

Pengembangan Prototipe untuk Prediksi Tingkat Penyeduhan Kopi Menggunakan Data Spektroskopi dan Deep Learning

Muhammad Teguh Prananto¹, Ridwan Raafi'udin², Muhammad Adrezo³, Musthofa Galih Pradana⁴, Nurul Afifah Arifuddin⁵

^{1,2,3,4,5} Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional Veteran Jakarta
Jl. RS. Fatmawati Raya, Pondok Labu, Jakarta Selatan, 12450, Indonesia

Info Artikel

Riwayat Artikel:

Received 2025-05-08

Revised 2025-06-25

Accepted 025-06-28

Abstract – Consistency in coffee flavor is a crucial factor for coffee enthusiasts, thus requiring a method capable of objectively measuring the coffee brewing level in accordance with the standard brewing chart. This study utilizes the AS7265X spectroscopy sensor to capture the characteristics of coffee based on the resulting light spectrum. The spectral data is then used in a deep learning model using the Convolutional Neural Network (CNN) algorithm to classify the coffee brewing level into five distinct classes. A total of 150 data samples were used in the training and testing process. Initial results show that the model achieved a very high average accuracy of approximately 97%. After hyperparameter tuning using the Random Search method, the model's accuracy further improved, reaching a very high accuracy. However, this performance improvement resulted in a trade-off in computational time, with execution time increasing from 15 seconds to 1 minute and 43 seconds. This research is expected to contribute to ensuring consistent coffee brew quality and to open opportunities for further studies that combine sensor technology and artificial intelligence in the food and beverage sector.

Keywords: AS7265X Sensor; Classification; Coffee Brewing Level; Convolutional Neural Network (CNN); Spectroscopy Data.

Corresponding Author:

Ridwan Raafi'udin

Email: raafiudin@upnvj.ac.id



This is an open access article under the [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/) license.

Abstrak – Konsistensi cita rasa kopi merupakan faktor penting bagi para penikmat kopi, sehingga diperlukan metode yang mampu mengukur tingkat penyeduhan kopi (coffee brewing level) secara objektif dan sesuai dengan standar brewing chart. Penelitian ini memanfaatkan sensor spektroskopi AS7265X untuk menangkap data karakteristik kopi berdasarkan spektrum cahaya yang dihasilkan. Data spektrum ini kemudian digunakan dalam pemodelan deep learning menggunakan algoritma Convolutional Neural Network (CNN) untuk mengklasifikasikan tingkat penyeduhan kopi ke dalam lima kelas berbeda. Sebanyak 150 data digunakan dalam proses pelatihan dan pengujian model. Hasil awal menunjukkan bahwa model mencapai rata-rata akurasi yang sangat tinggi, yaitu sekitar 97%. Setelah dilakukan penyetelan hyperparameter menggunakan metode Random Search, akurasi model meningkat lebih lanjut hingga mencapai tingkat akurasi sangat tinggi. Namun, peningkatan performa ini menyebabkan trade-off dalam waktu komputasi, di mana waktu eksekusi bertambah dari 15 detik menjadi 1 menit 43 detik. Penelitian ini diharapkan dapat memberikan kontribusi dalam memastikan kualitas seduhan kopi secara konsisten, serta membuka peluang bagi pengembangan penelitian sejenis yang menggabungkan teknologi sensor dan kecerdasan buatan dalam bidang pangan dan minuman.


Kata Kunci: Coffee Brewing Level, Convolutional Neural Network (CNN), Data Spektroskopi, Klasifikasi, Sensor AS7265X.

I. PENDAHULUAN


Kopi menjadi minuman favorit di dalam maupun luar negeri, dengan survei Snapcart 2023 menunjukkan 79% dari 4.538 responden di Indonesia mengonsumsinya setiap hari. *International Coffee Organization* (ICO) mencatat peningkatan permintaan kopi global sebesar 2,6% pada 2022-2023. Seiring tren konsumsi yang terus meningkat, angka produksi kopi di Indonesia juga semakin besar. Pertumbuhan konsumsi ini dibuktikan dengan jumlah kedai kopi yang melonjak dari 2.950 gerai pada 2019 menjadi 10.000 gerai pada 2023 [1] [2]. Lonjakan jumlah kedai kopi ini tidak hanya mencerminkan peningkatan konsumsi, tetapi juga menunjukkan perubahan gaya hidup masyarakat Indonesia. Kopi kini bukan sekadar minuman, melainkan bagian dari aktivitas sosial dan identitas budaya, terutama di kalangan generasi muda. Fenomena ini turut mendorong pertumbuhan ekonomi kreatif dan membuka peluang bisnis baru di sektor kuliner.

Akibatnya, preferensi cita rasa kopi semakin bervariasi dan kurang konsisten sehingga diperlukan kuantisasi berdasarkan *brew level*. Pada tahun 1957 Ernest E. Lockhart memperkenalkan *coffee brewing control chart* yang membagi kopi ke dalam 9 kelas berdasarkan *Extraction Yield* (EY) dan *Total Dissolved Solids* (TDS), dengan kelas "Ideal" sebagai standar cita rasa optimal [3] seperti ditunjukkan oleh Gambar 1. Pengukuran TDS biasanya menggunakan refraktometer, tetapi alat tersebut belum bisa mengklasifikasikan tingkat penyeduhan kopi karena hanya mampu mengukur tingkat TDS.

