



# Peningkatan Akurasi Model *Deep Learning* dalam Klasifikasi Kematangan Buah Kelapa Berbasis Sinyal Akustik

## *Improving the Accuracy of Deep-Learning Models for Coconut Maturity Classification Using Acoustic Signals*

Mochamad Rizki Fauji Lektriawan<sup>1)</sup>, Abdul Halim<sup>2)</sup>

<sup>1,2</sup> Teknik Elektro, Universitas Indonesia

<sup>1,2</sup> Jl. Prof. DR. Ir R Roosseno, Kukusan, Kecamatan Beji, Kota Depok, Jawa Barat 16425, Telepon: (021) 7270078

mochamad.rizki@ui.ac.id<sup>1)</sup>, a.halim@ui.ac.id<sup>2)</sup>

Diterima: 05 May 2025 || Direvisi: 30 May 2025 || Disetujui: 17 December 2025

**Abstrak** – Pada masa sekarang, perkembangan teknologi pemrosesan sinyal, sistem cerdas lanjutan dan pembelajaran *deep learning* telah menjadi hal yang umum digunakan dalam teknologi agrikultur. Salah satu komoditas agrikultur yang banyak terdapat di dunia adalah buah kelapa. Sayangnya penerapan teknologi agrikultur pasca panen sangat minim di pertanian kelapa. Selama ini para petani menentukan *maturity* buah kelapa dengan mendengar suara ketukan buah kelapa sehingga memerlukan banyak waktu untuk memeriksa tingkat *maturity*. Dalam jurnal ini akan membahas peningkatan akurasi model *deep learning* dalam klasifikasi buah kelapa berbasis sinyal akustik. Untuk uji coba klasifikasi tingkat *maturity* buah kelapa ini menggunakan metode *deep learning* yang terdiri dari *Convolutional Neural Network* (CNN) dan *Long Short-Term Memory* (LSTM). serta menggunakan dataset *open access* terdiri dari sampel yang digunakan sebesar 129 kelapa dengan tiga level klasifikasi - *premature*, *mature* dan *overmature* (Caladcad, 2023). Dalam tulisan ini mengusulkan peningkatan arsitektur model *deep learning* dengan parameter *learning rate* 0.0001, *epoch* 500, *Batch-Normalization* dan *Dropout* 0,3 dengan hasil dari uji klasifikasi sinyal akustik buah kelapa memiliki akurasi data testing sebesar 98,36% dan *F1 Score* sebesar 99%. Hasil ujicoba ini lebih baik dibandingkan ujicoba terdahulu (Caladcad, 2024) dengan hasil akurasi 97,42% dan *F1 Score* 97,20%. serta menunjukkan bahwa peningkatan metode kombinasi *deep learning* menghasilkan sistem klasifikasi kematangan kelapa yang lebih andal, dan bebas bias kelas.

**Kata Kunci:** *sinyal akustik, kelapa, CNN, LSTM*

**Abstract** – Nowadays, the development of signal processing technology, advanced intelligent systems and deep learning have become commonplace in agricultural technology. One of the agricultural commodities that are widely available in the world is coconut. Unfortunately, the application of post-harvest agricultural technology is very minimal in coconut farming. So far, farmers determine the maturity of coconuts by listening to the sound of the coconut being knocked so that it takes a lot of time to check the maturity level. This paper will discuss improving the accuracy of deep learning models in classifying coconuts based on acoustic signals. For the trial of the classification of the maturity level of coconuts, a deep learning method consisting of *Convolutional Neural Network* (CNN) and *Long Short-Term Memory* (LSTM) was used. And using an open access dataset consisting of samples used of 129 coconuts with three classification levels - *premature*, *mature* and *overmature* (Caladcad, 2023). In this paper, we propose an improvement in the deep learning model architecture with learning rate parameters of 0.0001, epoch 500, Batch-Normalization and Dropout 0.3 with the results of the coconut acoustic signal classification test having a data testing accuracy of 98.36% and an *F1 Score* of 99%. The results of this trial are better than the previous trial (Caladcad, 2024) with an accuracy of 97.42% and an *F1 Score* of 97.20%. and shows that the improvement of the deep learning combination method produces a more reliable coconut ripeness classification system, and is free from class bias.

**Keywords:** *acoustic signals, coconouts, CNN, LSTM*

## PENDAHULUAN

Buah kelapa (*Cocos nucifera*) merupakan produk pertanian yang banyak dihasilkan oleh negara-negara beriklim tropis seperti Indonesia. Buah kelapa sendiri banyak memberi manfaat bagi manusia, mulai dari air kelapa yang kaya akan vitamin dan mineral hingga daging buahnya yang bisa digunakan sebagai produk olahan di industri kimia dan farmasi (Salsabila, A.-Oktavia, A, 2022). Kebutuhan yang tinggi oleh industri inilah yang menyebabkan komoditas buah kelapa banyak ditanam oleh petani.


