhnya. Arsitektur CNN adalah seperti yang ditunjukkan pada Gambar. 3 (Indolia dkk, 2018).



Gambar 3. Arsitektur CNN (DL foundations, 2020)

3.2 YOLOv4

You Only Look Once (YOLO) adalah model deteksi obyek berbasis deep learning yang dibuat oleh Joseph Redmond. Joseph Redmond tidak berpartisipasi dalam pembuatan YOLOv4. Alexey Bochkovskiy, Chien-Yao Wang, dan Hong-Yuan Mark Liao mengembangkan YOLO menjadi YOLOv4 dan meningkatkan Average Precision (AP) 10% dan Frames Per Second (FPS) 12% dibandingkan dengan YOLOv3 (Bochkovskiy dkk, 2020). Model YOLO didasarkan pada Convolutional Neural Network (CNN) tunggal. CNN akan membagi citra menjadi beberapa region/grid yang kemudian memberikan prediksi dan probabilitas untuk setiap region secara bersamaan. Implementasi YOLOv4 menggunakan framework Darknet. Arsitektur YOLOv4 terdiri dari input, backbone, neck, dan dense prediction, seperti yang ditunjukkan pada Gambar 4.



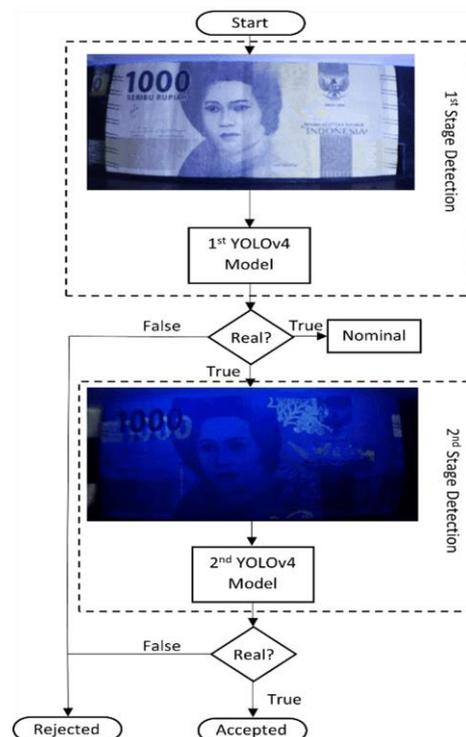
Gambar 4. Deteksi obyek single stage (Iyer dkk , 2021)

Input adalah bentuk gambar yang akan diubah ukurannya sesuai dengan resolusi layer input. Syarat layer yang bisa digunakan adalah bisa dibagi 32. Backbone YOLOv4 adalah CSPDarknet53 (Cross-Stage-Partial-connections). Layer ini akan melakukan ekstraksi fitur dengan membagi input feature map menjadi dua bagian.

Bagian neck adalah lapisan antara backbone dan dense prediction. Di bagian ini, untuk pengumpulan feature maps dan membuat beberapa predictive paths moving dari atas ke bawah atau sebaliknya. Di YOLOv4 menggunakan Path Aggregation Network (PANet) untuk layer neck. Lapisan terakhir YOLOv4 adalah dense prediction. Dimana pada layer ini akan memberikan gambar kotak-kotak pembatas.

Metode yang diusulkan untuk validasi keaslian uang kertas Rupiah adalah dengan menggunakan dua model YOLOv4 yang dilatih secara terpisah menggunakan dataset yang berbeda. Model pertama untuk mendeteksi uang kertas saat disinari dengan lampu LED. Jika terdeteksi uang kertas palsu, maka tidak akan dilanjutkan ke tahap pendeteksian berikutnya. Setelah terdeteksi sebagai uang kertas asli, sistem akan melanjutkan ke tahap pendeteksian berikutnya.

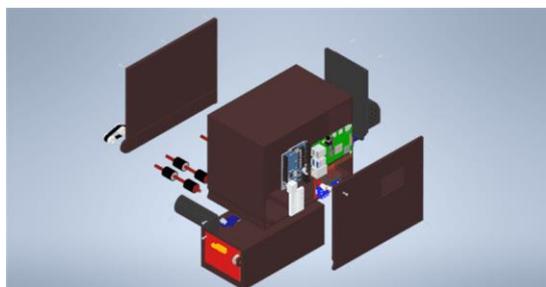
Tahap selanjutnya adalah memvalidasi uang kertas yang disinari lampu ultraviolet. Fitur tersembunyi uang kertas Rupiah akan ditampilkan dan model kedua YOLOv4 digunakan untuk memvalidasi fitur yang muncul pada uang kertas Rupiah. Ilustrasi alur kerja seperti pada Gambar 5.