Alat yang digunakan harus mampu mengenali karakteristik mengenai kandungan dari suatu objek. Berdasarkan penelitian sebelumnya yang di mana sensor spektroskopi sering kali digunakan dalam analisis kandungan objek seperti penelitian dilakukan oleh Daffa menggunakan *deep learning* dalam prediksi beras oplosan yang memanfaatkan kombinasi antara sensor spektroskopi AS7265X dengan *deep learning*. Penelitian tersebut menggunakan *deep learning* model *Convolutional Neural Network* dan berhasil mengklasifikasikan beras dengan baik yang di mana akurasi sebesar 86%. Model tersebut kemudian dilakukan hyperparameter tuning dan meningkatkan akurasi menjadi 100% [4].



Gambar 1. Coffee Brewing Control Chart [5]



Gambar 2. Desain 3 Dimensi Prototipe

Penelitian lain yaitu pengembangan alat ukur portabel untuk memprediksi kandungan nitrogen yang menggunakan sensor AS7265X sebagai sensor utama. Penelitian tersebut memanfaatkan data spektroskopi dengan model *Multi Linear Regression* dan mampu memprediksi dengan baik di mana rata-rata skor R^2C adalah 0,97 [6]. Hal tersebut menunjukkan bahwa sensor AS7265X memiliki potensi yang baik dalam mengenali karakteristik dari kopi sesuai dengan *coffee brewing level* yang ada pada *brewing control chart*. Terdapat penelitian terdahulu yang mengembangkan model seleksi fitur berbasis penyederhanaan garis menggunakan metode *Random Forest Regressor* pada data *Near-Infrared Spectroscopy* (NIRS) untuk meningkatkan akurasi prediksi enam parameter kualitas daging sapi. Hasil penelitian menunjukkan peningkatan signifikan pada nilai R^2 dengan rata-rata kenaikan akurasi sebesar 17,49% dan nilai R^2 akhir mencapai rata-rata 90%. Metode ini terbukti efektif dan berpotensi diterapkan dalam analisis kualitas pangan, khususnya daging sapi, dengan efisiensi yang lebih baik [7].

Penelitian lain yang dilakukan oleh Amanah terkait prediksi kandungan gula pada kentang sehat dan terinfeksi cendawan *Fusarium sp.* dengan menggunakan spektroskopi Vis-NIR berbasis sensor fiber optic dan AS7265X. Model *Partial Least Squares Regression* (PLSR) digunakan untuk data dari sensor fiber optik, sementara model *Multiple Linear Regression* (MLR) digunakan untuk data dari sensor AS7265X. Model PLSR menunjukkan performa terbaik dengan nilai R^2C sebesar 0,9, 0,91, dan 0,79 serta R^2P sebesar 0,77, 0,88, dan 0,43 untuk prediksi fruktosa, glukosa, dan sukrosa. Di sisi lain, model MLR terbaik memperoleh nilai R^2C sebesar 0,92, 0,86, dan 0,88 serta R^2P sebesar 0,80, 0,68, dan 0,84. Hasil penelitian ini menunjukkan bahwa kedua sensor dapat digunakan untuk mengidentifikasi kandungan gula dalam kentang dengan tingkat akurasi

yang cukup tinggi [8]. Penelitian-penelitian tersebut menunjukkan bahwa data spektroskopi dapat digunakan dalam berbagai bidang, mulai dari analisis pangan hingga klasifikasi objek deep learning, dengan hasil yang menjanjikan dalam meningkatkan akurasi prediksi dan efisiensi proses analisis.

Oleh karena itu, dilakukan penelitian menggunakan sensor spektroskopi karena memiliki kemampuan mengidentifikasi komposisi dari suatu objek. Sensor yang digunakan yaitu AS7265X yang memiliki harga lebih terjangkau dibandingkan refraktometer. Data yang diperoleh dari sensor spektroskopi atau disebut sebagai data spektroskopi kemudian digunakan dalam pembuatan model menggunakan metode deep learning. Implementasi deep learning yaitu untuk mengenali pola dalam data spektroskopi dan memprediksi *coffee brewing level* berdasarkan karakteristik data. Tujuan penelitian yaitu mengembangkan sistem yang mampu mengklasifikasikan kopi berdasarkan *brewing level*-nya dengan akurat. Penelitian ini akan mengkaji bagaimana implementasi deep learning bisa mempelajari data spektroskopi dan mendeteksi *coffee brewing level*. Penelitian diharapkan bisa memberikan kontribusi untuk meningkatkan efisiensi dalam deteksi kopi sesuai dengan *brewing level*.

II. METODE

Dalam mempermudah penelitian, ditentukan beberapa tahapan yang perlu dilakukan guna membuat penelitian lebih terstruktur. Tahapan penelitian dilakukan secara bertahap mulai dari pengumpulan data hingga evaluasi model, adapun tahapannya dapat dilihat pada Gambar 33.