Selama ini para petani kelapa menggunakan metode manual dengan mendengar suara ketukan tempurung (*ridge*) kelapa untuk menentukan kondisi *maturity* buah kelapa. Cara ini cukup sulit serta membutuhkan waktu yang lama dalam mensortir kelapa (Terdwongworakul, 2009). Oleh karena itu berkembanglah riset buah kelapa yang menghasilkan tiga klasifikasi: *premature*, *mature* dan *overmature* (Gatchalian, (1994). Dalam penelitian sebelumnya yang dilakukan oleh Caladcad (2024) memanfaatkan dataset akustik berisi 129 buah kelapa dengan distribusi tidak seimbang 8:36:85 (*premature*:*mature*:*overmature*). Meskipun studi terdahulu sudah melakukan augmentasi, laporan mereka tidak menyebutkan strategi *class balancing* dan bias kelas mayoritas masih terlihat pada matriks *confusion* dengan hasil akurasi 97,42 % dan F1 mencapai 97,20 %. Riset ini memperbaiki situasi tersebut dengan augmentasi data, analisis PCA sebagai *treatment diagnostik*, dan *upgrade* parameter *deep learning* dengan pengendalian *overfitting* melalui *Batch-Normalization* dan *Dropout* sehingga akurasi naik menjadi 98,36 % dan F1 mencapai 99 %.

## METODOLOGI PENELITIAN

Dalam penelitian ini menggunakan metode dan dataset sinyal akustik kelapa yang telah dilakukan oleh Caladcad (Caladcad, 2024). Dataset ini terdiri dari 129 kelapa dan memiliki tiga kelas klasifikasi: *premature*, *mature* dan *overmature* (Caladcad, 2020). Komposisi buah kelapa terdiri dari 8 kelapa kelas *premature*, 36 kelapa kelas *mature* dan 85 kelapa kelas *overmature*. Karena jumlah kelas *overmature* paling dominan mengakibatkan terjadinya ketidakseimbangan distribusi data. Kondisi ini juga membatasi ketersediaan data yang memadai untuk fase pengujian sebelum dilakukan augmentasi data.

Augmentasi data dilakukan pada *dataset* dengan memperbanyak jumlah sampel data di tiap kelas. Proses ini berlangsung dalam tiga tahap utama: prapemrosesan, pembuatan data, dan validasi. Tahap prapemrosesan, dimulai dengan membersihkan data dari entri yang tidak lengkap atau keliru. Setelah itu, sinyal-sinyal dikombinasikan dan fitur-fitur yang relevan dipilih untuk dianalisis. Metode paling optimal adalah penjumlahan sinyal dikombinasikan dengan fitur *Mel Frequency Cepstral Coefficient* (MFCC) (Caladcad, 2024). Untuk augmentasi data yang digunakan adalah metode audimentasi sehingga akan menghasilkan lebih banyak jumlah fitur-fitur sinyal akustik kelapa. Total fitur sinyal akustik kelapa hasil augmenatsi adalah 500 sampel data per kelas. Oleh karena itu jumlah fitur-fitur data dari ketiga kelas *maturity* setelah augmentasi adalah 1500 data. Adapun pembagian data latih dan validasi adalah 80% untuk data latih dan 20% untuk data validasi.

Penggabungan sinyal penting dilakukan karena, sebagaimana dijelaskan dalam penelitian setiap sampel kelapa menghasilkan tiga sinyal—satu dari masing-masing sisi tempurung. Karena pengelompokan berdasarkan sisi tempurung tidak memungkinkan, seluruh sinyal dari semua sisi tempurung harus digabung sebelum dianalisis. Sinyal akustik hasil ekastraksi fitur MFCC akan menjadi input sinyal akustik untuk diolah model *deep learning* CNN dan LSTM dalam memprediksi kelas *maturity* kelapa sesuai tahapan ujicoba di Gambar. 1.