Gambar 5. Alur kerja sistem

4. PEMBAHASAN

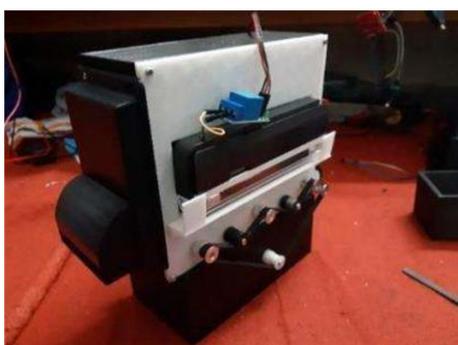
Prototipe alat yang dibuat terdiri dari raspberry untuk implementasi metode yang digunakan, camera untuk mendeteksi uang yang masuk, sinar UV dan lampu LED sebagai sinar pencahayaan, arduino dan driver motor digunakan untuk proses memasukkan dan mengeluarkan uang yang akan dideteksi. Gambar 6 adalah desain yang telah dibuat.



Gambar 6. Desain prototipe alat pembayaran

4.1 Persiapan Dataset

Sebelum membuat model YOLOv4 diperlukan dataset yang terdiri dari gambar yang berisi label kelas. Pecahan yang digunakan adalah Rp1.000,00, Rp2.000,00, Rp5.000,00, dan Rp10.000,00. Perbedaan model 1 dan 2 ini terletak pada pengujiannya, yaitu ketika diberi sinar UV untuk model 2 dengan tidak diberi sinar UV untuk model 1. Pada model 1 sudah dapat diketahui nominal serta keaslian uang yang diuji. Untuk memperkuat *statement* keaslian digunakan model 2 yaitu dengan memvalidasi jika uang kertas yang dideteksi disinari UV. Untuk mendeteksi uang rupiah palsu setiap model, baik model 1 dan 2 dilatih dengan gambar uang rupiah palsu. Semua gambar diambil menggunakan Modul Kamera yang terpasang pada prototipe yang telah terealisasi pada gambar 7.



Gambar 7. Realisasi prototipe alat

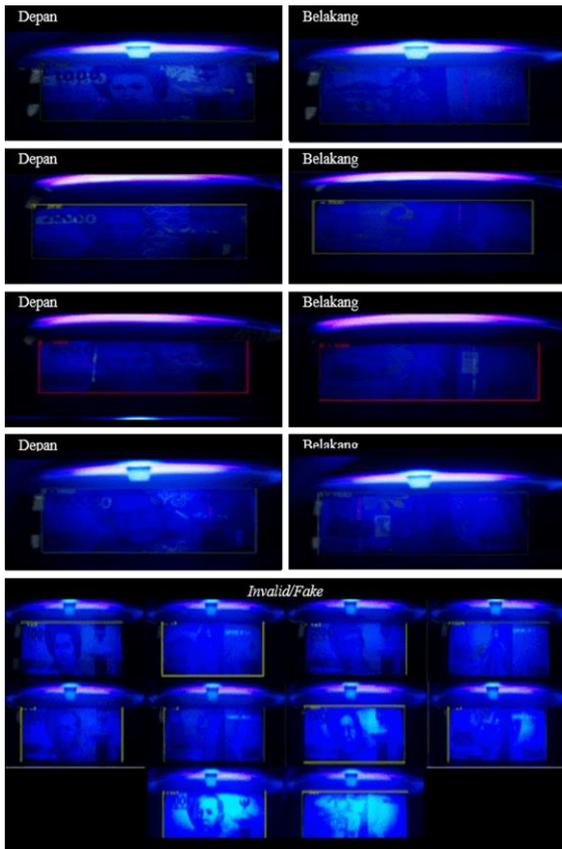
Dataset pertama terdiri dari gambar-gambar uang Rupiah yang tersinari oleh lampu LED. Jumlah dataset yang digunakan untuk melakukan proses *training* adalah sebanyak 100 gambar pada setiap nominal yang terdiri dari uang yang halus, uang kusut, dan uang terlipat atau tertekuk.

