

Klasifikasi Nominal Uang Berbasis Stacking Ensemble pada Celengan IoT dengan Sensor TCS34725

Syapiq Rabani¹, Tri Widodo^{1*}, Okma Arnilia²

¹Fakultas Teknik dan Ilmu Komputer, Universitas Teknokrat Indonesia, Bandar Lampung, Indonesia

²Fakultas Ilmu Tarbiyah dan Keguruan, Universitas Islam Negeri Siber Syekh Nurjati Cirebon, Cirebon, Indonesia

Email: ¹syapiq_rabani@teknokrat.ac.id, ^{2*}tri_widodo@teknokrat.ac.id, ³okmaarnilia@uinss.ac.id

Email Penulis Korespondensi: tri_widodo@teknokrat.ac.id*

Submitted: 30/08/2026; Accepted: 11/09/2026; Published: 30/09/2026

Abstrak– Celengan konvensional memiliki kelemahan mendasar berupa ketiadaan pencatatan saldo otomatis, sedangkan upaya identifikasi mandiri menghadapi kendala degradasi fisik uang lusuh dan fluktuasi spektrum warna. Penelitian ini bertujuan mengembangkan sistem celengan cerdas berbasis *Internet of Things (IoT)* yang mampu mengklasifikasikan tujuh pecahan nominal uang kertas Rupiah emisi tahun 2016 dan 2022 secara otomatis dan memantau saldo tabungan secara *real-time*. Perangkat keras sistem mengintegrasikan mikrokontroler ESP32 dan sensor spektrum warna TCS34725 dengan server REST API berbasis Python Flask. Data masukan warna diproses melalui ekstraksi 21 fitur spektrum diskriminatif (mencakup warna mentah, rasio relatif, kontras, ruang warna HSV, proyeksi trigonometri Hue, diferensial warna lawan, rasio logaritmik, dan luminansi), penyaringan noise sensor menggunakan Edited Nearest Neighbours (ENN), penstandaran skala StandardScaler, serta penyeimbangan distribusi kelas data latih menggunakan SMOTE. Proses klasifikasi menerapkan arsitektur Stacking Ensemble berbasis pohon keputusan yang menggabungkan Random Forest, XGBoost, CatBoost, dan Gradient Boosting sebagai model dasar, serta Random Forest Classifier sebagai model meta. Hasil pengujian menunjukkan bahwa model Stacking Ensemble memperoleh akurasi sebesar 93,07% dengan weighted average F1-score sebesar 0,93 pada 202 data uji murni. Pengujian langsung pada perangkat fisik celengan IoT menggunakan 70 lembar uang kertas asli independen dalam tiga kondisi fisik (baru, sedang, dan lusuh) menghasilkan tingkat keberhasilan pembacaan *real-time* sebesar 87,1%. Sistem berhasil mengintegrasikan pencatatan transaksi ke database MySQL dan pemantauan saldo pada dashboard web secara terpadu.

Kata Kunci: Celengan IoT; Klasifikasi Uang; Machine Learning; Stacking Ensemble; TCS34725

Abstract– Conventional piggy banks have a fundamental limitation due to the absence of automated balance recording, while autonomous banknote identification faces challenges from physical degradation of worn banknotes and spectral color shifts. This study develops an Internet of Things (IoT)-based smart piggy bank capable of automatically classifying seven denominations of Indonesian Rupiah banknotes (2016 and 2022 Emission Series) and monitoring savings balances in real time. The hardware architecture integrates an ESP32 microcontroller and a TCS34725 color sensor connected to a Python Flask-based REST API server. Spectral input data are processed through 21 discriminative feature extractions (including raw colors, relative ratios, contrast, HSV color space, trigonometric Hue projections, color opponency, logarithmic ratios, and luminance), sensor noise filtering using Edited Nearest Neighbours (ENN), StandardScaler normalization, and training class balancing using SMOTE. The classification framework applies a tree-based Stacking Ensemble combining Random Forest, XGBoost, CatBoost, and Gradient Boosting as base estimators, along with Random Forest Classifier as the meta-model. Experimental evaluation demonstrates that the Stacking Ensemble achieved an accuracy of 93.07% with a weighted average F1-score of 0.93 on 202 pure unseen test samples. Direct physical testing on the IoT piggy bank prototype using 70 independent genuine banknotes (separate from the dataset) across new, moderate, and worn physical conditions resulted in a real-time reading success rate of 87.1%. The system successfully integrates transaction logging into a MySQL database and real-time balance monitoring via an integrated web dashboard.

Keywords: Banknote Classification; IoT Piggy Bank; Machine Learning; Stacking Ensemble; TCS34725

1. PENDAHULUAN

Budaya menabung secara mandiri menggunakan celengan konvensional masih menjadi metode pengelolaan keuangan harian yang sangat diminati oleh masyarakat Indonesia [1]. Wadah tabungan konvensional memiliki kelemahan mendasar berupa ketiadaan fitur pencatatan nominal uang masuk, sehingga pengguna tidak dapat memantau akumulasi saldo secara pasti tanpa membongkar celengan tersebut terlebih dahulu. Guna mengatasi masalah pemantauan saldo ini, diperlukan mekanisme pengenalan mata uang yang mengekstraksi ciri spektrum warna dominan sebagai identitas utama setiap pecahan Rupiah saat dimasukkan ke dalam wadah. Variasi kondisi fisik lembaran uang seperti kondisi lusuh, terlipat, serta degradasi warna permukaan menjadi tantangan nyata yang memengaruhi akurasi klasifikasi nominal uang kertas [2]. Keterbatasan wadah konvensional beserta kompleksitas karakteristik spektral uang kertas ini menuntut peralihan menuju pengembangan sistem cerdas yang sanggup mencatat tabungan sekaligus membaca parameter warna secara konsisten dan akurat [3].

Berbagai penelitian telah dilakukan untuk mengembangkan sistem identifikasi nominal uang kertas menggunakan pendekatan berbasis sensor maupun pengolahan citra. Alfari [4] merancang sistem otomasi penyimpanan uang kertas berbasis IoT menggunakan sensor TCS34725 untuk membaca spektrum warna RGB dan temperatur warna dari setiap nominal uang kertas, yang dikombinasikan dengan lampu ultraviolet untuk verifikasi

keaslian. Putra [5] melakukan analisis komparasi performa algoritma *Random Forest* dalam menangani dataset dengan distribusi kelas tidak seimbang dan membuktikan bahwa penerapan teknik *SMOTE* mampu meningkatkan akurasi serta *F1-Score* model berbasis pohon keputusan secara signifikan. Sadewa dan Yamasari [6] mengkaji klasifikasi nominal uang kertas Rupiah menggunakan *deep transfer learning* dan membuktikan efektivitas ekstraksi fitur visual warna dalam membedakan variasi nominal secara akurat. Habsari [7] mengeksplorasi ekstraksi fitur statistik orde pertama dan algoritma *K-Nearest Neighbor (KNN)* untuk mengidentifikasi nominal uang kertas Rupiah dengan akurasi tinggi tanpa membebani komputasi sistem secara berlebihan.

Pada konteks implementasi sistem celengan dan pengelolaan keuangan berbasis *IoT*, beberapa penelitian juga telah memberikan kontribusi dalam pengembangan dan penerapan teknologi tersebut. Komarudin [3] merancang celengan pintar berbasis *IoT* yang memanfaatkan *RFID* untuk autentikasi pengguna dan sensor warna untuk mendeteksi uang kertas dengan notifikasi saldo melalui aplikasi *Telegram* secara *real-time*. Irma [8] membuktikan keandalan sensor spektrum warna *TCS34725* dalam membaca komponen warna *Red*, *Green*, dan *Blue* secara presisi pada purwarupa sistem otomasi berbasis mikrokontroler. Masmur dan Snae [9] memvalidasi keandalan sensor *TCS34725* dalam sistem penyortiran otomatis berbasis mikrokontroler dengan tingkat akurasi 92,3%, yang mengindikasikan bahwa data warna dari sensor tersebut cukup representatif untuk dijadikan masukan sistem cerdas. Berbagai penelitian terdahulu telah membuktikan kelayakan sensor *TCS34725* dan integrasi *IoT* dalam sistem pengelolaan uang, namun pendekatan klasifikasi yang diterapkan umumnya masih mengandalkan model tunggal yang rentan terhadap penurunan akurasi ketika menghadapi variasi data yang kompleks.