Gambar 3. Tahapan Penelitian


Ditunjukkan pada Gambar 33 terdapat 10 langkah utama yang dilakukan dalam penelitian. Penelitian ini diawali dengan identifikasi masalah untuk merumuskan pertanyaan yang tepat, menetapkan tujuan jelas, dan memilih metode yang relevan agar penelitian lebih terarah. Studi literatur dilakukan dengan mengkaji penelitian terdahulu terkait kopi, sensor spektroskopi, dan *Deep Learning* sebagai dasar pengembangan model CNN yang optimal.

A. Menentukan Sampel

Penelitian ini menggunakan 5 (lima) kelas tingkat seduhan dari total 9 (sembilan) yaitu *weak*, *underdeveloped*, *ideal*, *bitter*, dan *strong*. Jenis kopi yang digunakan yaitu biji kopi dengan tingkatan *medium roast*. Selain itu, teknik penyeduhan kopi adalah V60. Hal ini berdasarkan syarat yang berlaku pada *brewing chart* [8]. Sampel kopi dibuat secara langsung oleh barista yang kompeten dan ahli dalam penyeduhan kopi. Jumlah kelas diperkecil dengan tujuan memperkecil lingkup penelitian serta mengurangi sampel yang diperlukan pada saat pengambilan data. Nantinya, data diambil dalam 3 (tiga) keadaan yang berbeda yaitu pada saat kopi dalam keadaan panas, dalam keadaan hangat, dan dalam keadaan suhu ruangan yang di mana masing-masing di ambil sebanyak 10 (sepuluh) kali sehingga jumlah data setiap label yaitu 30 (tiga puluh) data dan total keseluruhan data yaitu 150 (seratus lima puluh) baris data.

B. Sensor Spektroskopi dan Prototipe

Sensor spektroskopi yang digunakan dalam penelitian yakni sensor spektroskopi AS7265X. Sensor ini dilengkapi dengan 3 komponen utama yaitu AS72651 untuk *visible light*, AS72652 untuk Near-Infrared, dan AS72653 untuk ultraviolet. Sensor ini akan menghasilkan output sebanyak 18 (delapan belas) intensitas cahaya dalam panjang gelombang yang berbeda-beda [9]. Komponen yang digunakan disambungkan ke Raspberry PI yang nantinya juga akan dimasukkan model Tensorflow Lite untuk melakukan pemodelan. Setelah komponen dihubungkan, maka komponen akan ditaruh ke dalam wadah yang dibuat menggunakan mesin 3D *printer*. Wadah dirancang sedemikian rupa menggunakan aplikasi Google Sketchup. Wadah yang dibuat untuk menaruh sebuah gelas “sloki” kecil dan diberi lubang untuk memancarkan cahaya dari sensor AS7265X. Wadah juga diberi penutup untuk mencegah interferensi cahaya, guna memastikan konsistensi data yang diperoleh. Selain itu digunakan OLED dan tombol untuk mempermudah interaksi antara pengguna dengan prototipe. Berikut pada Gambar 44 merupakan skematik rangkaian pada prototipe yang di mana komponen berwarna merah adalah sensor spektroskopi AS7265X.



Gambar 4. Rangkaian atau Skematik Prototipe

C. Pra-proses


Sampel penelitian terdiri dari lima jenis kopi berdasarkan *solubles concentration* dan *solubles yield*. Data dikumpulkan dengan *scanning* spektroskopi pada tiga tahap suhu (panas, hangat, normal) untuk meningkatkan akurasi, menghasilkan total 150 data. Awalnya data dalam file berekstensi txt. Kemudian data diberi label dan digabung sehingga menjadi format CSV. Data tersebut lalu dibagi menjadi data pelatihan (80%) dan validasi (20%) yang di mana data pelatihan akan digunakan dalam proses pelatihan dan validasi untuk evaluasi.

D. Pembuatan Model

CNN merupakan salah model *deep learning* yang sering digunakan dalam klasifikasi gambar. Sering kali CNN dianggap hanya memiliki kemampuan untuk ekstraksi fitur pada gambar. Padahal, pada implementasinya CNN memiliki kemampuan untuk mengekstraksi fitur spasial sehingga cocok digunakan saat bekerja berkaitan dengan data spektrum [10]. Seperti halnya yang dilakukan pada penelitian klasifikasi beras yang memanfaatkan data spektroskopi serta CNN sebagai model pada penelitiannya. Penelitian tersebut meraih hasil yang baik sehingga menjadi salah satu alasan penggunaan CNN pada penelitian ini.

Model CNN yang digunakan pada penelitian ini terdiri dari 5 (lima) lapisan, yaitu input layer, konvolusi 1 dimensi, *Flatten*, *fully-connected layer*, serta output layer. Pada lapisan input layer hanya menerima input dan mengubah dimensi data menjadi (18,1). Hal ini karena sebanyak data dengan 18 (delapan belas) fitur akan diubah menjadi 1 channel sehingga dapat diproses lebih lanjut oleh lapisan konvolusi. Selanjutnya lapisan konvolusi dengan ukuran kernel 2 (dua) akan melakukan pemetaan fitur dengan jumlah filter sebanyak 16 (enam belas). Data kemudian diubah kembali menjadi 1 dimensi oleh lapisan *Flatten* agar bisa dilakukan perhitungan oleh lapisan berikutnya yaitu *fully-connected layer* dengan 16 (enam belas) neuron. Terakhir, yaitu *fully-connected*