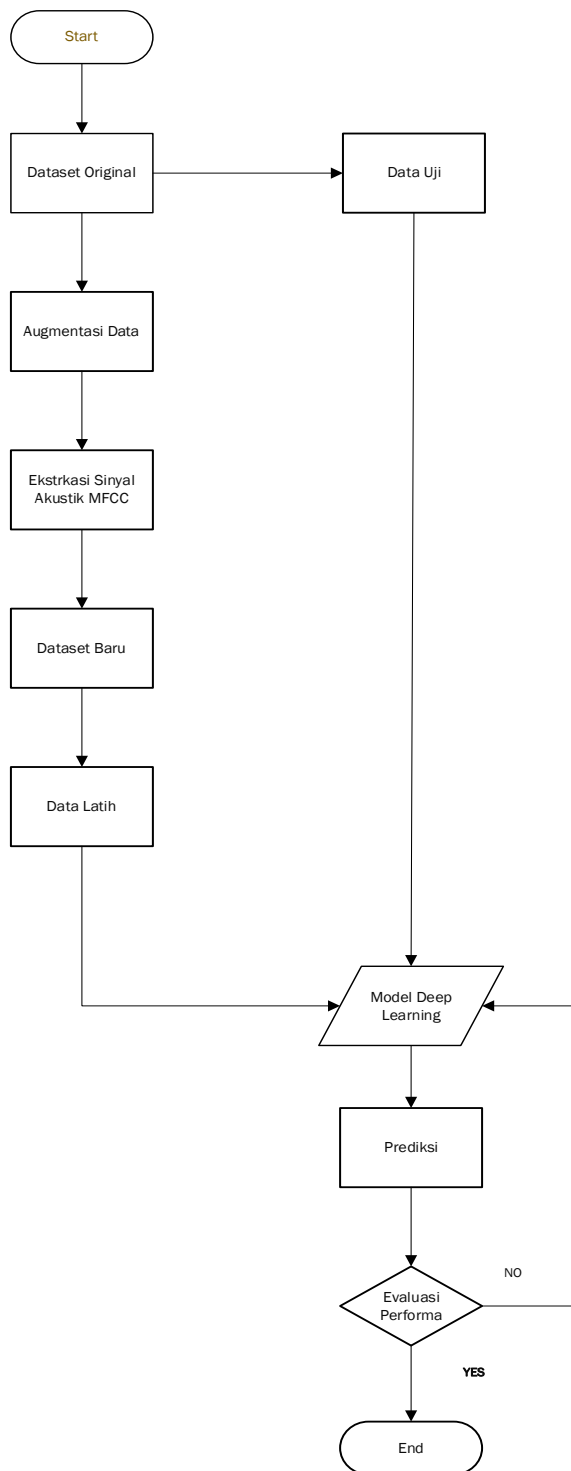


**Gambar 1** Tahapan Ujicoba Klasifikasi Sinyal Akustik Kelapa

## Perancangan Model

Tahap ini menjelaskan pemodelan sistem klasifikasi sinyal akustik kelapa menggunakan metode *deep learning*. Aplikasi yang digunakan dalam sistem adalah *Google Collab* dengan bahasa program *Python*. Model *deep learning* yang digunakan merupakan kombinasi CNN dan LSTM. Data latih dan data uji sinyal akustik kelapa yang telah diproses oleh augmentasi data dan fitur MFCC akan diolah oleh model *deep learning* dan dievaluasi hasil akurasi.

Dalam Gambar 2 menunjukkan diagram blok desain sistem model *deep learning*.



**Gambar 2** Diagram Blok Uji Coba Klasifikasi Sinyal Akustik Kelapa

Pada Gambar 2 dijelaskan tahapan dalam menjalankan ujicoba. Untuk mengolah *dataset* yang mengalami ketidakseimbangan jumlah (*imbalance class*) *dataset* kelas maka perlu menggunakan metode augmentasi data. Data original dalam augmentasi data ini mengalami kenaikan jumlah *dataset* masing-masing menjadi lima ratus *dataset* per kelas. Pada Tabel 1 akan

memperlihatkan perbandingan *dataset* original dengan *dataset* baru.

**Tabel 1** Perbandingan *Dataset* Original dan Baru

| Kelas Sinyal      | <i>Dataset</i> Original | <i>Dataset</i> Baru |
|-------------------|-------------------------|---------------------|
| Akustik Kelapa    |                         |                     |
| <i>Premature</i>  | 24                      | 500                 |
| <i>Mature</i>     | 108                     | 500                 |
| <i>Overmature</i> | 387                     | 500                 |
| Jumlah            |                         | 1500                |

Tipe augmentasi data yang digunakan yaitu metode audimentasi. Audimentasi adalah teknik augmentasi data yang digunakan untuk memodifikasi data akustik guna memperbanyak variasi tanpa mengubah makna aslinya. Metode ini sering dipakai dalam pelatihan model *deep learning* agar sistem lebih tahan terhadap kondisi nyata yang beragam. Dalam proses *preprocessing* sinyal audio, dilakukan tahap penyaringan menggunakan *frequency filter* bertipe *lowpass filter* karena dari *dataset* suara ketukan kelapa berada di frekuensi menengah (300-4000 Hz). Tujuan utama dari penggunaan *lowpass filter* ini adalah untuk menghilangkan komponen frekuensi tinggi yang tidak relevan atau *noise*, sehingga sinyal yang diproses lebih bersih dan fitur yang dihasilkan menjadi lebih representatif. Tabel 2 menjelaskan parameter audimentasi dan *frequency filter* yang digunakan dalam simulasi.