Penerapan teknik *ensemble learning* menawarkan pendekatan yang menjanjikan guna mengatasi keterbatasan algoritma tunggal karena mampu menggabungkan kekuatan beberapa model klasifikasi untuk menghasilkan prediksi yang lebih akurat dan stabil. Sudarto dan Kusri [10] membuktikan bahwa teknik *Stacking Ensemble* yang menggabungkan beberapa *base learner* dengan *Logistic Regression* sebagai *meta-learner* mampu mencapai akurasi sebesar 94%. Keunggulan algoritma berbasis pohon juga ditunjukkan oleh Anggraini [11] melalui analisis komparasi performa *Random Forest* dan *XGBoost* yang membuktikan bahwa algoritma *ensemble* berbasis pohon memiliki efektivitas tinggi dalam menangkap pola pada klasifikasi data multikelas. Pada perancangan model bertingkat, Rambe [12] menunjukkan efektivitas arsitektur *Stacking Ensemble* berbasis *XGBoost* dalam meningkatkan stabilitas dan akurasi prediksi. Penanganan data yang tidak seimbang (*imbalanced data*) juga menjadi aspek krusial dalam klasifikasi, sebagaimana dibuktikan oleh Siagian [13] bahwa integrasi teknik *Synthetic Minority Oversampling Technique (SMOTE)* dengan algoritma *XGBoost* berhasil menyeimbangkan batas keputusan kelas dan meningkatkan performa model secara signifikan.

Evaluasi terhadap berbagai penelitian terdahulu mengungkap adanya kesenjangan operasional antara akurasi identifikasi dan efisiensi implementasi perangkat keras fisik. Prototipe celengan berbasis sensor warna yang dikembangkan sebelumnya umumnya masih mengandalkan logika ambang batas (*thresholding*) statis atau algoritma klasifikasi tunggal. Pendekatan tersebut sangat rentan mengalami penurunan akurasi ketika membaca sampel uang kertas yang telah lusuh, terlipat, maupun mengalami pergeseran spektrum warna fisik. Implementasi model *Stacking Ensemble* yang terbukti tangguh pada kajian literatur umumnya juga masih dievaluasi secara terisolasi pada lingkungan komputer berspesifikasi tinggi dan belum diintegrasikan secara nyata dengan mekanisme fisik. Guna mengatasi kelemahan tersebut, integrasi arsitektur *client-server* melalui layanan *REST API* menjadi jembatan yang efektif untuk memisahkan beban komputasi [14]. Melalui pemisahan ini, mikrokontroler dapat difokuskan sebagai node akuisisi data sensor yang hemat daya, sedangkan inferensi model *Stacking Ensemble* dieksekusi di sisi *server* secara cepat, dan terhubung ke *database*.

Penelitian ini mengembangkan sistem celengan cerdas berbasis *IoT* yang mengintegrasikan mikrokontroler *ESP32* dan sensor warna *TCS34725* dengan *server REST API* berbasis *framework Flask* untuk melakukan klasifikasi tujuh nominal uang kertas Rupiah secara *real-time*. Pendekatan yang diusulkan menggunakan arsitektur *Stacking Ensemble* berbasis *Tree-Algorithms* dengan *Random Forest*, *XGBoost*, *CatBoost*, dan *Gradient Boosting* sebagai *base estimators*, serta *Random Forest Classifier* sebagai *meta-estimator*. Sistem menerapkan ekstraksi 21 fitur warna, pembersihan *noise* menggunakan *Edited Nearest Neighbours (ENN)*, penstandaran fitur dengan *StandardScaler*, dan penyeimbangan data latih menggunakan *Synthetic Minority Oversampling Technique (SMOTE)* guna meningkatkan kemampuan diskriminasi karakteristik spektral uang kertas. Berbeda dari penelitian terdahulu yang cenderung mengevaluasi model secara terpisah dari perangkat fisik, penelitian ini mengintegrasikan model klasifikasi dengan celengan *IoT* melalui arsitektur *client-server*, sehingga *ESP32* difungsikan sebagai *node* akuisisi data sensor, sedangkan proses inferensi dilakukan pada sisi *server*. Kinerja pendekatan dievaluasi melalui performa klasifikasi pada data uji independen serta pengujian langsung pada perangkat celengan menggunakan uang kertas Rupiah asli dengan kondisi fisik yang beragam. Sistem juga diintegrasikan dengan *database MySQL* dan *dashboard web* untuk mendukung pencatatan transaksi dan pemantauan saldo secara *real-time*. Penelitian ini diharapkan menghasilkan sistem klasifikasi nominal uang yang akurat dan dapat diimplementasikan pada perangkat *IoT*, sekaligus memberikan kajian mengenai penerapan *Stacking Ensemble* berbasis *tree algorithms* pada sistem celengan cerdas.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif berbasis eksperimen rekayasa sistem (*engineering-based experimental research*) untuk mengembangkan sistem celengan cerdas berbasis *Internet of Things (IoT)* yang mampu mengklasifikasikan nominal mata uang kertas Rupiah secara *real-time* berbasis sensor warna *TCS34725* [11]. Metodologi penelitian dirancang secara sistematis dengan mengadopsi arsitektur *Stacking Ensemble* berbasis pohon keputusan (*Tree-Algorithms*) yang mengombinasikan algoritma *Random Forest*, *XGBoost*, *CatBoost*, dan *Gradient Boosting* sebagai model dasar, serta *Random Forest Classifier* sebagai model meta guna meningkatkan akurasi dan ketahanan klasifikasi terhadap variasi spektrum warna uang kertas [14]. Alur eksperimen mencakup proses akuisisi data spektral *RGB*, ekstraksi 21 fitur warna diskriminatif, pembersihan *noise* sensor berbasis *Edited Nearest Neighbours (ENN)*, penstandaran skala, penyeimbangan sampel menggunakan *SMOTE* pada data latih, pelatihan model ensemble, hingga integrasi sistem ke perangkat mikrokontroler *ESP32* [15]. Tahapan penelitian secara umum ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1 Pengumpulan Data

Pengumpulan data dilakukan secara langsung melalui pembacaan celengan *IoT* untuk merekam pantulan spektrum warna dari tujuh pecahan nominal uang kertas Rupiah emisi tahun 2016 dan 2022, yang meliputi Rp1.000, Rp2.000, Rp5.000, Rp10.000, Rp20.000, Rp50.000, dan Rp100.000. Proses akuisisi data dilaksanakan di dalam ruangan tertutup pada malam hari, yaitu antara pukul 19.00 hingga 23.00 WIB, guna menjaga kestabilan intensitas cahaya sekitar serta menghindari fluktuasi bias dari sinar matahari langsung. Selama proses pengukuran, pembacaan spektrum warna mengandalkan pencahayaan aktif dari lampu *LED* terintegrasi pada sensor *TCS34725* di dalam ruang pemindaian celengan yang tertutup, sehingga pantulan warna yang direkam tetap konsisten dan terbebas dari gangguan interferensi pencahayaan luar.

2.1.1 Konfigurasi Perangkat Keras dan Parameter Sistem Celengan *IoT*

Akuisisi data warna dilaksanakan langsung pada sistem celengan *IoT* berbasis mikrokontroler *ESP32 WROOM-32* berkecepatan tinggi [16]. Pembacaan spektrum warna *Red*, *Green*, *Blue*, dan *Clear* dilakukan oleh sensor *TCS34725* dengan *LED* internal yang dipicu otomatis oleh sensor inframerah saat uang dimasukkan guna mencegah pembacaan berulang. Sistem ini dilengkapi keamanan *RFID* dan *solenoid valve lock* berbasis *relay*, serta layar *LCD I2C* untuk menampilkan nominal uang dan total saldo tabungan secara *real-time*. Parameter teknis seluruh komponen disajikan pada Tabel 1.