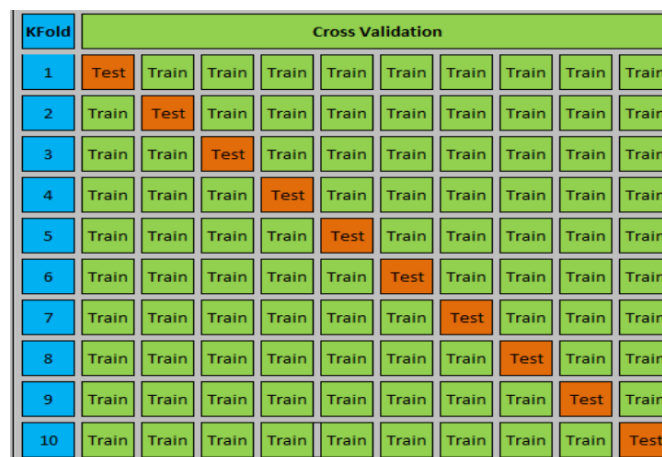
layer sebagai lapisan output dengan 5 neuron menyesuaikan jumlah kelas pada penelitian. Pada konvolusi 1 dan *fully-connected layer* digunakan fungsi aktivasi ReLU dan diterapkan regularisasi L2 dengan nilai konstanta sebesar 0,001 untuk mencegah *overfitting* [11].



Gambar 5. Arsitektur Model CNN

E. Evaluasi

Model dievaluasi terdahulu menggunakan confusion matrix untuk melihat bagaimana persebaran prediksi yang dihasilkan. Kemudian metrik yang umum digunakan dalam klasifikasi seperti precision, recall, f1-score, dan accuracy digunakan untuk mengukur performa klasifikasi. Tahap ini penting untuk melihat seberapa baik performa model dalam memprediksi *coffee brewing level* serta melihat apakah model terindikasi *overfitting* ataupun *underfitting* [12]. Selain itu, model juga dievaluasi menggunakan *K-Fold Cross Validation*. *K-Fold Cross Validation* merupakan metode untuk mengevaluasi model dengan cara membagi dataset training dan validasi secara bergantian sesuai dengan jumlah *fold* [13]. Metode ini akan membagi data menggunakan jumlah *fold* di mana jumlah data validasi yaitu sebanyak jumlah data dibagi dengan *fold*. Pada penelitian ini, digunakan *Fold* sebesar 5 (lima). Adapun contoh skema dari metode *K-Fold Cross Validation* dengan 7 (tujuh) kali *fold* yang terlihat pada Gambar 66.




Gambar 6. Skema K-Fold Cross Validation [13]

F. Hyperparameter Tuning

Dalam rangka meningkatkan performa model awal yang telah dibuat, dilakukan hyperparameter tuning. Metode hyperparameter tuning yang digunakan dalam penelitian yaitu *Random Search*. *Random Search* adalah salah satu teknik hyperparameter tuning yang menggunakan kombinasi parameter secara acak dalam mencari parameter terbaiknya [14]. Berbeda dengan *Grid Search*, metode ini tidak menjamin diperolehnya parameter terbaik dari seluruh kombinasi yang ada karena pemilihan parameter secara acak dilakukan sebanyak 5 (lima) kali percobaan dengan tiap percobaan dilatih selama 100 (seratus) *epochs*.

Random Search

```
Pseudocode  
Hyperparameter_One = random.num(range)  
Hyperparameter_Two = random.num(range)
```



Gambar 7. Random Search [15]

G. Implementasi Model

Model yang memiliki performa terbaik akan diimplementasikan ke dalam model. Model yang digunakan adalah model berekstensi tensorflow lite. Seluruh *script* dan model kemudian dimasukkan ke Raspberry PI menggunakan protokol SFTP. Selain itu, Raspberry PI juga dikonfigurasi menggunakan crontab agar setiap kali Raspberry PI dinyalakan akan mengeksekusi *script* yang telah dibuat untuk mengklasifikasi.

H. Pengujian Alat/Prototipe


Setelah model diimplementasikan dan semua rangkaian sensor dapat bekerja, maka disiapkan sebuah sampel. Sampel seduhan kopi dituangkan ke dalam gelas sloki kecil yang kemudian diletakkan di atas alat. Kemudian, gelas tersebut diberikan penutup agar tidak ada cahaya yang masuk dari luar yang berpotensi mengganggu pengambilan data oleh sensor AS7265X. Tombol dipencet dan menunggu keseluruhan proses berjalan mulai dari pengambilan data oleh sensor AS7265X berupa data 18 angka yang kemudian digunakan sebagai *input* untuk klasifikasi model CNN.

III. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil eksperimen yang diperoleh dari penelitian secara keseluruhan mulai dari hasil prototipe yang dibuat, pengambilan data, pemodelan klasifikasi kopi menggunakan data spektroskopi, evaluasi, hingga hyperparameter tuning. Selain itu, analisis lebih lanjut dilakukan untuk memahami bagaimana persebaran dari data yang diperoleh dan performa model yang telah dilatih. Berikut adalah hasil dan pembahasan dari eksperimen yang telah dilakukan.