**Tabel 2** Parameter audimentasi dan *frequency filter*

| Audimentasi                      | Frekuensi Filter |
|----------------------------------|------------------|
| Gaussian Noise =                 | Sampling rate =  |
| min_amplitude=0.0001             | 132.300 Hz       |
| max_amplitude=0.001, p=0.5       |                  |
| Time Stretch = min_rate=0.995    | Cut off low pass |
| max_rate=1.005, p=0.5            | filter = 4000    |
| Pitch Shift = min_semitones=-0.1 |                  |
| max_semitones=0.1, p=0.5         |                  |
| Shift = min_shift=-0.005         |                  |
| max_shift=0.005, p=0.5           |                  |

Ekstrak fitur frekuensi yang digunakan dalam percobaan adalah MFCC. MFCC atau *Mel-Frequency Cepstral Coefficients* adalah representasi dari sinyal suara yang sering digunakan dalam pengenalan suara atau pemrosesan audio. Intinya, MFCC membantu mengubah suara menjadi angka-angka yang bisa dipahami oleh komputer. Prosesnya melibatkan beberapa tahap, mulai dari memecah sinyal menjadi potongan kecil, lalu menganalisis frekuensinya berdasarkan cara telinga manusia mendengarnya

(Abdelali Belkhou, Atman Jbari, Othmane El Badlaoui, 2021). Hasil akhirnya adalah sekumpulan nilai yang mewakili karakteristik unik dari suara tersebut.

*Deep learning* adalah metode analisis data untuk mengotomatisasi inferensi berdasarkan data historis; merupakan perluasan hierarkis mendalam dari *machine learning* (Tuan-Tang Le, 2019). Sebelum digunakan dalam proses pelatihan, data biasanya dipisahkan terlebih dahulu menjadi dua bagian utama: data untuk pelatihan dan data untuk pengujian (Caladcad, 2024). Seperti halnya pada *machine learning*, *deep learning* juga memiliki dua tahapan penting, yaitu tahap pelatihan dan tahap pengujian. Kedua proses ini sangat krusial karena menentukan seberapa baik sebuah model bisa belajar dan bekerja, baik dalam konteks *machine learning* maupun *deep learning*. Pada Tabel 3 menunjukkan parameter *deep learning* dalam uji coba.

**Tabel 3** Parameter *Deep Learning*

| Komponen | Parameter                         |
|----------|-----------------------------------|
| CNN      | nn.Conv1d(128, 128, 3, padding=1) |
|          | nn.BatchNorm1d(128)               |
|          | nn.Dropout (0.3)                  |
|          | nn.Conv1d(128, 64, 3, padding=1)  |
|          | nn.BatchNorm1d(64)                |
| LSTM     | nn.AvgPool1d (2)                  |
|          | Memori sel hidden layer = 64      |
|          | Dropout = 0.3                     |
|          | Memori sel hidden layer = 64      |
|          | Dropout = 0.3                     |
|          | Batch size = 128                  |
|          | Epoch = 500                       |
|          | Learning rate = 0.0001            |

Tipe CNN yang digunakan adalah CNN 1D. Hal ini karena CNN 1D dapat digunakan untuk memproses perbedaan spektral temporal sinyal audio (J. Salamon dan J.P.Bello, 2017). Selain itu CNN 1D dapat mengekstrak fitur-fitur data akustik melalui perhitungan konvolusi (Jielong Ni, 2023). Untuk CNN menggunakan 2 lapisan konvolusi 1 dimensi yang berurutan. Lapisan pertama terdiri dari 128 filter dengan ukuran 3 kernel serta memiliki *batch normalization* dan *dropout* bernilai 30% untuk mencegah *overfitting*. Lapisan konvolusi kedua menggunakan 64 filter dengan ukuran kernel yang sama, diikuti juga dengan *batch normalization*. Setelahnya, dilakukan average pooling dengan ukuran jendela 2, yang berfungsi mereduksi dimensi waktu

output, sekaligus menyaring *noise* dan mempertahankan fitur-fitur penting

Sedangkan LSTM digunakan karena dapat menangani data sekuensial dan deret waktu dalam satu siklus koneksi (Thomas Fischer dan Christopher Krauss, 2018). Memori data tersebut tersimpan dalam *hidden layer* LSTM. Adapun *hidden layer* LSTM terdiri dari *forget gate*, *input gate* dan *ouput gate*. Gate – gate inilah yang membuat sel memori pada LSTM untuk mengakses dan menyimpan informasi dalam jangka waktu yang panjang. Model ini memiliki 2 lapisan LSTM. Pada lapisan pertama dan kedua LSTM sama-sama memiliki 64 memori sel yang dapat menyimpan dan mengelola informasi dalam urutan waktu, dengan nilai *dropout* 30% pada input dan koneksi ulang untuk mencegah *overfitting*.

Adapun *leraning rate* yang digunakan sebesar 0.0001 dengan *batch size* sebesar 128 dan *epoch* sebanyak 500 merupakan hasil terbaik ujicoba ini dalam mencari nilai akurasi dan *F1 score* terbaik. Untuk data latih model *deep learning* menggunakan *dataset* hasil augmentasi yang telah diekstrak dengan MFCC sedangkan data uji model *deep learning* menggunakan dataset original.