Tabel 1. Spesifikasi Perangkat Keras

Komponen Perangkat Keras	Spesifikasi / Parameter	Fungsi Operasional pada Celengan <i>IoT</i>
Mikrokontroler	<i>ESP32-WROOM-32</i> (3,3V)	Pengirim data sensor dan penerima hasil klasifikasi via <i>REST API</i>
Power Supply	Modul Power Supply 5V	Menyertakan daya teregulasi stabil untuk seluruh komponen
Sensor Warna	<i>TCS34725</i> dengan <i>LED</i> Terintegrasi	Akuisisi komponen warna <i>Red</i> , <i>Green</i> , dan <i>Blue</i>
Sensor Inframerah (IR)	Modul <i>IR Obstacle / Proximity Sensor</i>	Pemicu pembacaan tunggal otomatis (mencegah <i>double read</i>)
Sensor Keamanan	Modul <i>RFID</i> (13,56 MHz)	Autentikasi identitas dan hak akses pintu celengan <i>IoT</i>
Aktuator Pengunci	<i>Solenoid Valve Lock & Modul Relay</i>	Mekanisme pengunci pintu celengan berbasis kontrol <i>relay</i>
Layar Tampilan	Layar <i>LCD I2C</i> (16×2)	Menampilkan pecahan uang terbaca dan total saldo tabungan

2.1.2 Skema Sampling dan Pembentukan Dataset Mentah

Pengambilan sampel data mencakup 70 lembar uang kertas fisik emisi tahun 2016 dan 2022 dengan sebaran merata pada tujuh pecahan nominal Rupiah (Rp1.000 hingga Rp100.000). Setiap pecahan nominal terdiri atas 10 lembar uang yang mencakup variasi kondisi fisik baru, sedang, dan lusuh. Pembacaan spektrum warna dilakukan berulang kali pada berbagai posisi dan orientasi lembaran menggunakan sensor *TCS34725* untuk merekam komponen *Red*, *Green*, dan *Blue* di dalam ruang tertutup celengan. Proses akuisisi data ini menghasilkan total 1.361 baris data mentah yang disimpan dalam format berkas CSV. Rincian distribusi sampel per nominal, sebaran kondisi fisik uang, serta batas rentang nilai spektrum warna mentah (*Min-Max*) disajikan secara lengkap pada Tabel 2.

Tabel 2. Rincian Distribusi Sampel Pengumpulan Dataset

Pecahan Nominal (Rupiah)	Warna Dominan Uang	Kondisi Fisik Uang	Rentang Nilai Red	Rentang Nilai Green	Rentang Nilai Blue	Jumlah Baris Sampel
Rp1.000	Hijau Abu-abu	Baru, Sedang, Lusuh	146 – 1.074	134 – 1.101	106 – 655	180
Rp2.000	Abu-abu Perak	Baru, Sedang, Lusuh	32 – 381	23 – 366	11 – 324	147
Rp5.000	Cokelat Muda	Baru, Sedang, Lusuh	38 – 1.285	32 – 1.117	20 – 624	234
Rp10.000	Ungu	Baru, Sedang, Lusuh	90 – 1.201	74 – 1.301	51 – 903	184
Rp20.000	Hijau Muda	Baru, Sedang, Lusuh	104 – 1.218	115 – 1.649	70 – 902	260
Rp50.000	Biru Laut	Baru, Sedang, Lusuh	62 – 454	58 – 441	41 – 398	177
Rp100.000	Merah Cerah	Baru, Sedang, Lusuh	84 – 697	63 – 631	38 – 569	179

2.2 Rekayasa Fitur

Rekayasa fitur (*feature engineering*) dilakukan untuk mengekstraksi informasi spektral turunan dari komponen warna mentah *Red*, *Green*, dan *Blue* guna meningkatkan daya pembeda (*discriminative power*) antar pecahan nominal uang kertas. Pembentukan fitur masukan ($X \in \mathbb{R}^{21}$) ini bertujuan untuk menormalisasi variasi intensitas pencahayaan, mempertegas karakteristik kromatisitas, menangani sifat siklik warna, serta mengekstraksi kontras lawan warna (*color opponency*). Dua puluh satu fitur masukan yang dirumuskan mencakup:

1. Komponen Warna Mentah
Tiga nilai intensitas spektrum warna dasar *Red*, *Green*, dan *Blue* diperoleh langsung dari pembacaan fotodiode sensor *TCS34725*.
2. Rasio Warna Relatif
Proporsi masing-masing komponen warna *R_ratio*, *G_ratio*, dan *B_ratio* terhadap akumulasi total intensitas spektral dihitung melalui persamaan:

$$R_ratio = \frac{Red}{Red+Green+Blue+\epsilon} \quad (1)$$

$$G_ratio = \frac{Green}{Red+Green+Blue+\epsilon} \quad (2)$$

$$B_ratio = \frac{Blue}{Red+Green+Blue+\epsilon} \quad (3)$$

Formulasi rasio ini berfungsi mengeliminasi pengaruh fluktuasi kecerahan absolut sehingga model tetap fokus pada komposisi kromatisitas relatif warna uang. Simbol ϵ merepresentasikan konstanta bernilai kecil (10^{-7}) untuk mencegah pembagian dengan nol (*zero-division guard*).

3. Total Intensitas dan Kontras RGB
Jumlah keseluruhan intensitas spektral (*Intensity*) serta selisih nilai tertinggi dan terendah (*Contrast*) untuk mengukur sebaran saturasi dinamis dirumuskan sebagai:

$$Intensity = Red + Green + Blue + \epsilon \quad (4)$$

$$Contrast = \max(Red, Green, Blue) - \min(Red, Green, Blue) \quad (5)$$

4. Ruang Warna HSV dan Proyeksi Trigonometri Hue
Nilai mentah *Red*, *Green*, dan *Blue* dari sensor dinormalisasi terlebih dahulu ke dalam skala standar $[0, 1]$ (setara rentang 0–255) menggunakan normalisasi *Min-Max*:

$$RGB_{norm} = \frac{RGB_{raw} - \min(RGB_{raw})}{\max(RGB_{raw}) - \min(RGB_{raw}) + \epsilon} \quad (6)$$

Nilai RGB_{norm} dikonversi ke ruang warna HSV untuk mengekstraksi corak warna (*Hue*), tingkat kejenuhan (*Saturation*), dan tingkat kecerahan (*Brightness*). Guna mengatasi diskontinuitas siklik pada sudut lingkaran warna ($0 \approx 2\pi$), nilai *Hue* diproyeksikan ke dalam fungsi trigonometri:

$$Hue_sin = \sin(2\pi \cdot Hue) \quad (7)$$

$$Hue_cos = \cos(2\pi \cdot Hue) \quad (8)$$

5. Selisih Warna Lawan (*Color Opponency*)

Fitur diferensial warna normalisasi dan komponen lawan kuning-biru (*Yellow-Blue opponency*) diekstraksi untuk mempertajam pemisahan antar spektrum warna yang berlawanan:

$$RG_diff = \frac{Red - Green}{Red + Green + \epsilon} \quad (9)$$

$$RB_diff = \frac{Red - Blue}{Red + Blue + \epsilon} \quad (10)$$

$$GB_diff = \frac{Green - Blue}{Green + Blue + \epsilon} \quad (11)$$

$$YB_opp = \frac{Red + Green - 2 \cdot Blue}{Intensity} \quad (12)$$

6. Rasio Logaritmik Sinyal Sensor dan Luminansi

Rasio logaritmik digunakan untuk memodelkan respon sensor terhadap perbandingan sinyal spektral secara non-linear, sedangkan luminansi (*Luminance*) merepresentasikan persepsi kecerahan terbobot:

$$Log_RG = \ln\left(\frac{Red+1}{Green+1}\right) \quad (13)$$

$$Log_RB = \ln\left(\frac{Red+1}{Blue+1}\right) \quad (14)$$

$$Log_GB = \ln\left(\frac{Green+1}{Blue+1}\right) \quad (15)$$

$$Luminance = 0.299 \cdot Red + 0.587 \cdot Green + 0.114 \cdot Blue \quad (16)$$

Kombinasi 21 fitur masukan (tiga fitur mentah dan 18 fitur turunan) tersebut digunakan sebagai matriks variabel bebas (X), sedangkan label pecahan uang kertas (y) ditetapkan sebagai variabel terikat target klasifikasi.

2.3 Pembagian Dataset

Pemisahan dataset dilakukan sebelum seluruh tahapan pembersihan dan pra-pemrosesan data untuk mencegah kebocoran data (*zero data leakage*). Pembagian data menerapkan *Group Split* berbasis ID lembar menjadi 70% data latih (49 lembar), 10% data validasi (7 lembar), dan 20% data uji (14 lembar). Pemisahan berbasis kelompok lembar fisik ini memastikan tidak ada data pembacaan dari lembaran uang yang sama terdistribusi silang ke dalam himpunan data yang berbeda. Data validasi dan data uji diisolasi secara ketat dan dibiarkan dalam kondisi alami tanpa mengalami proses pembersihan *noise* ataupun penambahan data sintetis.

2.4 Pembersihan Data

Fluktuasi pantulan optik dan kondisi fisik uang kertas menimbulkan *noise* serta *outliers* pada pembacaan sensor TCS34725. Pembersihan *noise* sensor dengan menerapkan algoritma *Edited Nearest Neighbours (ENN)* secara eksklusif pada partisi data latih yang telah melalui standardisasi. Algoritma *ENN* menggunakan parameter $k=5$ dan $kind_sel='mode'$ untuk mengeliminasi sampel *noise* yang memiliki ketidaksesuaian label mayoritas terhadap tetangga terdekatnya. Penerapan *ENN* khusus pada data latih ini mengeliminasi 374 sampel *noise* tanpa menyentuh data validasi maupun data uji, sehingga integritas evaluasi performa model terhadap data asli tetap terjaga utuh.