A. Prototipe

Prototipe dibuat mengikuti skematik yang ada pada Gambar 8. Prototipe kemudian diberikan wadah yang dibuat menggunakan 3D Printer. Wadah yang dibuat dilengkapi dengan tempat untuk menaruh gelas pengambilan data serta penutup untuk menutupi gelas saat pengambilan data dilakukan. Hal ini dilakukan untuk menghindari adanya cahaya yang masuk karena bisa mengakibatkan adanya bias pada data. Berikut merupakan Hasil *prototype* yang telah dibuat.



Gambar 8. Prototipe

B. Data Spektroskopi

Pada saat data dari sampel diambil, digunakan termometer untuk melihat suhu dalam keadaan *realtime*, seperti yang terlihat pada Gambar 9. Data spektroskopi ditaruh di atas prototipe yang sudah dibuat kemudian diberikan tutup untuk mencegah adanya cahaya lain yang berpotensi mengintervensi pengambilan data. Contoh pengambilan data dapat dilihat pada Gambar 9 dan Gambar 10.



Gambar 9. Sampel Kopi




Gambar 10. Prototipe dan Sampel

C. Pelatihan Model

Data yang telah melalui tahapan praproses kemudian diacak dan dibagi dengan rasio 80:20, yakni 80% dari keseluruhan data digunakan untuk tahap pelatihan, dan 20% sisanya sebagai testing atau validasi. Data dijadikan dalam bentuk *batch* dengan ukuran yaitu 12 (dua belas). Menurut penelitian yang dilakukan Sebastian menunjukkan bahwa pemilihan ukuran *batch* dengan kelipatan 2 (dua) memang memberikan hasil pengalokasian *memory* yang lebih optimal dan terorganisir sehingga memungkinkan perhitungan *matrix* yang terjadi pada tahap training menjadi lebih efisien [16].

Model dilatih dengan ukuran *batch* data 12 (dua belas) menyesuaikan jumlah training data yakni 120, jumlah *epochs* 100, serta menggunakan *optimizer* Adam dengan learning rate 0.001. Selain itu, digunakan *callback* ReduceLROnPlateau untuk mengurangi *learning rate* apabila *val_loss* sudah tidak menurun dan *callback* EarlyStopping untuk menghentikan training apabila model tidak berkembang lagi dalam 100 *epochs* tersebut. Berikut merupakan grafik yang menunjukkan performa model setelah dilakukan pelatihan seperti ditunjukkan oleh Gambar 11.



Gambar 11. Grafik Akurasi dan Loss setiap *Epoch* pada Model Awal

Performa yang diperoleh model awal cukup baik di mana akurasi akhir yaitu 100% dan *val_accuracy* yaitu 86%. Lalu untuk *loss*-nya yaitu sebesar 0,09 dan *val_loss* sebesar 0,19. Selisih antara akurasi pada training dan data validasi cukup besar sehingga mengindikasikan terjadinya *overfitting*.

D. Hyperparameter Tuning

Dalam tahap ini, terdapat beberapa variabel yang dipilih sebagai untuk diacak dalam Random Search. Tabel 1 menunjukkan daftar hyperparameter yang berperan dalam *Random Search* beserta rentang nilai atau opsi yang diterapkan pada masing-masing hyperparameter.

TABEL 1
RENTANG ATAU OPSI HYPERPARAMETER TERPILIH


Hyperparameter	Step/Options
Filters (F)	16 – 64 (<i>step</i> 16)
Kernel Size (KRL)	3 atau 5
Regularisasi L2 Conv1D (L2CV)	0,0001 – 0,01 (logarithmic sampling)
Dense Unit (DU)	16 – 128 (<i>step</i> 16)
Regularisasi <i>fully-connected</i> layer (L2D)	0,0001 – 0,01 (logarithmic sampling)
Optimizer (OPT)	Adam or RMSProp
Learning Rate (LR)	0,01, 0,001, or 0,0001

Setelah Random Search diimplementasikan, kemudian peneliti mengamati beberapa percobaan yang dilakukan dalam tahap hyperparameter tuning dan membandingkan seluruh hasil percobaan dengan model awal yang telah dibuat. Metrik yang diukur yaitu berdasarkan akurasi pada data validasi.

TABEL 2
HASIL HYPERPARAMETER TUNING

No.	F	KRL	L2CV	DU	L2D	OPT	LR	Val_Acc
1.	48	3	0,00065	48	0,00597	Adam	0,001	1
2.	64	3	0,0001	48	0,00524	Adam	0,001	1
3.	64	3	0,00014	32	0,0004	Adam	0,0001	0,92
4.	64	3	0,00307	128	0,0017	RMSProp	0,0001	0,88
5.	32	3	0,00067	16	0,00014	RMSprop	0,0001	0,68

Berdasarkan hasil hyperparameter tuning, terdapat 2 kombinasi hyperparameter yang mencapai akurasi lebih baik dibanding sebelumnya. Hal ini menunjukkan bahwa model yang dilakukan hyperparameter tuning memperoleh performa yang lebih baik dibandingkan dengan model awal. Pada penelitian ini dilakukan pelatihan ulang menggunakan hyperparameter terbaik yang di mana secara otomatis menggunakan kombinasi nomor 1 pada tabel hasil yang ditampilkan.