### Pengujian Model

Tahapan dalam pengujian model *deep learning* sebagai berikut:


1. Input dataset ke dalam google collab.dan pastikan semua dataset terupload dengan benar.
2. Gambarkan Sinyal akustik kelapa dataset dan jumlahkan sinyal – sinyal ridge dataset tersebut.
3. Buat diagram plot dari dataset sinyal akustik kelapa baik masing–masing ridge maupun penjumlahannya menggunakan metode PCA (*Principal Component Analysis*).
4. Buat dataset baru menggunakan metode augmentasi data dan fitur ekstraksi MFCC.
5. Dataset baru diproses oleh model *deep learning* sebagai data latih sedangkan data original digunakan oleh model *deep learning* sebagai data uji klasifikasi sinyal akustik kelapa.
6. Bandingkan hasil akurasi model *deep learning* dengan model machine learning.

## HASIL DAN PEMBAHASAN


Untuk uji coba ini menggunakan aplikasi *google collab* dan Bahasa program *python*. Upload Dataset sinyal akustik kelapa dan periksa nilai sinyal tiap ridge agar tidak terdapat kolom dataset bernilai nol.

Dataset sinyal akustik kelapa ini menjadi input awal dari system dan jumlahkan sinyal data *Ridge A*, *Ridge B* dan *Ridge C* sehingga menjadi sinyal kombinasi. Banyaknya sampel yang terdapat di dataset berjumlah 129 kelapa sebagai input dari model *deep learning* dan dibuat gambar-gambar dari setiap sinyal akustik kelapa. Hal ini bertujuan agar kita bisa mencari perbedaan dari sinyal akustik kelapa di setiap kelas.


Pada Gambar 3, Gambar 4, dan Gambar 5 menunjukkan contoh sinyal akustik kelapa kelas *premature*, *mature* dan *Overmature*.



**Gambar 3** Contoh Sinyal Akustik Kelapa Kelas *Premature*



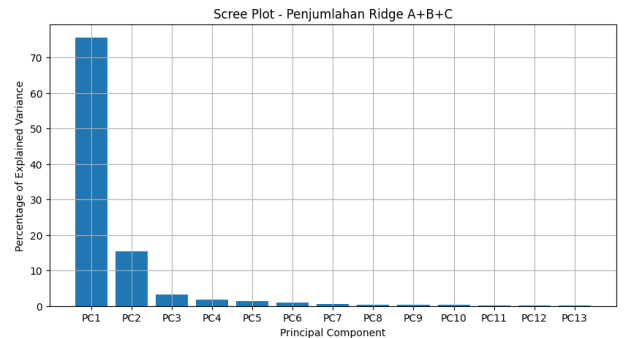
**Gambar 4** Contoh Sinyal Akustik Kelapa Kelas *Mature*



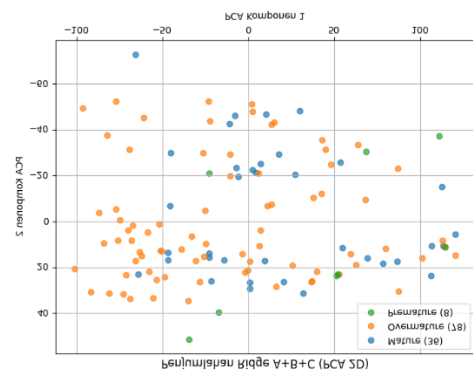
**Gambar 5** Contoh Sinyal Akustik Kelapa Kelas *Overmature*

Semua sinyal akustik kelapa diplot menggunakan metode PCA. Metode PCA (*Principal Component Analysis*) adalah sebuah teknik statistik yang bertujuan untuk mereduksi dimensi data secara linier dengan cara mengekstrak “fitur utama” (*principal components*)

yang paling menjelaskan variasi di dalam data. Untuk jumlah koefisien MFCC yang digunakan dalam ekstrak sinyal akustik kelapa adalah tiga belas (Jurafsky, 2023).



**Gambar 6** Grafik Scree Plot *Dataset* Penjumlahan Sinyal Ridge A, Ridge B, Ridge C



**Gambar 7** Diagram Plot *Dataset* Penjumlahan Sinyal Ridge A, Ridge B, Ridge C

Analisis *Principal Component Analysis* (PCA) digunakan sebanyak dua kali. Saat pra-augmentasi, PCA menampilkan sebaran fitur MFCC yang tumpang-tindih, menandakan tingginya risiko *misclassification*. Hasil scree-plot (Gambar 6) menunjukkan 95 % variansi tersebar pada 12 komponen, sedangkan scatter-plot 2D (Gambar 7) memperlihatkan dominasi kelas *overmature*. Dari plot-plot diatas menunjukkan pola *dataset* original tersebar. Hal ini mengakibatkan hasil akurasi data latih dan data uji model *deep learning* kurang bagus dan condong terhadap kelas dengan jumlah sampel terbesar (kelas mayoritas). Oleh karena itu model perlu menggunakan augmentasi data agar performanya lebih baik. Dalam augmentasi dataset ditingkatkan jumlahnya menjadi masing-masing kelas klasifikasi menjadi 500 *dataset* sehingga tercipta *dataset* baru dengan total 1500 *dataset*. Proses ekstraksi fitur sinyal akustik kelapa menggunakan MFCC dengan jumlah data *point* adalah 132.300.