Gambar 8 merupakan sampel masing-masing kelas yang digunakan untuk melatih model pertama.



Gambar 8. Sampel dataset tanpa UV

Sampel dataset di tiap kelas diambil dari prototipe alat validator yang telah dibuat. Gambar yang diambil tampak dari depan dan belakang uang kertas yang akan dideteksi. Terdapat 5 kelas yaitu uang pecahan Rp1.000, Rp2.000, Rp5.000, Rp10.000, dan uang *invalid*/palsu. Terdapat 2 model proses pendeteksian yaitu pengambilan gambar uang kertas tanpa penyinaran sinar UV dan dengan penyinaran sinar UV. Tujuan penggunaan kedua model tersebut adalah agar sistem lebih *robust* dalam mendeteksi uang rupiah palsu. Pada model kedua dilatih menggunakan gambar uang kertas rupiah di bawah sinar UV, baik uang asli ataupun palsu. Pengumpulan gambar uang kertas Rupiah di bawah lampu LED dan sinar UV tidak cukup untuk melatih model YOLOv4. Model YOLOv4 juga membutuhkan label dari setiap gambar. Seperti yang ditunjukkan pada gambar 8 dan gambar 9 yang telah diberi label. Label terdiri dari koordinat kotak pembatas dan nama kelas. Setelah mendapatkan seluruh citra dan label yang terkumpul, langkah selanjutnya adalah membagi dataset utama untuk menjadi dataset training, dataset validasi, dan dataset *testing*. Pada gambar 8 dan 9 merupakan contoh dataset tiap model. Untuk model 2 ini terletak pada gambar 9 yang menunjukkan gambar sampel dari setiap kelas dataset yang diambil.

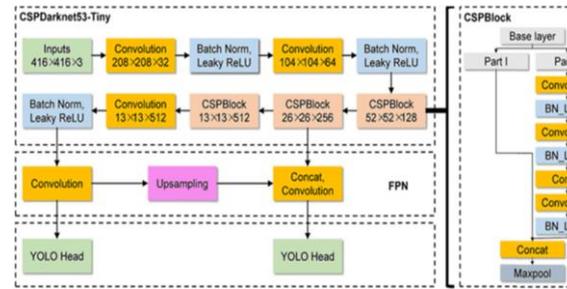


Gambar 9. Sampel dataset dengan sinar UV

Rasio yang digunakan untuk membagi dataset adalah 75% untuk pelatihan, 13% untuk validasi, dan 12% untuk pengujian. Rasio ini berlaku untuk masing-masing kelas. Setelah dilakukan pemisahan setiap dataset kelas, citra-citra tersebut digabungkan lagi menjadi satu dataset. Sebagai contoh, dataset untuk pelatihan berisi 75 gambar dari setiap kelas. Dikarenakan terdapat 5 kelas diperlukan jumlah total gambar untuk pelatihan adalah 375 gambar.

4.2 YOLOv4 Model

Membuat model YOLOv4 dapat memakan banyak ruang memori. Tidak banyak perangkat yang mampu menjalankan model YOLOv4 untuk deteksi objek. Dalam penelitian ini model perlu diimplementasikan dalam *embedded system*. Solusi untuk ini adalah dengan menggunakan model YOLOv4-tiny. Modelnya masih bekerja dengan cara yang sama seperti model YOLOv4 asli, tetapi memiliki ukuran file yang kecil. Dengan ukuran file yang kecil diharapkan komputasinya tidak terlalu berat dibandingkan versi YOLOv4 yang di proses prototipe alat validator yang telah dibuat. Gambar 10 menunjukkan arsitektur YOLOv4-tiny.