Gambar 12. Grafik Akurasi dan Loss setiap Epoch pada Model dengan hyperparameter tuning

Dapat dilihat grafik yang ditampilkan pada Gambar 12 menunjukkan bahwa akurasi model yang dilakukan hyperparameter tuning lebih baik di mana akurasi training dan validasi mencapai 100%. Gambar tersebut juga menunjukkan loss yang lebih rendah di mana loss pada training mencapai 0,15 dan loss pada validasi sebesar 0,18. Walaupun model awal memiliki loss sebesar 0,09 pada *training*, tetapi hal tersebut tidak dapat digunakan sebagai acuan karena loss tersebut adalah loss pada pelatihan.

E. Evaluasi

Model CNN yang telah dirancang serta model yang telah dilakukan hyperparameter tuning dievaluasi lebih lanjut menggunakan metrik seperti *confusion matrix*, *akurasi*, *precision*, *recall*, dan *f1-score*. Performa model secara keseluruhan dapat disimpulkan bekerja kurang baik dan dapat dilihat Gambar 13 masih ada kesalahan prediksi.




Gambar 13. *Confusion Matrix Model Awal*

TABEL 3.
CLASSIFICATION REPORT MODEL AWAL

	Precision	Recall	F1-Score	Support
<i>Bitter</i>	1,0	1,00	1,00	6
<i>Ideal</i>	1,00	1,00	1,00	6
<i>Strong</i>	1,00	0,33	0,50	6
<i>Underdeveloped</i>	0,60	1,00	0,75	6
<i>Weak</i>	1,00	1,00	1,00	6
<i>Accuracy</i>			0,87	30
<i>Macro Avg</i>	0,92	0,87	0,85	30
<i>Weighted Avg</i>	0,92	0,87	0,85	30

Performa model awal menunjukkan bahwa performa model yang cukup baik. Namun, model awal masih memiliki kekurangan seperti belum bisa mengklasifikasikan dengan baik terutama pada label Strong yang memiliki nilai Recall, dan F1-Score yang kurang baik. Meskipun begitu, secara keseluruhan akurasi model mencapai 87%.




Gambar 14. *Confusion Matrix Model dengan Hyperparameter Tuning*

TABEL 4.
CLASSIFICATION REPORT MODEL DENGAN HYPERPARAMETER TUNING

	Precision	Recall	F1-Score	Support
<i>Bitter</i>	1,00	1,00	1,00	6
<i>Ideal</i>	1,00	1,00	1,00	6
<i>Strong</i>	1,00	1,00	1,00	6
<i>Underdeveloped</i>	1,00	1,00	1,00	6
<i>Weak</i>	1,00	1,00	1,00	6
<i>Accuracy</i>			1,00	30
<i>Macro Avg</i>	1,00	1,00	1,00	30
<i>Weighted Avg</i>	1,00	1,00	1,00	30


Dapat diamati pada TabelTABEL 4 bahwa performa model dengan hyperparameter tuning mendapatkan hasil yang sangat baik. Model mampu meraih akurasi yang tinggi seperti halnya saat proses training sehingga tidak mengindikasikan terjadinya *overfitting*. Regularisasi juga telah diimplementasikan untuk mengurangi terjadinya *overfitting*. Kombinasi hyperparameter yang diperoleh menggunakan Random Search mungkin sudah memberikan hasil yang memuaskan. Akan tetapi, kombinasi tersebut belum tentu merupakan kombinasi terbaik yang bisa diimplementasikan pada hyperparameter terpilih mengingat Random Search hanya memilih secara acak gabungan dari beberapa hyperparameter. Adapun hasil *confusion matrix* setelah penerapan *hyperparameter tuning* dapat dilihat pada Gambar 14.

Pada bagian akhir model dievaluasi menggunakan K-Fold Cross Validation dengan K sebanyak 5. Hal ini berarti data akan dibagi menjadi 5 (lima) *fold* dan model akan diuji menggunakan data testing yang berbeda-beda pada tiap *fold*-nya. Seluruh jumlah dataset yaitu 150 (seratus lima puluh) data dan dibagi menjadi 5 (lima) *fold* yang berarti tiap *fold* terdiri dari 30 (tiga puluh) data testing. Pembagian data dilakukan menggunakan *stratify* sehingga jumlah label pada data testing sama di mana masing-masing label sebanyak 6 (enam) sehingga jumlah data testing yaitu 30 (tiga puluh) data.



Gambar 15. Cross Validation Model Awal

Dapat dilihat bahwa pada model awal, pada *fold* ke-4 akurasi model hanya mencapai 87% sedangkan pada *fold* lainnya mampu mengklasifikasikan dengan baik yaitu meraih akurasi sebesar 100%. Dengan begitu, rata-rata akurasi yang diperoleh yaitu sebesar 97%.



Gambar 16. Cross Validation Model dengan Hyperparameter Tuning

Berdasarkan Gambar 16 model hasil dari penerapan *hyperparameter tuning* mampu mengklasifikasikan *coffee brewing level* dengan baik. Model mampu memprediksi setiap label dengan tepat pada setiap *fold*. Hal tersebut menunjukkan bahwa model yang dilakukan *hyperparameter tuning* memiliki performa yang lebih unggul yang di mana memiliki rata-rata akurasi sebesar 100%.