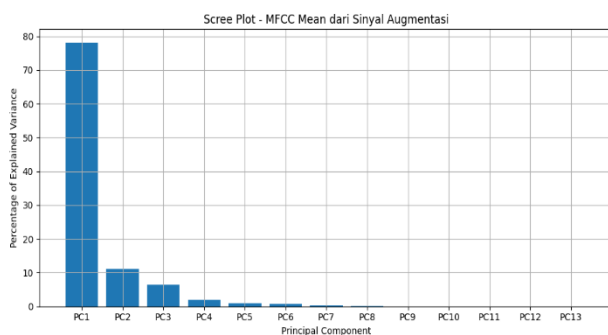
Selain itu untuk pembagian data latih dan data validasi adalah 80% data latih dan 20% data validasi. Untuk mencegah terjadinya ketidakseimbangan

distribusi maka digunakan *library stratify* dalam pembagian data latih dan data validasi. Pada Tabel 4 menjelaskan rincian setiap kelas adalah 400 *dataset* latih dan 100 *dataset* validasi.


**Tabel 4** Pembagian *Dataset* Latih dan *Dataset* Validasi

| Kelas Sinyal<br>Akustik Kelapa | <i>Dataset</i><br>Latih | <i>Dataset</i><br>Validasi |
|--------------------------------|-------------------------|----------------------------|
| Premature                      | 400                     | 100                        |
| Mature                         | 400                     | 100                        |
| Overmatur                      | 400                     | 100                        |

Selanjutnya pasca augmentasi, Gambar 8 dan Gambar 9 menegaskan konsentrasi *cluster-cluster* yang kini seimbang, tiga gugus titik yang kini terpisah jelas, masing-masing memusat di sekitar kelas *premature*, *mature*, dan *overmature* dengan jarak antar kelompok yang lebih simetris. Output *dataset* hasil augmentasi data diekstrak fituranya dengan MFCC serta dilakukan cek ulang menggunakan metode PCA. Hal ini bertujuan untuk memeriksa perbedaan *dataset* hasil augmentasi data dengan *dataset* original. Dalam Gambar 8 dan Gambar 9 menunjukkan plot hasil augmentasi data penjumlahan sinyal *ridge A*, *ridge B*, *ridge C* telah mempunyai pola plot yang terkonsentrasi. Plot hasil augmentasi data kelas *premature* berwarna hijau telah membentuk garis diagonal di area yang berdekatan sehingga model klasifikasi akan berhenti condong ke kelas mayoritas. Hal inilah yang membantu model *deep learning* dalam meningkatkan akurasi klasifikasi sinyal akustik kelapa.



**Gambar 8** Grafik Scree Plot *Dataset* Hasil Augmentasi Data Penjumlahan Sinyal *Ridge A*, *Ridge B*, *Ridge C*



**Gambar 9** Diagram Plot *Dataset* Hasil Augmentasi Data Penjumlahan Sinyal *Ridge A*, *Ridge B*, *Ridge C*

Untuk arsitektur dalam *deep learning* menggunakan metode CNN dan LSTM. Model CNN yang digunakan adalah CNN 1D karena sinyal yang diproses adalah sinyal akustik. Sedangkan model LSTM digunakan karena dapat menyimpan data sekuensial serta mempelajari pola datanya dalam memproses *dataset* berjumlah besar. Untuk data uji menggunakan *dataset* original sedangkan untuk data latih menggunakan *dataset* hasil augmentasi data. Pada Tabel 5 di bawah menunjukkan perbandingan arsitektur *deep learning klasifikasi* sinyal akustik kelapa hasil ujicoba dengan arsitektur *deep learning klasifikasi* sinyal akustik kelapa hasil percobaan sebelumnya oleh Caladcad (Caladcad, 2023).