Gambar 10. Arsitektur YOLOv4 tiny

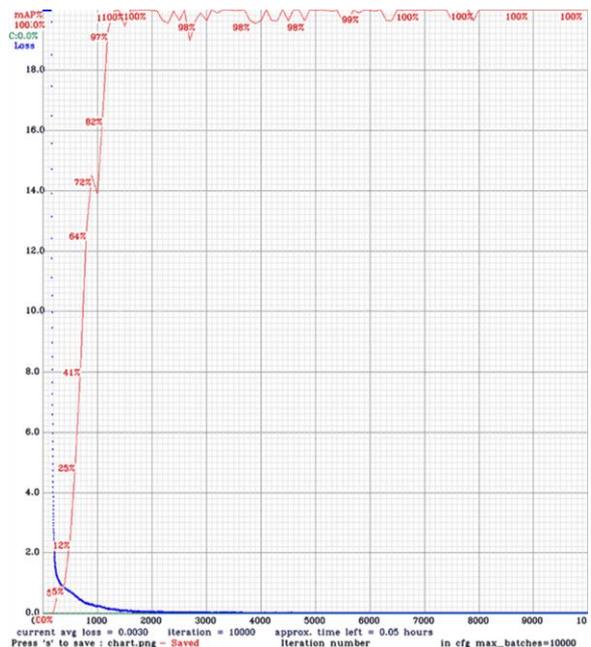
Sebelum melatih YOLOv4-tiny, kita perlu menentukan filter untuk kedua konvolusi yang terjadi sebelum YOLO Head. Persamaan (1) dapat digunakan untuk mencari jumlah filter yang tepat.

$$Filter = (number\ of\ classes + 5) \times 3 \quad (1)$$

Karena jumlah kelasnya lima, maka filter untuk lapisan konvolusi adalah 30. Artinya keluarannya akan menjadi 30 dimensi dengan ukuran *filter* 3 x 3. Bobot kecil YOLOv4 dilatih menggunakan 29 lapisan pertama dari bobot prapelatihan untuk lapisan konvolusional.

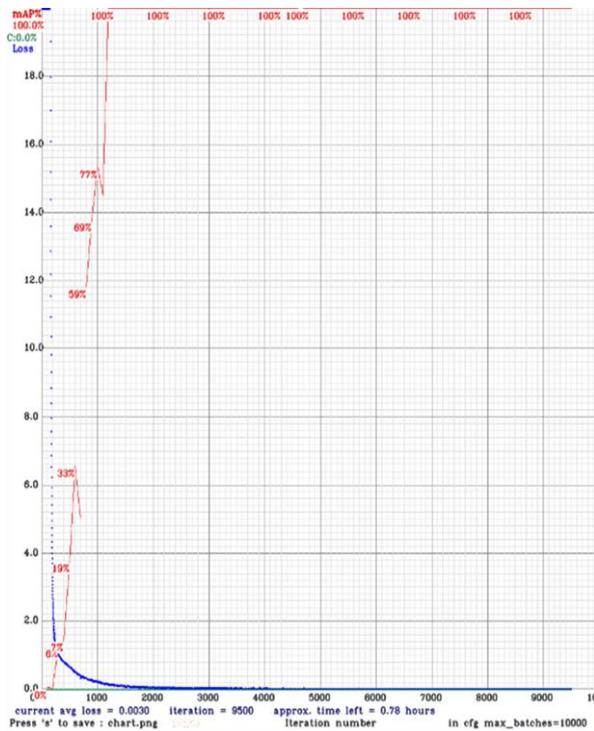
4.3 Hasil Eksperimen

Hasil training bobot YOLOv4 pertama seperti pada Gambar 11. Iterasi yang digunakan untuk training adalah 10000. Dari hasil tersebut terlihat *Mean Average Precision* (MAP) mencapai 100% dengan rata-rata loss 0,003 dan tidak berkurang lagi. Proses *training* model dilakukan dengan menggunakan *virtual machine Google Colab*. Proses ini berjalan selama delapan jam dengan hasil *training* model pertama.



Gambar 11. Training chart YOLOv4-tiny pertama

Model kedua yang dilatih menggunakan citra uang kertas UV Rupiah mencapai 100% MAP sekitar 1000 iterasi dengan rata-rata loss sekitar 0,1. Kerugian berkurang selama iterasi hingga mencapai 0,003, tetapi MAP tetap sama. Iterasi pelatihan adalah 9500. Hasil kedua seperti pada Gambar 12.