TABEL 5.
PERBANDINGAN AKURASI DAN *RUNTIME*

	Model Awal	Hyperparameter Tuning
Rata-rata akurasi	97%	100%
Runtime	15 detik	1 menit 43 detik

Model dengan implementasi Random Search memberikan performa yang lebih baik dibandingkan model awal. Akan tetapi, terdapat *trade-off* antara performa model dan *runtime* yang dibutuhkan seperti yang disajikan pada TabelTABEL 5. Dalam implementasinya, waktu yang diperlukan oleh model awal jauh lebih sedikit. Pada model yang diterapkan *hyperparameter tuning* memerlukan waktu hingga 1 menit 43 detik yang berarti kurang lebih 6,86 kali lipat dari *runtime* model awal. Sebagai gantinya, Random Search mencari *hyperparameter* pada model yang memiliki performa lebih baik. Hasil tersebut menunjukkan bahwa performa model yang dilakukan *hyperparameter tuning* lebih baik dibandingkan model awal di mana model ini mampu meraih akurasi yang sangat tinggi. Sebab, pada implementasinya *runtime* tersebut adalah *runtime* yang dibutuhkan untuk melakukan *hyperparameter tuning* di mana model dilatih menggunakan beberapa kombinasi *hyperparameter* yang berbeda. Akan tetapi, *runtime* yang dibutuhkan oleh kedua model dalam klasifikasi hanya berselisih milidetik sehingga dianggap tidak mempengaruhi performa dalam klasifikasi.

F. Uji Coba Prototipe

Model yang telah dilatih kemudian modelnya disimpan berupa berkas model Tensorflow Lite. Hal ini bertujuan untuk meringankan komputasi yang dilakukan saat inferensi. Kemudian model di-*embed* ke dalam Raspberry PI untuk melakukan prediksi setelah menerima data spektroskopi yang diambil oleh sensor AS7265X. Sebuah sampel kopi digunakan dalam uji coba prototipe. Sampel kopi dibuat secara langsung oleh barista yang sama untuk pembuatan sampel sebelumnya.



Gambar 17. Prediksi oleh Prototipe

Hasil penelitian ini menunjukkan kinerja yang baik dalam klasifikasi *coffee brewing level* menggunakan data spektroskopi dari sensor AS7265X dan model deep learning berbasis CNN. Model awal telah menunjukkan akurasi yang tinggi, dan performanya meningkat lebih lanjut setelah dilakukan *hyperparameter tuning*, yang mengindikasikan bahwa proses optimasi parameter mampu meningkatkan kualitas prediksi secara signifikan. Implementasi model pada perangkat fisik yang terintegrasi dengan sensor AS7265X juga menunjukkan bahwa sistem dapat bekerja secara andal di lingkungan nyata. Hal ini membuktikan kompatibilitas yang kuat antara sensor spektroskopi AS7265X dengan arsitektur CNN dalam mendeteksi level penyeduhan kopi, serta membuka peluang penerapan teknologi ini dalam industri kopi untuk meningkatkan konsistensi kualitas seduhan secara otomatis.

Namun demikian, penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan. Jenis biji kopi yang digunakan dalam pengumpulan data hanya terbatas pada satu varian, sehingga generalisasi model terhadap

jenis kopi lainnya masih perlu divalidasi lebih lanjut. Selain itu, data primer yang dikumpulkan hanya berasal dari satu kedai kopi, yang menyebabkan keterbatasan dalam variasi data baik dari segi metode penyeduhan maupun kondisi lingkungan. Keterbatasan ini dapat memengaruhi kemampuan model dalam menghadapi data yang lebih beragam di luar skenario penelitian ini. Oleh karena itu, studi lanjutan dengan cakupan data yang lebih luas dan beragam sangat diperlukan untuk meningkatkan validitas model dalam konteks model yang lebih luas.

IV. SIMPULAN

Kesimpulan dari penelitian ini adalah bahwa prototipe sistem yang dikembangkan, yang menggabungkan sensor spektroskopi AS7265X dengan model deep learning berbasis *Convolutional Neural Network* (CNN), mampu mengklasifikasikan tingkat penyeduhan kopi dengan baik. Implementasi sistem secara fisik menunjukkan kinerja yang stabil dan responsif, menandakan bahwa pendekatan ini tidak hanya valid secara teoritis tetapi juga aplikatif dalam konteks dunia nyata, khususnya dalam mendukung sistem otomasi kualitas seduhan kopi. Selain itu, hasil evaluasi model menunjukkan performa klasifikasi yang sangat tinggi. Model awal berhasil mencapai akurasi sebesar 97%, dan setelah dilakukan hyperparameter tuning, akurasi meningkat menjadi 100%, menandakan bahwa optimasi parameter memiliki pengaruh signifikan terhadap peningkatan akurasi prediksi. Meskipun demikian, penelitian ini memiliki keterbatasan pada keberagaman data, karena hanya menggunakan satu jenis biji kopi dan data yang dikumpulkan dari satu kedai, sehingga generalisasi model terhadap kondisi yang lebih luas masih perlu dikaji lebih lanjut. Secara keseluruhan, penelitian ini memberikan kontribusi nyata dalam pengembangan sistem klasifikasi berbasis sensor dan deep learning, serta membuka potensi penerapan lebih luas di industri kopi dan sistem otomasi mutu minuman.