**Tabel 5** Pembagian Komponen Arsitektur *Deep learning Ujicoba* Mandiri dan Hasil Ujicoba Oleh Caladcad (Caladcad,2024)

| Komponen | Ujicoba Mandiri   | Caladcad   |
|----------|---|--|
| CNN      | nn.Conv1d(128, 128, 3, padding=1)<br>nn.BatchNorm1d(128)<br>nn.Dropout (0.3)<br>nn.Conv1d(128, 64, 3, padding=1)<br>nn.BatchNorm1d(64)<br>nn.AvgPool1d (2)                                  | nn.Conv1d(128, 32, 3, padding=1)<br><br><br>nn.Conv1d(32, 64, 3, padding=1)<br>nn.AvgPool1d(1)                               |
| LSTM     | Memori sel <i>hidden layer</i> = 64<br>Dropout = 0.3<br>Memori sel <i>hidden layer</i> = 64<br>Dropout = 0.3<br><br><i>batch size</i> = 128<br>epoch = 500<br><i>learning rate</i> = 0.0001 | Memori sel <i>hidden layer</i> = 64<br><br><br><br><br><i>batch size</i> = 128<br>epoch = 60<br><i>learning rate</i> = 0.001 |


Dalam ujicoba ini untuk epoch model *deep learning* sebesar lima ratus sedangkan ujicoba oleh Caladcad



menggunakan epoch sebesar enam puluh. Parameter tersebut digunakan dalam percobaan agar mendapatkan hasil nilai akurasi data uji dan *F1 Score* yang lebih baik dari nilai akurasi data uji mode sebelumnya. *Epoch* dalam ujicoba ditingkatkan hingga lima ratus karena menyesuaikan dengan *learning rate* ujicoba. Jika nilai *learning rate* lebih besar dari 0.0001 maka model-model mengalami *overfitting* karena data validasi akan mirip dengan data latih. Sebaiknya jika nilai *learning rate* lebih kecil dari 0.0001 maka model akan mengalami *underfitting* karena model belum cukup mempelajari data latih. Agar simulasi dapat menyimpan model terbaik dalam simulasi ujicoba maka ditambahkan *Custom Callback*.



**Gambar 10** Matriks Confusion Model Deep learning Klasifikasi Sinyal Akustik Kelapa



**Gambar 11** Grafik Loss Pada Model Deep learning Klasifikasi Sinyal Akustik Kelapa

Gambar 10 dan Gambar 11 menjelaskan performa model *deep learning* berhasil melakukan klasifikasi sinyal akustik kelapa ke dalam tiga kategori *maturity*: *premature*, *mature*, dan *overmature*. Dataset yang digunakan terdiri dari 1.200 sampel akustik yang telah melalui proses augmentasi untuk mencapai keseimbangan antar kelas. Validasi dilakukan pada 300 sampel seimbang, sementara pengujian akhir menggunakan 122 sampel yang tidak seimbang yaitu

78 kelapa kelas *overmature*, 36 kelapa *mature*, dan 8 kelapa kelas *premature*. Dari matriks *confusion* model juga berhasil memprediksi jumlah kelapa kelas *premature* dengan tepat yaitu 8 kelapa kelas *premature* tanpa mengalami kesalahan bias terhadap kelas mayoritas.

**Tabel 6** Perbandingan Akurasi dan *F1 Score* Model Deep learning CNN & LSTM Ujicoba oleh (Caladcad, 2023) dengan Ujicoba Mandiri

| Indikator Performa    | Caladcad | Ujicoba Mandiri |
|-----------------------|----------|-----------------|
| Accuracy (%)          | 97,42    | 98,36           |
| Average precision (%) | 97,23    | 98,00           |
| Average recall (%)    | 97,32    | 99,00           |
| F1-score (%)          | 97,20    | 99,00           |

Dari Tabel 6 menunjukkan bahwa performa model *deep learning CNN* dan *LSTM* pada ujicoba menunjukkan akurasi tinggi sebesar 98,36%, dengan *F1-score* mencapai 99%. Performa ini lebih dibandingkan performa akurasi ujicoba sebelumnya (Caladcad, 2024) yaitu 97,42% dan *F1-Score* 97,20%. Hal ini terjadi karena kedalaman arsitektur model yang menggunakan dua layer *CNN 1D* yang diperkaya *batch normalization* dan *dropout* mengekstraksi ciri sinyal akustik secara stabil lalu dua lapisan *LSTM* menangkap pola temporal secara lebih komprehensif. Selain itu arsitektur *CNN 1D* dan *LSTM* efektif dalam menangkap pola temporal dari data audio. Penggunaan *batch normalization* juga membantu mencegah *overfitting* selama pelatihan.

Secara keseluruhan, makalah ini mengusulkan *upgrade* arsitektur model *deep learning* dengan parameter *learning rate* 0.0001, epoch 500, *Batch-Normalization* dan *Dropout* 0,3 yang berhasil mendorong akurasi hingga 98,36 % dan *F1-score* 99 % meningkat 1 pp (*point percentage*) dibanding baseline Caladcad (2024). Dengan kombinasi augmentasi seimbang, validasi PCA, dan desain model yang lebih dalam menghasilkan sistem klasifikasi kematangan kelapa yang lebih andal, bebas bias kelas, serta siap diintegrasikan ke perangkat inspeksi lapangan berbasis sinyal akustik *real-time*.