2.5 Pra-Pemrosesan Data

Tahapan pra-pemrosesan data diterapkan guna memastikan kesiapan numerik dan keseimbangan sampel sebelum pemodelan *machine learning* [17]. Modul *LabelEncoder* mengonversi label nominal uang menjadi indeks numerik terurut $y \in \{0, 1, 2, 3, 4, 5, 6\}$. Transformasi *StandardScaler* menghitung rata-rata (μ) dan varians (σ^2) hanya dari data latih, kemudian parameter skala tersebut digunakan untuk mentransformasi data validasi dan data uji untuk mencegah kebocoran informasi skala (*scale leakage*). Penyeimbangan kelas menerapkan metode *SMOTE* dengan konfigurasi $k_neighbors=4$ dan $random_state=42$ pada data latih. Proses *SMOTE* dienkapsulasi di dalam *pipeline* pada setiap iterasi *Stratified Group 3-Fold Cross-Validation*, sehingga pembentukan sampel sintetis terbatas hanya pada lipatan latih (*training folds*) dan tidak menimbulkan keterkaitan data sintetis dengan lipatan validasi (*validation fold*).

2.6 Pelatihan Model Dasar

Tahap pemodelan tingkat dasar (*Level 0*) mengombinasikan empat algoritma berbasis pohon keputusan, yaitu *Random Forest*, *XGBoost*, *CatBoost*, dan *Gradient Boosting*, untuk menghasilkan probabilitas prediksi awal secara mandiri [10]. Kombinasi keempat model dasar ini memanfaatkan keunggulan teknik *bagging* dan *boosting* guna saling melengkapi dalam mengidentifikasi pola spektral uang kertas [18]:

1. *Random Forest*

Struktur *bagging* pada *Random Forest* berfungsi mereduksi variansi data dan menjaga stabilitas prediksi saat menghadapi keusangan fisik serta lipatan kertas uang. Model ini bekerja efektif dalam memetakan nilai absolut warna mentah, total intensitas, dan luminansi. Parameter model mencakup $n_estimators=200$, $max_depth=10$, $min_samples_split=6$, $min_samples_leaf=2$, $max_features='sqrt'$, dan $random_state=42$.

2. *XGBoost*

Mekanisme *boosting* sekuensial pada *XGBoost* berfungsi meminimalkan bias prediksi serta mempertegas batas pemisah (decision boundary) antar pecahan yang memiliki corak pigmen berdekatan. Algoritma ini memfokuskan koreksi kesalahan residual pada fitur kontras, rasio warna relatif, dan diferensial warna lawan (*color opponency*). Konfigurasi model meliputi $n_estimators=200$, $max_depth=4$, $learning_rate=0.03$, $subsample=0.75$, $colsample_bytree=0.75$, $regularisasi\ reg_alpha=0.3$, $reg_lambda=2.0$, dan $random_state=42$.

3. *CatBoost*

Arsitektur pohon simetris (*oblivious trees*) pada *CatBoost* berfungsi mencegah *overfitting* dan menjaga ketahanan model terhadap fluktuasi *noise* pembacaan fotodioda sensor. Struktur pohon seimbang ini meminimalkan pergeseran target (*target leakage*) saat memproses data proyeksi trigonometri *Hue*. Konfigurasi model menetapkan $iterations=200$, $depth=4$, $learning_rate=0.025$, $l2_leaf_reg=8$, $subsample=0.75$ (*bootstrap Bernoulli*), dan $random_seed=42$.

4. *Gradient Boosting*

Model *Gradient Boosting Classifier* berfungsi mengoptimalkan fungsi kerugian (*loss function*) secara bertahap guna menangkap pola interaksi non-linear pada fitur rasio logaritmik sensor. Model ini memperkaya keragaman sudut pandang prediksi antar model dasar sebelum diteruskan ke tingkat meta. Konfigurasi model menerapkan $n_estimators=150$, $max_depth=3$, $learning_rate=0.03$, $subsample=0.75$, dan $random_state=42$.

2.7 Pelatihan Model Meta

Tahap pemodelan meta (*Level 1*) menyatukan luaran probabilitas prediksi dari empat model dasar menggunakan modul *StackingClassifier* dari pustaka *scikit-learn* [18]. Model meta (*final estimator*) tidak memproses 21 fitur spektrum secara langsung, melainkan mempelajari matriks probabilitas prediksi (*meta-features*) yang dihasilkan oleh *Random Forest*, *XGBoost*, *CatBoost*, dan *Gradient Boosting* [10]. Algoritma *Random Forest Classifier* ditetapkan sebagai model meta dengan konfigurasi $n_estimators=100$, $max_depth=5$, dan $random_state=42$ guna menyeimbangkan bobot prediksi serta mengoreksi bias individual dari keempat model dasar.

Skema validasi silang internal 3-lipat ($cv=3$) diterapkan selama pembentukan matriks fitur meta guna mencegah kebocoran data (*data leakage*). Mekanisme *out-of-fold* ini memastikan setiap model dasar menghasilkan estimasi prediksi terhadap sampel yang tidak dilibatkan dalam pelatihan lipatan terkait. Matriks probabilitas independen tersebut menjadi data masukan baru bagi model meta untuk mengenali pola konsensus prediksi secara objektif, sehingga arsitektur *Stacking Ensemble* terhindar dari risiko *overfitting* dan memiliki daya generalisasi yang kokoh.

2.8 Evaluasi

Tahap evaluasi dilakukan untuk mengukur performa kuantitatif dan daya generalisasi model *Stacking Ensemble* yang telah dilatih terhadap subset data uji independen X_{test} . Sebelum perhitungan metrik dilakukan, nilai prediksi angka y_{pred} dan target data uji y_{test} dikonversi kembali ke nilai nominal mata uang Rupiah asli melalui fungsi *label_encoder.inverse_transform*. Pengukuran kinerja model klasifikasi dihitung berdasarkan dua indikator evaluasi utama:

1. Akurasi

Metrik *accuracy_score* digunakan untuk mengukur persentase total prediksi pecahan nominal uang kertas yang berhasil diklasifikasikan secara tepat terhadap seluruh data uji. Formulasi akurasi dirumuskan melalui persamaan:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (17)$$

Keterangan:

TP = *True Positive* (jumlah prediksi benar pada kelas nominal target);

TN = *True Negative* (jumlah prediksi benar di luar kelas nominal target);

FP = *False Positive* (jumlah prediksi salah yang terdeteksi sebagai kelas nominal target);

FN = *False Negative* (jumlah prediksi salah dari kelas target yang terdeteksi sebagai nominal lain).

2. Laporan Klasifikasi

Pengujian kinerja per kelas nominal diukur menggunakan modul *classification_report* yang mengevaluasi nilai *Precision*, *Recall*, dan *F1-Score* untuk masing-masing pecahan uang kertas Rp1.000 hingga Rp100.000. Persamaan matematis dari ketiga metrik tersebut meliputi:

$$Precision = \frac{TP}{TP+FP} \quad (18)$$

$$Recall = \frac{TP}{TP+FN} \quad (19)$$

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (20)$$

Melalui pengujian metrik ini, keandalan model *Stacking Ensemble* dalam membedakan spektrum warna antar pecahan nominal mata uang Rupiah dianalisis secara objektif sebelum diimplementasikan pada perangkat keras celengan *IoT*.

2.9 Integrasi Sistem *IoT*

Tahap akhir penelitian berfokus pada integrasi sistem *real-time* celengan *IoT* dengan *web server* menggunakan *REST API* berbasis *framework Flask* dan *database MySQL*. Model *Stacking Ensemble* yang sudah dilatih beserta objek pemeta *StandardScaler* dan *LabelEncoder* diserialisasikan menggunakan *library joblib* untuk dimuat ke dalam *server*. Keberadaan fisik lembaran uang yang masuk dideteksi oleh sensor inframerah untuk memicu pembacaan warna dari sensor *TCS34725* secara otomatis sebanyak satu kali. Nilai spektrum warna *RGB* dikirimkan oleh mikrokontroler *ESP32* melalui *endpoint HTTP POST* menuju *server* untuk dihitung 18 fitur turunannya (membentuk total 21 fitur masukan), ditransformasikan skalanya menggunakan *StandardScaler*, dan diklasifikasikan nominalnya secara *real-time*. Hasil prediksi disimpan secara otomatis ke dalam *database* untuk menghitung akumulasi total saldo tabungan. *Server* mengirimkan balasan *JSON* berstatus *HTTP 200* berisi nilai nominal dan total saldo menuju *ESP32* untuk ditampilkan pada layar *LCD I2C*, sedangkan akses pintu celengan dikendalikan oleh modul *RFID* dan pengunci *solenoid valve* berbasis *relay*.