UCAPAN TERIMA KASIH

Penulis ingin mengucapkan terima kasih kepada Algorima Kopi Cafe yang berlokasi di Gandul, Depok, Jawa Barat, Indonesia atas dukungannya terhadap penelitian ini serta seluruh pihak terkait yang telah membantu keberlangsungan penelitian.

DAFTAR PUSTAKA

- [1] S. Zakiah, "Kenaikan Konsumsi Kopi Tak Dibarengi Peningkatan Produksi." <https://www.metrotvnews.com/play/NA0CjeYW-kenaikan-konsumsi-kopi-tak-dibarengi-peningkatan-produksi> (accessed Sep. 29, 2024).
- [2] I. M. S. Sayekti, "Trend Industri Kopi Masa Depan: Keberlanjutan Bisnis Hingga Keberlanjutan Lingkungan." <https://pressrelease.kontan.co.id/news/trend-industri-kopi-masa-depan-keberlanjutan-bisnis-hingga-keberlanjutan-lingkungan> (accessed Sep. 30, 2024).
- [3] M. Várady, J. Tauchen, P. Klouček, and P. Popelka, "Effects of Total Dissolved Solids, Extraction Yield, Grinding, and Method of Preparation on Antioxidant Activity in Fermented Specialty Coffee," *Fermentation*, vol. 8, no. 8, 2022, doi: 10.3390/fermentation8080375.
- [4] D. Rabbani, "Klasifikasi Beras Oplosan Berbasis Data Spektroskopi Menggunakan Deep Learning." Universitas Pembangunan Nasional 2024.
- [5] "Coffee Brewing Control Chart: Panduan Mendasar Penyeduhan Kopi - Coffeeland." <https://coffeeland.co.id/coffee-brewing-control-chart-panduan-mendasar-penyeduhan-kopi/> (accessed Aug. 22, 2024).
- [6] M. K. N. Wanhar, "Pengembangan Alat Ukur Portable untuk meprediksi Kandungan Nitrogen, Phospor, Kalium, dan Magnesium Daun Melon Menggunakan Sensor Spektroskopi Berbasis Reflektansi-Fluoresensi," Aug. 2023.
- [7] R. Raafi'udin, Y. A. Purwanto, I. S. Sitanggang, and D. A. Astuti, "Feature Selection Model Development on Near-Infrared Spectroscopy Data Case Study of Beef Freshness Quality Prediction," *Int. J. Adv. Comput. Sci. Appl.*, vol. 15, no. 1, pp. 645–653, 2024, doi: 10.14569/IJACSA.2024.0150163.
- [8] H. Z. Amanah, "Prediksi Kandungan Gula pada Kentang (*Solanum tuberosum* L.) Sehat dan Terinfeksi Cendawan *Fusarium* sp. dengan menggunakan Spektroskopi Vis-NIR Sensor Fiber Optic dan AS7265x IBNU FARRAS, Dr. Rudiati Evi Masithoh, STP., M.DT; Hanim Zahrotul Amanah, STP., M," vol. 12, no. 11, 2023, Accessed: Sep. 05, 2024. [Online]. Available: <https://etd.repository.ugm.ac.id/penelitian/detail/220125>
- [9] ams AG, "ams Datasheet AS7265x Smart 18-Channel VIS to NIR Spectral_ ID 3-Sensor Chipset with Electronic Shutter," 2020.
- [10] Y. Wang, M. Li, R. Ji, M. Wang, Y. Zhang, and L. Zheng, "Mark-Spectra: A convolutional neural network for quantitative spectral analysis overcoming spatial relationships," *Comput. Electron. Agric.*, vol. 192, p. 106624, Jan. 2022, doi: 10.1016/J.COMPA.2021.106624.
- [11] WANDB, "Understanding L1 and L2 regularization: techniques for optimized model training | ml-articles – Weights & Biases," 2024. https://wandb.ai/mostafaibrahim17/ml-articles/reports/Understanding-L1-and-L2-regularization-techniques-for-optimized-model-training--Vmlldzo3NzYwNTM5?utm_source=chatgpt.com (accessed Mar. 20, 2025).
- [12] F. Adha, H. Airi, T. Suprapti, and A. Bahtiar, "Komparasi Metode Klasifikasi Data Mining Untuk Prediksi," vol. 18, pp. 73–79, 2023.
- [13] A. I. Pradana and V. Atina, "Teknik K-Fold Cross Validation untuk Mengevaluasi Kinerja Mahasiswa," pp. 239–248, 2024, doi: 10.33364/algoritma/v.21-1.1618.
- [14] I. C. Azhari and T. Haryanto, "Modeling Of Hyperparameter Tuned RNN-LSTM and Deep Learning For Garlic Price Forecasting In Indonesia," *J. Informatics Telecommun. Eng.*, vol. 7, no. 2, pp. 502–513, 2024, doi: 10.31289/jite.v7i2.10714.
- [15] Ravi Kumar, "Grid search Vs Randomize search CV," Apr. 18, 2022. <https://medium.com/@ravikumar10593/grid-search-cv-vs-randomize-search-cv-54708be0d599> (accessed May 06, 2025).
- [16] S. Raschka, "No, We Don't Have to Choose Batch Sizes As Powers Of 2," 2022. <https://sebastianraschka.com/blog/2022/batch-size-2.html> (accessed Feb. 27, 2025).