## KESIMPULAN

Berdasarkan hasil analisis, perancangan, dan pengujian yang telah dilakukan pada penelitian ini, maka dapat disimpulkan sebagai berikut:

1. Metode augmentasi data dalam pengolahan sinyal akustik kelapa berhasil menyeimbangkan distribusi kelas dengan menciptakan *dataset*

- baru yang memiliki jumlah yang sama tiap kelas.
2. Data latih yang digunakan adalah *dataset* baru hasil augmentasi data berjumlah 500 kelapa untuk kelas *premature*, 500 kelapa untuk kelas *mature* dan 500 kelapa untuk kelas *overmature* sedangkan data uji yang digunakan adalah *dataset original* terdiri dari 8 kelapa kelas *premature*, 36 kelapa kelas *mature* dan 85 kelapa kelas *overmature*.
  3. Berdasarkan hasil pengujian model *deep learning* CNN dan LSTM ujicoba mandiri berhasil mengklasifikasi kelas kematangan kelapa dengan nilai akurasi 98,36% dan *F1-Score* 99% dan lebih baik dibandingkan dengan model *deep learning* CNN dan LSTM ujicoba Caladcad (Caladcad,2023) yang memiliki nilai akurasi 97,42% dan *F1-Score* 97,20%.
  4. Arsitektur model *deep learning* CNN dan LSTM yang diujicobakan secara mandiri menggunakan dua layer CNN 1D yang ditambahkan *batch normalization* dan *Dropout* mengekstraksi ciri sinyal akustik secara stabil dengan dua lapisan LSTM menangkap pola temporal secara lebih komprehensif sehingga meningkatkan nilai akurasi dan F1 Score dibandingkan dengan model *deep learning* hasil ujicoba Caladcad. (Caladcad,2023).

## UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih khususnya kepada rekan-rekan mahasiswa Magister Teknik Elektro Universitas Indonesia yang telah membantu dalam hal studi dan penelitian.

## DAFTAR PUSTAKA

June Anne Caladcad, Shiela Cabahug, Mary Rose Catamco, Paul Elyson Villaceran, Leizel Cosgafa, Karl Norbert Cabizares, Marfe Hermosilla, 2020. Determining philippine coconut maturity level using machine learning algorithms based on acoustic signal. *Computers and electronics in agriculture*, 172:105327, 2020.

Salsabila, A., Oktavia, A., Dewi, F. M., Purwani, Y., Arsy, F. S., Albar, R., Priyanti, P., Khairiah, A., & Des, M. (2022). Nilai manfaat ekonomi tanaman kelapa (*Cocos nucifera* L.) di Pasar Tradisional Kemiri Muka di Kota Depok, Jawa Barat. *Prosiding SEMNAS BIO 2022, Universitas Islam Negeri (UIN) Syarif Hidayatullah Jakarta*, 242–251

Terdwongworakul, A., Chaiyapong, S., Jarimopas, B., & Meeklangsaen, W. (2009). Physical properties of fresh young Thai coconut for maturity sorting. *Biosystems Engineering*, 103(2), 208–216.

J. A. Caladcad, E. Piedad, 2024. *Deep learning* classification system for coconut maturity levels based on acoustic signals, 2024 *IEEE 12th Region 10 Humanitarian Technology Conference (R10-HTC)*, Kuala Lumpur, Malaysia, 2024, doi: 10.1109/R10-HTC59322.2024.10778826.

Jurafsky, D., & Martin, J. H. (2023). Speech and language processing (3rd ed., draft). Retrieved from <https://web.stanford.edu/~jurafsky/slp3/>

Gatchalian, M.M., De Leon, S.Y., Yano, T., 1994. Measurement of Young Coconut (*Cocos nucifera*, L.) Maturity by Sound Waves. *Journal of Food Eng.* 23, 253–276.

June Anne Caladcad., 2023. Acoustic dataset of coconut (*cocosnucifera*) based on tapping system. *Data in Brief*, 47:108936, 2023.

Tuan-Tang Le, Chyi-Yeu Lin, 2019. *Deep learning* for noninvasive classification of clustered horticultural crops—a case for banana fruit tiers. *Postharvest Biology and Technology*, 156:110922, 2019.

Abdelali Belkhou, Atman Jbari, Othmane El Badlaoui, 2021. A computer-aided-diagnosis system for neuromuscular diseases using mel frequency cepstral coefficients. *Scientific African*, 13: e00904.

J. Salamon and J. P. Bello, 2017. Deep Convolutional Neural Networks and Data Augmentation for Environmental Sound Classification, in *IEEE Signal Processing Letters*, vol. 24, no. 3, pp. 279–283, March 2017, doi: 10.1109/LSP.2017.2657381.

Jielong Ni, Zao Tang, Jia Liu, Pingliang Zeng, Chimeddorj Baldorj, 2023. A topology identification method based on one-dimensional convolutional neural network for distribution network. *Energy Reports*, 9:355–362, 2023.

Thomas Fischer, Christopher Krauss, 2018. *Deep learning* with long short-term memory networks for financial market predictions. *European journal of operational research*, 270 :654–669, 2018.