3. HASIL DAN PEMBAHASAN

3.1 Analisis Karakteristik Data Spektral dan Rekayasa Fitur

Tahap awal analisis hasil eksperimen berfokus pada pengujian karakteristik fisik sebaran spektrum warna mentah serta efektivitas penerapan rekayasa fitur turunan dan penyeimbangan data berbasis *SMOTE*. Konsep purwarupa celengan cerdas berbasis *IoT* ini memanfaatkan pembacaan sensor warna untuk mengakuisisi spektrum warna *Red*, *Green*, dan *Blue* dari 1.361 baris sampel uang kertas Rupiah [2].

3.1.1 Analisis Sebaran Karakteristik Spektral Uang Kertas Rupiah

Pengukuran nilai intensitas warna mentah dipengaruhi oleh tingkat reflektansi permukaan kertas uang serta variasi jarak pantul di dalam celengan *IoT*. Langkah reduksi sensitivitas terhadap fluktuasi pencahayaan eksternal menerapkan ekstraksi 21 fitur masukan ($X \in \mathbb{R}^{21}$) yang mencakup rasio warna relatif, total intensitas, kontras *RGB*, ruang warna *HSV*, proyeksi trigonometri *Hue*, diferensial warna lawan (*color opponency*), rasio logaritmik sensor, dan luminansi. Karakteristik sebaran data spektral antar tujuh pecahan nominal uang kertas Rupiah disajikan pada Gambar 2.




Gambar 2. Distribusi Total Intensitas dan Kontras *RGB* per Nominal Uang Kertas Rupiah

Visualisasi *boxplot* pada Gambar 2 menunjukkan bahwa total intensitas spektral ($Intensity = Red + Green + Blue$) memiliki rentang variasi yang dinamis pada setiap pecahan nominal. Pecahan Rp20.000, Rp5.000, dan Rp1.000 menghasilkan rentang sebaran serta titik pencilan intensitas tertinggi hingga melampaui nilai 3.500 akibat tingginya reflektansi optik pada serat kertas tertentu. Pecahan Rp50.000 dan Rp2.000 mencatatkan median total intensitas yang lebih rendah dan stabil pada rentang nilai 500–650 akibat tingginya penyerapan spektrum cahaya oleh karakteristik pigmen permukaan kertas uang [19]. Fitur kontras *RGB* ($Contrast = \max(RGB) - \min(RGB)$) memberikan daya pembeda (*discriminative power*) yang kuat dalam

mengelompokkan karakteristik pigmen warna uang. Pecahan Rp20.000 dan Rp5.000 memperlihatkan rentang interkuartil kontras tertinggi karena memiliki selisih nilai yang lebar antara komponen warna dominan (hijau dan coklat) terhadap komponen warna lainnya. Pecahan Rp2.000 (abu-abu) dan Rp50.000 memperlihatkan kotak distribusi kontras yang sangat pipih di bawah nilai 50 akibat nilai intensitas ketiga komponen dasar *Red*, *Green*, dan *Blue* yang relatif seimbang. Integrasi fitur rasio warna, ruang warna *HSV*, serta diferensial lawan warna terbukti efektif mengeliminasi pengaruh fluktuasi kecerahan absolut dan mempertegas corak warna murni dari setiap pecahan uang kertas.

3.1.2 Analisis Hasil Penyeimbangan Sampel Sintetis SMOTE

Pembagian dataset menerapkan *Group Split* berbasis ID lembar fisik menjadi 70% data latih (49 lembar), 10% data validasi (7 lembar), dan 20% data uji (14 lembar). Penyaringan *Edited Nearest Neighbours (ENN)* mengeliminasi 374 sampel *noise* sensor (27,5%), meliputi pecahan Rp10.000 (80 sampel), Rp20.000 (72 sampel), Rp100.000 (63 sampel), Rp50.000 (58 sampel), Rp1.000 (54 sampel), Rp5.000 (47 sampel), dan Rp2.000 (0 sampel). Eliminasi *noise* terdistribusi merata pada kondisi baru (28,0%), sedang (27,3%), dan lusuh (27,2%), dengan 391 sampel uang lusuh (72,8%) tetap tersimpan secara valid dalam dataset. Distribusi 682 data latih bersih menempatkan pecahan Rp20.000 sebagai kelas mayoritas (134 baris) dan Rp10.000 sebagai kelas minoritas (72 baris). Algoritma *SMOTE* menyintesis sampel kelas minoritas hingga seluruh nominal seimbang pada angka 134 baris per kelas (total 938 data latih) [14], sebagaimana disajikan pada Gambar 3.



Gambar 3. Perbandingan Distribusi Sampel Kelas Sebelum dan Sesudah *SMOTE*


Gambar 3 menunjukkan penambahan sampel sintetis *SMOTE* yang menyamakan seluruh pecahan pada angka 134 baris, menghasilkan total 938 data latih. Penambahan ini mencegah algoritma *ensemble* terbias pada pecahan mayoritas (Rp20.000) sekaligus memperjelas batas pemisah antarkelas. Penerapan proses sintesis yang dibatasi khusus pada data latih memastikan keaslian 202 sampel data uji tetap terjaga untuk evaluasi akhir model.

3.2 Evaluasi Model

Tahap evaluasi model berfokus pada pengujian kuantitatif performa klasifikasi nominal uang kertas Rupiah menggunakan arsitektur *Stacking Ensemble* yang mengombinasikan empat algoritma model dasar (*Random Forest*, *XGBoost*, *CatBoost*, dan *Gradient Boosting*) pada *Level 0* serta *Random Forest Classifier* sebagai pemodel meta pada *Level 1* [18]. Pengujian performa dilaksanakan terhadap subset 202 sampel data uji murni yang telah diisolasi secara ketat dari seluruh proses pelatihan dan penyeimbangan data.

3.2.1 Analisis Tingkat Kepentingan Fitur (*Feature Importance*)

Evaluasi kontribusi masing-masing dari 21 fitur masukan ($X \in \mathbb{R}^{21}$) bertujuan untuk memetakan peranan fitur warna mentah dan fitur turunan dalam proses percabangan pohon keputusan. Pemeringkatan sepuluh fitur paling berpengaruh (*feature importance*) dari model dasar *Random Forest*, *XGBoost*, *CatBoost*, dan *Gradient Boosting* disajikan pada Gambar 4.



Gambar 4. Pemeringkatan Tingkat Kepentingan Fitur pada Model Dasar

Visualisasi *feature importance* pada Gambar 4 menunjukkan bahwa fitur turunan hasil rekayasa mendominasi simpul keputusan utama secara konsisten di ketiga algoritma. Fitur rasio logaritmik sensor (*Log_RG*) dan diferensial warna lawan (*RG_diff*) menempati peringkat teratas pada model *Random Forest* (skor 0,088 dan 0,085) serta model *CatBoost* (skor 16,7 dan 12,8). Model *XGBoost* menempatkan proyeksi kosinus corak warna (*Hue_cos*) sebagai kontributor utama dengan nilai kepentingan tertinggi sebesar 0,123, disusul oleh fitur *Log_RG* sebesar 0,115. Kelompok fitur turunan lain seperti *Hue*, *Hue_sin*, *G_ratio*, dan *Log_GB* turut memberikan kontribusi konsisten pada jajaran sepuluh besar pemisah kelas. Komponen warna mentah sensor (*Green*, *Blue*) serta total intensitas (*Intensity*) tergeser ke urutan terbawah dan tidak mendominasi pembentukan percabangan keputusan. Bukti empiris ini mengonfirmasi bahwa penambahan fitur warna lawan, transformasi logaritmik, dan proyeksi trigonometri *Hue* berhasil memberikan perolehan informasi (*information gain*) yang lebih tinggi serta kebal terhadap fluktuasi intensitas cahaya dibandingkan sekadar mengandalkan data mentah sensor.

Pengujian ablasi dilakukan untuk membuktikan pengaruh langsung rekayasa fitur terhadap akurasi klasifikasi dengan membandingkan 3 fitur *RGB* mentah melawan 21 fitur spektrum warna pada data uji yang sama. Tabel 3 merangkum perbandingan performa kedua konfigurasi fitur tersebut.