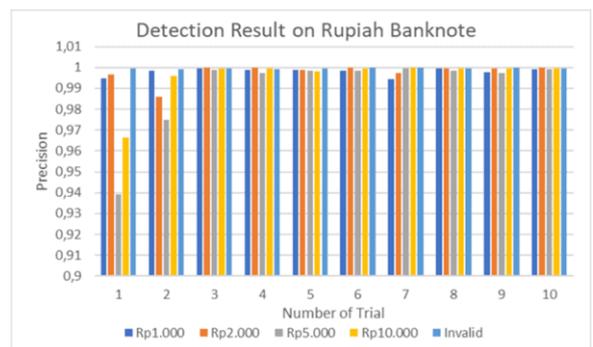
Gambar 12. Training chart YOLOv4-tiny kedua

Kedua bobot yang telah dibuat tersebut perlu diuji untuk melihat kinerja dalam mengklasifikasikan pecahan dan keaslian uang rupiah. Eksperimen dilakukan dengan menggunakan Raspberry Pi 4 model B sebagai perangkat untuk menjalankan model dan bobot YOLOv4-tiny. Setiap gambar uang Rupiah yang diambil diubah ukurannya menjadi 416 x 416 dan dinormalisasi sebelum digunakan sebagai input. Menggunakan dataset testing yang sudah dibuat saat memecah seluruh dataset dan tambahan uang Rupiah yang bukan dari dataset. Gambar yang digunakan untuk pengujian adalah uang kertas Rupiah pecahan Rp1.000,00, Rp2.000,00, Rp5.000,00, Rp10.000,00, dan uang Rupiah palsu terdiri dari uang kertas mainan dan uang cetak menggunakan printer. Pengujian dilakukan dengan cara mendeteksi setiap kelas sebanyak 10 kali dengan uang yang berbeda pada setiap percobaan. Selain menampilkan kepresisian model dalam mendeteksi uang, model dapat menghasilkan *boundary box* yang berfungsi untuk menandai objek yang terdeteksi. Eksperimen pertama adalah dengan menggunakan model 1. Hasil sampel pendeteksian uang kertas Rupiah seperti pada Gambar 13.



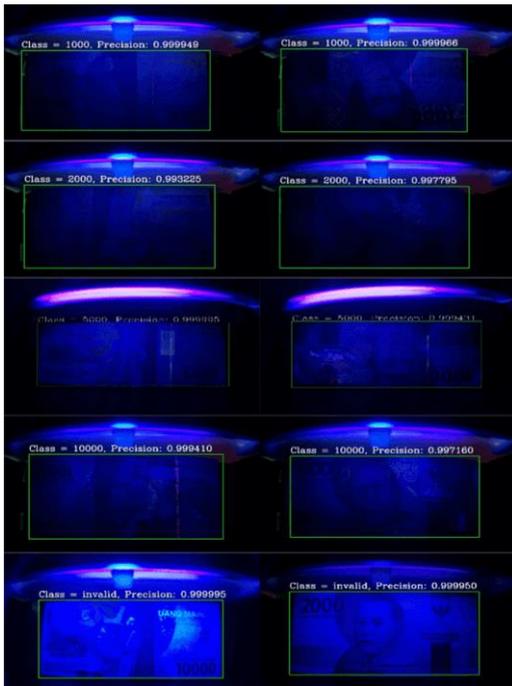
Gambar 13. Hasil deteksi model 1

Gambar 14 menunjukkan hasil presisi dari setiap percobaan. Dari hasil saat model deteksi Rp1.000 memiliki presisi rata-rata 99,79%, untuk Rp2.000 presisi rata-rata yang diperoleh adalah 99,78%, presisi rata-rata saat mendeteksi Rp5.000 adalah 99,02%, presisi rata-rata dalam mendeteksi uang kertas Rp10.000 adalah 99,57%, dan terakhir saat mendeteksi uang kertas yang tidak sah memiliki presisi rata-rata 99,95%.