Tabel 3. Perbandingan Akurasi Model pada Pengujian Ablasi Fitur

Model Klasifikasi	3 Fitur RGB Mentah	21 Fitur Spektrum Rekayasa	Peningkatan Akurasi (Δ)
<i>Random Forest</i>	59,41%	92,08%	32,67%
<i>XGBoost</i>	53,47%	91,58%	38,12%
<i>CatBoost</i>	48,02%	88,61%	40,59%
<i>Gradient Boosting</i>	59,41%	90,10%	30,69%
<i>Stacking Ensemble</i>	58,91%	93,07%	34,16%

Model yang hanya memanfaatkan 3 fitur *RGB* dasar mencatatkan akurasi rendah pada rentang 48,02% hingga 59,41%, dengan capaian *Stacking Ensemble* sebesar 58,91%. Nilai intensitas *RGB* mentah rentan terganggu oleh perubahan jarak baca dan pantulan cahaya sensor. Penerapan 21 fitur hasil rekayasa warna menaikkan performa seluruh model secara substansial di atas 30%. Akurasi *Random Forest* meningkat menjadi 92,08% (+32,67%), *XGBoost* menjadi 91,58% (+38,12%), *CatBoost* menjadi 88,61% (+40,59%), *Gradient Boosting* menjadi 90,10% (+30,69%), serta *Stacking Ensemble* meraih akurasi tertinggi sebesar 93,07% (+34,16%). Hasil empiris ini membuktikan bahwa ekstraksi 21 fitur memberikan kontribusi nyata dalam meningkatkan akurasi sistem pengenalan uang kertas, bukan sekadar memperbanyak dimensi data.

3.2.2 Perbandingan Performa Model Dasar (*Base Learners*) dan *Stacking Ensemble*

Pengujian komparatif mengukur efektivitas arsitektur *Stacking Ensemble* terhadap empat model dasar penyusunnya pada 202 sampel data uji murni dari 14 lembar fisik independen. Arsitektur *Stacking Ensemble* memperoleh akurasi sebesar 93,07% dan nilai *weighted average F1-score* sebesar 0,93. Capaian numerik ini bersaing ketat dan relatif setara dengan performa model tunggal *Random Forest* (92,08%), *XGBoost* (91,58%), *Gradient Boosting* (90,10%), dan *CatBoost* (88,61%). Selisih akurasi sebesar 0,99% di atas *Random Forest* menunjukkan bahwa *Stacking Ensemble* tidak memberikan lonjakan performa drastis. Manfaat utama integrasi *meta-learner Random Forest Classifier* terletak pada stabilisasi estimasi probabilitas konsensus serta peredaman variansi prediksi individual antarmodel dasar melalui kombinasi teknik *bagging* dan *boosting* [20].




Gambar 5. Kurva Konvergensi *Multi-class Log-Loss* dan Akurasi Model per Iterasi

Evaluasi stabilitas pelatihan dan potensi *overfitting* dipantau melalui kurva pembelajaran sepanjang 200 iterasi pada Gambar 5. Proses pemantauan konvergensi ini memanfaatkan himpunan data validasi terpisah (7 lembar fisik/103 sampel), menjaga keaslian data uji murni yang hanya dievaluasi satu kali pada tahap akhir. Kurva *multi-class log-loss* menunjukkan nilai kehilangan data latih (*Train Loss*) menurun bertahap dari 1,88 hingga mencapai 0,13, sementara nilai kehilangan data validasi (*Val Loss*) melandai secara konsisten dari 1,89 hingga 0,37 tanpa mengalami pemisahan lonjakan (*loss divergence*). Ketiadaan kenaikan nilai *loss* pada data

validasi independen ini mengonfirmasi keberhasilan konfigurasi parameter regularisasi dalam mengontrol kompleksitas model secara optimal [13]. Kurva akurasi memperlihatkan konvergensi yang stabil, dengan capaian akurasi data validasi terkunci pada kisaran 89,32% sejak iterasi ke-185 hingga ke-200. Karakteristik kedua kurva yang melandai rapat membuktikan bahwa penetapan 200 estimator telah mencapai titik optimal dalam meminimalkan galat residual tanpa memicu kejenuhan model [21].

3.2.3 Analisis Confusion Matrix dan Laporan Klasifikasi Stacking Ensemble

Evaluasi ketepatan dan pola pembiasan klasifikasi antarpecahan nominal dianalisis secara visual menggunakan matriks kebingungan (*confusion matrix*) pada 202 data uji murni dari 14 lembar fisik independen. Sebaran hasil prediksi tepat (*True Positive*) dan kesalahan klasifikasi (*misclassification*) disajikan pada Gambar 6.



Gambar 6. Heatmap Confusion Matrix Klasifikasi Stacking Ensemble pada Data Uji

Matriks pada Gambar 6 menunjukkan dominasi kuat pada diagonal utama dengan total 188 prediksi tepat dari 202 sampel data uji murni, menghasilkan akurasi keseluruhan sebesar 93,07%. Pecahan Rp5.000 mencatatkan 38 prediksi tepat dari 39 sampel, disusul Rp20.000 (33 dari 35 sampel), Rp2.000 (27 dari 29 sampel), Rp100.000 (25 dari 29 sampel), Rp50.000 (24 dari 25 sampel), serta Rp1.000 (23 dari 24 sampel). Pecahan Rp10.000 membukukan 18 prediksi tepat dari 21 sampel, dengan 3 sampel terkeliru sebagai pecahan Rp2.000 akibat pergeseran saturasi warna ungu pada kondisi fisik uang lusuh [17]. Kekeliruan minor ini hanya terjadi pada 14 dari total 202 sampel, membuktikan stabilitas arsitektur *Stacking Ensemble* dalam mengenali ciri spektral ketujuh pecahan uang kertas Rupiah secara konsisten [7].

Laporan klasifikasi rinci pada Tabel 4 memetakan metrik *precision*, *recall*, dan *F1-score* khusus untuk model *Stacking Ensemble* guna mengevaluasi kinerja model pada setiap kelas nominal secara mendalam.

Tabel 4. Laporan Metrik Klasifikasi Model *Stacking Ensemble* pada Data Uji Murni

Pecahan Nominal	Precision	Recall	F1-Score
Rp1.000	0,88	0,96	0,92
Rp2.000	0,82	0,93	0,87
Rp5.000	1,00	0,97	0,99
Rp10.000	0,86	0,86	0,86
Rp20.000	0,97	0,94	0,96
Rp50.000	1,00	0,96	0,98
Rp100.000	0,96	0,86	0,91
Rata-rata Makro	0,93	0,93	0,93
Rata-rata Terbobot	0,93	0,93	0,93
Akurasi Keseluruhan	-	-	93,07%

Data pada Tabel 4 memperlihatkan keandalan klasifikasi yang merata di seluruh kategori nominal. Pecahan Rp5.000 dan Rp50.000 meraih nilai *precision* sempurna sebesar 1,00 tanpa menghasilkan satupun prediksi positif palsu (*False Positive*). Pecahan Rp10.000 yang memiliki irisan spektrum paling kompleks tetap mempertahankan performa stabil dengan nilai *precision*, *recall*, dan *F1-score* seimbang di angka 0,86. Perhitungan *Macro-F1* arsitektur ini membukukan skor 0,93, identik dengan nilai *Weighted-F1* sebesar 0,93. Kesetaraan kedua metrik rata-rata tersebut membuktikan bahwa performa tinggi model tersebar merata dan tidak dimanipulasi oleh besarnya proporsi kelas mayoritas, sekaligus memastikan kelas-kelas minoritas tetap terprediksi secara akurat.

3.3 Implementasi Perangkat Keras Celengan IoT

Tahap akhir penelitian berfokus pada pengujian fisik integrasi perangkat keras celengan *IoT* dalam mengklasifikasikan lembaran uang kertas Rupiah asli secara langsung, penyajian arsitektur komunikasi layanan

web server REST API berbasis framework Flask, serta pemantauan data transaksi tabungan secara *real-time* melalui Dashboard Web [15].

3.3.1 Implementasi dan Pengujian Pembacaan Uang Kertas Asli

Bentuk fisik prototipe celengan IoT dibangun secara terintegrasi dengan menyatukan ESP32, sensor warna TCS34725, sensor inframerah sebagai pemicu pembacaan, modul keamanan RFID, solenoid valve lock, modul relay, power supply, dan LCD. Implementasi fisik perangkat celengan IoT ditunjukkan pada Gambar 7.



Gambar 7. Implementasi Fisik Perangkat Celengan Cerdas IoT

Pengujian langsung pada perangkat celengan cerdas IoT dilakukan menggunakan 70 lembar uang kertas Rupiah asli. Uang yang digunakan merupakan lembaran yang berbeda dari uang pada proses pengumpulan dataset, yang terdiri atas 1.361 baris data mentah. Pengujian fisik mencakup seluruh pecahan uang kertas, mulai dari Rp1.000 hingga Rp100.000 dari emisi tahun 2016 dan 2022. Komposisi uang yang digunakan dalam pengujian pada setiap pecahan terdiri atas 3 lembar berkondisi baru, 4 lembar berkondisi sedang, dan 3 lembar berkondisi lusuh, sehingga totalnya mencapai 21 lembar baru, 28 lembar sedang, dan 21 lembar lusuh. Uang kertas dimasukkan ke dalam slot celengan dengan empat variasi orientasi arah hadap muka secara acak. Pengaturan ini bertujuan untuk menguji ketahanan inferensi model *ensemble* secara *real-time* terhadap variasi tahun emisi dan tingkat keausan fisik uang. Hasil keterbacaan perangkat terhadap seluruh uang yang diuji disajikan pada Tabel 5.

Tabel 5. Hasil Pengujian Pembacaan Uang Kertas Rupiah Asli pada Perangkat Celengan IoT


Pecahan Nominal Uang Kertas	Jumlah Pengujian Lembar Uang	Jumlah Prediksi Tepat	Jumlah Prediksi Salah	Tingkat Keberhasilan Pembacaan <i>Real-Time</i> (%)
Rp1.000	10 Lembar	9 Lembar	1 Lembar	90,0%
Rp2.000	10 Lembar	9 Lembar	1 Lembar	90,0%
Rp5.000	10 Lembar	9 Lembar	1 Lembar	90,0%
Rp10.000	10 Lembar	8 Lembar	2 Lembar	80,0%
Rp20.000	10 Lembar	9 Lembar	1 Lembar	90,0%
Rp50.000	10 Lembar	8 Lembar	2 Lembar	80,0%
Rp100.000	10 Lembar	9 Lembar	1 Lembar	90,0%
Total/rata-rata	70 Lembar	61 Lembar	9 Lembar	87,1%

Pengujian langsung pada perangkat celengan IoT menghasilkan tingkat keberhasilan pembacaan sebesar 87,1%, dengan 61 dari 70 lembar uang berhasil diidentifikasi secara tepat, sebagaimana disajikan pada Tabel 5. Hasil ini lebih rendah dibandingkan dengan akurasi model pada pengujian *offline* sebesar 93,07%. Perbedaan tersebut diduga dipengaruhi oleh variasi karakteristik spektral antara uang emisi tahun 2016 dan 2022, sudut luncur uang saat melewati perangkat, serta penurunan reflektansi optik pada lembaran berkondisi lusuh [4]. Berdasarkan pecahannya, uang Rp1.000, Rp2.000, Rp5.000, Rp20.000, dan Rp100.000 mencapai tingkat keberhasilan pembacaan sebesar 90,0%, dengan 9 dari 10 lembar berhasil diidentifikasi secara tepat. Pecahan Rp10.000 dan Rp50.000 memperoleh tingkat keberhasilan sebesar 80,0%. Penurunan pada kedua pecahan tersebut terutama ditemukan pada lembaran berkondisi lusuh dari emisi tahun 2016, yang diduga berkaitan dengan perubahan karakteristik saturasi pigmen warna. Sensor inframerah difungsikan sebagai pemicu siklus pembacaan warna secara otomatis ketika lembaran uang melewati slot celengan. Mekanisme ini diterapkan untuk mencegah pembacaan ganda.

3.3.2 Implementasi REST API Server dan Integrasi Dashboard Web

Komunikasi data antara celengan IoT dan sistem *backend* menggunakan web server berbasis framework Flask yang terhubung ke database MySQL. Server web menyediakan endpoint REST API dengan metode HTTP POST untuk menerima data spektral RGB mentah, menghitung 18 fitur turunannya (membentuk total 21 fitur masukan),

mengeksekusi prediksi model *Stacking Ensemble*, serta menyimpan riwayat transaksi ke *database*. *Endpoint* berbasis *HTTP GET* dikembangkan khusus untuk menyajikan akumulasi total saldo tabungan secara *real-time* melalui kueri penjumlahan data transaksi pada *database*. Informasi transaksi uang masuk serta akumulasi total saldo tabungan disinkronisasikan secara otomatis dari *database* menuju antarmuka *Dashboard Web*. Tampilan antarmuka *Dashboard Web* pemantauan tabungan ditunjukkan pada Gambar 8.



Gambar 8. Tampilan Antarmuka *Dashboard Web* Pemantauan Uang Masuk, Total Tabungan, dan Manajemen Penarikan Saldo Celengan IoT

Sebagaimana ditunjukkan pada Gambar 8, antarmuka *Dashboard Web* dirancang secara responsif dengan bilah navigasi utama di sebelah kiri yang memuat menu *Dashboard*, *Uang Masuk*, dan *Uang Keluar*. Bagian atas antarmuka menyajikan tiga kartu indikator utama, mencakup saldo *Uang Masuk Hari Ini*, *Uang Masuk Bulan Ini*, dan akumulasi *Total Tabungan* terkini. Bagian tengah memperlihatkan grafik garis tren *Uang Masuk Bulanan* untuk memantau fluktuasi pertumbuhan saldo tabungan dari waktu ke waktu. Bagian bawah antarmuka dilengkapi dengan panel kontrol penarikan saldo *Ambil Uang* yang memfasilitasi pengguna untuk melakukan konfirmasi penarikan sejumlah nominal tertentu atau penarikan seluruh tabungan secara terintegrasi [14].

3.4 Pembahasan

Pengembangan sistem celengan cerdas berbasis *Internet of Things* yang mengombinasikan sensor spektrum warna *TCS34725* dan arsitektur *Stacking Ensemble* memberikan kontribusi nyata terhadap keandalan pengenalan nominal uang kertas Rupiah secara *real-time*. Hasil pengujian eksperimen dievaluasi secara komprehensif dengan menghubungkan aspek rekayasa fitur spektral, pembersihan *noise*, penyeimbangan data, performa *Stacking Ensemble*, serta integrasi perangkat keras fisik. Karakteristik nilai spektral warna mentah membuktikan bahwa akuisisi dalam ruang tertutup berlampu *LED* terintegrasi sanggup mereduksi fluktuasi reflektansi akibat interferensi pencahayaan luar [4]. Ekstraksi 18 fitur turunan (membentuk total 21 fitur masukan) terbukti meningkatkan daya pembeda, di mana rasio logaritmik (*Log_RG*), diferensial warna lawan (*RG_diff*), dan proyeksi trigonometri (*Hue_cos*) mendominasi percabangan keputusan dalam memisahkan pigmen warna uang. Pembiasan minor pada pecahan bernilai spektral mirip mengonfirmasi teori pengenalan pola warna bahwa degradasi fisik menimbulkan peririsan ruang fitur [17]. Penanganan *noise* sensor menggunakan metode *ENN* serta penyeimbangan data latih berbasis *SMOTE* berhasil membentuk 938 sampel latih seimbang tanpa menimbulkan kebocoran data pada 202 sampel data uji murni.

Penerapan arsitektur *Stacking Ensemble* yang mengintegrasikan *Random Forest*, *XGBoost*, *CatBoost*, dan *Gradient Boosting* sebagai model dasar serta *Random Forest Classifier* sebagai model meta menghasilkan akurasi sebesar 93,07% dan nilai *weighted average F1-score* sebesar 0,93. Capaian ini menunjukkan performa yang kompetitif mendampingi model tunggal *Random Forest* (92,08%). Penggabungan heterogen ini tidak ditujukan untuk mengejar kenaikan akurasi ekstrem, melainkan menghadirkan mekanisme *meta-learning* yang efektif menyeimbangkan estimasi probabilitas antar algoritma pohon keputusan, meredam variansi prediksi, dan memitigasi kesalahan individual model dasar pada sampel uang berspektrum mirip [20]. Evaluasi kurva pembelajaran pada Gambar 5 memperlihatkan nilai kehilangan data validasi (*Validation Loss*) konvergen stabil pada angka 0,37 dan akurasi data validasi terkunci pada kisaran 89,32% sepanjang 200 iterasi tanpa indikasi *overfitting* [21].