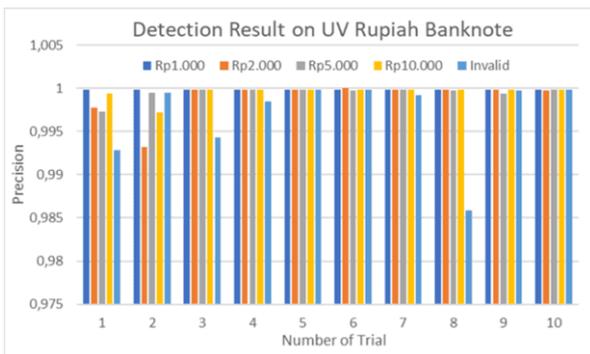
Gambar 14. Hasil uji rerata kepresisian deteksi uang model 1

Model kedua diuji menggunakan pecahan Rupiah yang sama seperti sebelumnya dan mata uang Rupiah palsu yang sama. Untuk menguji keakuratan model kedua uang kertas Rupiah disinari sinar UV dari lampu UV. Contoh hasil uji coba ditunjukkan pada Gambar 15.



Gambar 15. Hasil deteksi model 2

Hasil dari seluruh pengujian dibentuk menjadi grafik yang dapat dilihat pada Gambar 16. Dari grafik tersebut terlihat rata-rata presisi model saat mendeteksi Rp1.000 sebesar 99,99%, Rp2.000 mencapai 99,902%, Rp5.000 diperoleh rata-rata presisi 99,95%, pendeteksian Rp10.000 mencapai 99,96%, dan Invalid memiliki presisi rata-rata 99,69%.



Gambar 16. Hasil uji rerata kepresisian deteksi uang model 2

Perbedaan presisi saat mendeteksi uang rupiah dengan kedua model dipengaruhi oleh posisi uang kertas. Karena kamera menggunakan lensa lebar tambahan, gambar yang diambil terdistorsi. Jika uang kertas tidak berada di tengah kamera, akan ada lebih banyak distorsi.

5. KESIMPULAN

Implementasi metode *deep learning* pada prototipe validator uang rupiah ini memiliki rerata presisi 99% untuk setiap kelas atau nominal yang diuji. Pemanfaatan pendeteksian keaslian uang kertas dengan metode *image processing* merupakan solusi terbaik agar uang walaupun usang ataupun tidak, tetap terbaca dengan baik. Kondisi uang yang sedikit terlipat masih mampu dideteksi dengan baik. Terkadang pembayaran uang kertas pada *vending machine* umumnya selalu dikondisikan posisinya ketika memasukkan ke alatnya, agar mesin mampu mendeteksi dengan baik. Hal ini ditandai dengan akurasi MAP di kedua model menunjukkan hasil yang baik saat pelatihan dan pengujian. Grafik pelatihan kedua model mencapai 100% MAP. Saat menguji kedua model, presisi rata-rata sekitar 99% untuk setiap kelas. Dengan adanya pengembangan pendeteksian ini, posisi uang yang terbalik tetap dapat terdeteksi asalkan data set yang digunakan telah tersedia dan telah dilatih pada mesin

6. SARAN

Pengembangan validator uang tunai khususnya uang kertas sangat baik akurasi dan ketepatannya ketika menggunakan *image processing*. Perlu ditambahkan proses kalibrasi *image* pada kamera untuk mengurangi distorsi kamera akibat penambahan lensa *wide* sebelum pengambilan data dan proses pendeteksian. Kalibrasi ini penting agar pendeteksian lebih akurat. Setelah tidak ada distorsi gambar penambahan *caliper image* mungkin bisa digunakan agar lebih akurat pendeteksian. Dengan metode ini, gambar pencari dari uang yang akan dideteksi dapat dibandingkan dengan detail uang asli. Sistem prototipe yang dibuat, ke depan akan digabungkan dengan *payment gateway*, sehingga menjadi *raw model low cost* sistem yang memiliki fitur pembayaran uang digital dan uang tunai kertas pada satu alat *portable* ini.

7. DAFTAR PUSTAKA

- Alifuddin, M. (2019, 5). Rancang bangun sistem pengembalian uang kertas rupiah pada mesin vending berbasis arduino uno. *ILKOM Jurnal Ilmiah*, 11(1), 77-85.
- Andika, F., & Kustija, J. (2018, 7). *Nominal of Money and Colour Detector for the Blind People*. *IOP Conference Series: Materials Science and Engineering*, 384(1).
- Apoloni, J., Escueta, S., & Sese, J. (2022, 5). *Philippine Currency Counterfeit Detector using Image Processing*. *2022 IEEE 18th International Colloquium on Signal Processing & Applications (CSPA)*, 436-441.
- Azhar, K., Santoso, I., & Soetrisno, Y. (2021, 9). Implementasi *Deep Learning* Menggunakan Metode *Convolutional Neural Network* dan