4. KESIMPULAN

Penelitian ini mengembangkan sistem celengan cerdas berbasis *Internet of Things* (IoT) untuk mengklasifikasikan tujuh pecahan nominal uang kertas Rupiah menggunakan sensor warna *TCS34725* dan arsitektur *Stacking Ensemble*. Mikrokontroler *ESP32* difungsikan sebagai node akuisisi data sensor yang terhubung melalui layanan *REST API* menuju *server Flask*. Rangkaian pra-pemrosesan data yang mencakup ekstraksi 21 fitur spektrum warna, penyaringan *noise* sensor *Edited Nearest Neighbours* (*ENN*), standarisasi *StandardScaler*, serta

penyeimbangan SMOTE pada data latih terbukti efektif memperjelas batas pemisahan antarkelas dan mereduksi bias prediksi. Arsitektur *Stacking Ensemble* yang menggabungkan *Random Forest*, *XGBoost*, *CatBoost*, dan *Gradient Boosting* dengan *meta-learner Random Forest Classifier* mencatatkan akurasi tertinggi sebesar 93,07% dan *weighted average F1-score* sebesar 0,93 pada 202 sampel data uji murni.

Pengujian langsung pada perangkat fisik celengan IoT mencatatkan tingkat keberhasilan pembacaan sebesar 87,1% terhadap 70 lembar uang kertas asli independen yang mencakup kondisi fisik baru, sedang, dan lusuh dari emisi tahun 2016 dan 2022. Sensor inframerah difungsikan sebagai pemicu siklus pembacaan otomatis saat uang masuk untuk mencegah terjadinya pembacaan ganda. Pencatatan transaksi dan akumulasi saldo tersimpan ke dalam database MySQL untuk dipantau secara interaktif melalui *dashboard web*, didukung pengamanan akses fisik berbasis modul *RFID* dan pengunci solenoid.

REFERENCES

- [1] B. Indonesia, “Unsur Pengaman dan Spesifikasi Ciri Uang Kertas Rupiah Emisi 2022,” Bank Indonesia Official Web Portal. [Online]. Available: <https://www.bi.go.id/id/rupiah/gambar-uang/Default.aspx>
- [2] A. Syahputra, Syahwin, and M. Z. Siambaton, “Rancang Bangun Sistem Monitoring Smart Savings Anak Sekolah pada Celengan Uang Kertas Berbasis Internet of Things (IoT),” *J. Ilmu Komput.*, pp. 0–4, 2025, doi: 10.56211/helloworld.v4i2.959.
- [3] R. M. Komarudin, W. Suteddy, and D. A. R. Agustini, “Rancang Bangun Celengan Pintar Berbasis IoT Menggunakan RFID dan Notifikasi Telegram,” *Jambura J. Electr. Electron. Eng.*, vol. 6, no. 2, pp. 240–248, 2024, doi: 10.37905/jjee.v6i2.26179.
- [4] M. H. Alfari, A. L. Prasasti, and R. R. Septiawan, “IoT-Based Banknotes Saving Automation System,” *CEPAT J. Comput. Eng. Progress, Appl. Technol.*, vol. 2, no. 2, pp. 62–69, 2023, doi: 10.25124/cepat.v2i01.5499.
- [5] F. A. T. Putra, A. B. P. Negara, and H. Sastypratiwi, “Perbandingan Kinerja Naive Bayes dan Random Forest dengan Penganganan Imbalance Data,” *J. Inform. Polinema*, vol. 12, no. 2, pp. 401–408, 2026, doi: 10.33795/jip.v12i2.8424.
- [6] B. A. Sadewa and Y. Yamasari, “Implementasi Deep Transfer Learning untuk Klasifikasi Nominal Uang Kertas Rupiah,” *J. Informatics Comput. Sci.*, vol. 05, pp. 543–551, 2024, doi: 10.26740/jinacs.v5n04.p543-551.
- [7] R. K. Habsari, M. I. Khoiri, Purbandini, B. D. Satoto, A. H. Salim, and T. Kristanto, “Identification of Indonesian Rupiah Paper Currency Denominations Using First Order Statistical Feature Extraction and k-Nearest Neighbor,” *Int. J. INFORMATICS Vis.*, vol. 9, no. May, 2025, doi: 10.62527/joiv.9.3.3037.
- [8] Irma, D. Hendryadi, and J. Iryani, “Prototipe alat pemilah buah kopi otomatis pada panen racutan (stripping) menggunakan sensor warna TCS34725 dan modul Arduino,” *J. Syst. Inf. Comput. Inst. Teknol. Dan Bisnis Bina Adinata*, vol. 2, no. 1, 2024, doi: 10.63989/ammatoa.v2i1.74.
- [9] D. N. Masmur and M. Snae, “Rancang bangun sistem sortir buah cabai berdasarkan warna berbasis arduino uno,” *J. Teknol. Inf.*, vol. 15, no. c, pp. 33–42, 2024, doi: 10.52972/hoaq.vol15no1.p33-42.
- [10] Sudarto and Kusirini, “Klasifikasi Tsunami Gempa Bumi dengan Teknik Stacking Ensemble Machine Learning,” *J. Inform. Polinema*, vol. 10, no. 4, pp. 511–519, 2024, doi: 10.33795/jip.v10i4.5655.
- [11] N. Anggraini, S. J. Putra, L. K. Wardhani, F. D. U. Arif, N. Hakiem, and I. M. Shofi, “A Comparative Analysis of Random Forest , XGboost , and LightGBM Algorithms for Emotion Classification in Reddit Comments,” *J. Tek. Inform.*, vol. 17, no. 1, pp. 88–97, 2024, doi: 10.15408/jti.v17i1.38651.
- [12] K. H. Rambe *et al.*, “Model Ensemble Stacking untuk Klasifikasi Big Data Stunting Berbasis XGBoost dan MLP,” *Remik Ris. dan E-Jurnal Manaj. Inform. Komput.*, vol. 10, no. 1, pp. 385–395, 2026, doi: 10.33395/remik.v10i1.15903.
- [13] N. A. Siagian, S. P. Sipayung, A. Rikki, and N. Marbun, “Integrating SMOTE with XGBoost for Robust Classification on Imbalanced Datasets : A Dual-Domain Evaluation,” *J. dan Penelit. Tek. Inform.*, vol. 9, no. 3, pp. 1094–1107, 2025, doi: 10.33395/sinkron.v9i3.15029.
- [14] M. A. Hamid and E. R. Subhiyakt, “Performance Comparison of Random Forest , SVM , and XGBoost Algorithms with SMOTE for Stunting Prediction,” *J. Appl. Informatics Comput.*, vol. 9, no. 4, pp. 1163–1169, 2025, doi: 10.30871/jaic.v9i4.9701.
- [15] D. Trisatya and P. Haryoko, “Improving Customer Churn Detection Through Balanced Ensemble Learning,” *J. Inform. Polinema*, vol. 12, no. 3, pp. 431–438, 2026, doi: 10.33795/jip.v12i3.9500.
- [16] E. Systems, “ESP32 Series Datasheet: Hardware Specifications and Wi-Fi Microcontroller Capabilities,” Espressif Systems Official Technical Documentation. [Online]. Available: <https://www.espressif.com/en/products/socs/esp32>
- [17] I. K. G. D. Putra, *Pengolahan Citra Digital dan Pengenalan Pola*. Yogyakarta: Penerbit Andi, 2021.
- [18] N. A. Levina and M. Rahardi, “Analysis of Stacking Ensemble Method in Machine Learning Algorithms to Predict Student Depression,” *J. Appl. Informatics Comput.*, vol. 9, no. 6, pp. 3283–3294, 2025, doi: 10.30871/jaic.v9i6.11453.
- [19] R. Sukmawardani, L. Nurpulaela, and R. Rahmadewi, “Implementasi Arsitektur Resnet152 untuk Klasifikasi Uang Kerta Rupiah dengan Metode Transfer Learning,” *J. Mhs. Tek. Inform.*, vol. 8, no. 4, pp. 5650–5657, 2024, doi: 10.36040/jati.v8i4.10001.
- [20] D. Pratama, Sucipto, and B. C. Octariadi, “Penerapan Teknik Stacking Ensemble Learning untuk Identifikasi Infeksi Saluran Kemih,” *J. Mhs. Tek. Inform.*, vol. 10, no. 4, pp. 6035–6040, 2026, doi: 10.36040/jati.v10i4.18612.
- [21] J. Bahaswan, Sopingi, and H. Hasanah, “Perbandingan Random Forest dan XGBoost dalam Prediksi Status Pinjaman Menggunakan Cross Validation dan Analisis Feature Importance,” *J. Mhs. Tek. Inform.*, vol. 10, no. 4, pp. 6908–6915, 2026, doi: 10.36040/jati.v10i4.18823.