- Algoritma YOLO Dalam Sistem Pendeteksi Uang Kertas Rupiah bagi Penyandang *Low Vision*. *Transient: Jurnal Ilmiah Teknik Elektro*, 10(3), 502-509.
- Bank Indonesia. (2022, November). Retrieved from Detil Uang: <https://www.bi.go.id/id/rupiah/gambaruang/Detail-Uang.aspx?Bahan=Kertas&ID=14>
- Bochkovski, A., Wang, C.-Y., & Liao, H.-Y. (2020, 4). YOLOv4: *Optimal Speed and Accuracy of Object Detection*. Retrieved from <http://arxiv.org/abs/2004.10934>
- Dhanya, S., & Kirthika, N. (2016, 11). *Design and implementation of currency recognition system using LabVIEW*. 2016 Online International Conference on Green Engineering and Technologies (IC-GET), 1-5.
- DL Foundation. (2020). *Neural Network from scratch: Part 3; Deep Learning Framework Implementation*. Retrieved from <https://foundationsofdl.com/2020/07/18/deep-learning-framework-from-scratch-part-3/>
- Indolia, S., Goswami, A., Mishra, S., & Asopa, P. (2018). *Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach*. *Procedia Computer Science*, 132, 679-688.
- Iyer, R., Shashikant Ringe, P., Varadharajan Iyer, R., & Prabhulal Bhensdadiya, K. (2021). *Comparison of YOLOv3, YOLOv5s and MobileNet-SSD V2 for Real-Time Mask Detection*. Article in *International Journal of Research in Engineering and Technology*. Retrieved from <https://www.researchgate.net/publication/353211011>
- Jadhav, R., Kalbande, S., Katkar, R., Katta, R., Bharadwaj, R., Year, T., & Rakhi Bharadwaj, P. (2022). *Currency Recognition using Machine Learning*. *International Research Journal of Engineering and Technology*. Retrieved from www.irjet.net
- Lee, J. W., Hong, H. G., Kim, K. W., & Park, K. R. (2017). *A survey on banknote recognition methods by various sensors*. Switzerland: MDPI AG.
- Linkon, A., Labib, M., Bappy, F., Sarker, S., Marium-E-Jannat, & Islam, M. (2020, 12). *Deep Learning Approach Combining Lightweight CNN Architecture with Transfer Learning: An Automatic Approach for the Detection and Recognition of Bangladeshi Banknotes*. Retrieved from <http://arxiv.org/abs/2101.05081>
- Lubis, Z., Annisa, S., & Di, A. (2020). *Perancangan Alat Baru Untuk Nominal Uang Pada Vending Machine*.
- Rahman, S. R. (2021). *Convolutional Neural Networks Untuk Visi Komputer Jaringan Saraf Konvolusional untuk Visi Komputer (Arsitektur Baru, Transfer Learning, Fine Tuning, dan Pruning)*. Deepublish.
- Sani, K., Winarno, W., & Fauziati, S. (2016). *Analisis Perbandingan Algoritma Classification untuk Authentication Uang Kertas (Studi Kasus: Banknote Authentication)*.
- Sujana, D., Mardzotillah, Q., Nuraidin, A., Rosip, M. A., & Sulistianto, W. (2019). *Komparasi Analisa Sistem Simulasi Vending Machine Automatic Cash Money Dan E-Money Di Universitas Islam Syekh Yusuf Tangerang*. *JUTIS*, 7(1).
- Sumaila, M. V. (2020). *Persepsi Pedagang Terhadap Penggunaan Uang Logam Yang Tidak Digunakan Di Desa Molompar Timur Kecamatan Belang*. MANADO: IAIN MANADO.
- Watung, P. (2019). *Kajian Yuridis Mengenai Keberadaan Bitcoin Dalam Lingkup Transaksi Di Indonesia Ditinjau Dari UU No. 7 Tahun 2011 Tentang Mata Uang*. *Lex Et Societatis*, 5-13.
- Yamashita, R., Nishio, M., Do, R., & Togashi, K. (2018, 8). *Convolutional neural networks: an overview and application in radiology*. *Insights into Imaging*, 9(4), 611-629.