

Media Pembelajaran Pengenalan Buah (*Fruits Zone*) untuk Anak KB Menggunakan *Deep Learning*

SITI INGEFATUL KOMARIAH¹, DESTI FITRI AISYAH PUTRI², INTAN PERMATASARI³, ZILVANHISNA EMKA FITRI⁴, ERY SETIYAWAN JULLEV ATMADJI⁵, RESKI YULINA WIDIASTUTI⁶, ARIZAL MUJIBTAMALA NANDA IMRON⁷

^{1,2,3,4,5}Program Studi D4 Teknik Informatika, Politeknik Negeri Jember

⁶Program Studi S1 Pendidikan Guru Pendidikan Anak Usia Dini, Universitas Jember

⁷Program Studi D4 Teknologi Rekayasa Elektronika, Universitas Jember

Email : zilvanhisnaef@polije.ac.id

Received 6 November 2023 | Revised 1 Februari 2024 | Accepted 8 Maret 2024

ABSTRAK

Keterbatasan media pembelajaran dan metode pembelajaran yang masih terpusat pada kemampuan guru menjadi kendala bagi Pos Alamanda 105 Jumerto, Jember. Dibutuhkan sebuah media pembelajaran yang interaktif dan dapat diakses dimanapun untuk meningkatkan kemampuan siswa khususnya dalam pengenalan buah. Solusinya, peneliti mengembangkan media pembelajaran interaktif pengenalan buah pada anak usia dini. Metode yang digunakan adalah Deep Learning (CNN) dengan arsitektur yaitu Resnet18. Arsitektur Resnet-18 dipilih karena tidak menghilangkan gradien dan fitur citra meski layer yang digunakan semakin dalam, sehingga connected layer dapat mengenali objek dengan akurat. Penelitian ini menggunakan 21 jenis buah populer dan buah unik yang dilengkapi fitur suara berbahasa Indonesia dan Bahasa Inggris. Jumlah data sebanyak 2100 citra buah dengan learning rate sebesar 0.0002 dan maksimal epoch sebesar 100 mampu mengklasifikasikan buah dengan tingkat akurasi sebesar 96% (pelatihan sistem) dan 95% (pengujian sistem).

Kata Kunci: Media Pembelajaran, *Fruits Zone*, Deep Learning, ResNet18

ABSTRACT

Limitations in learning media and teaching methods that are still centered on teachers' abilities pose challenges for Pos Alamanda 105 in Jumerto, Jember. An interactive learning media accessible anywhere is needed to enhance students' abilities, especially in fruit recognition. The solution is researchers developing an interactive early childhood fruit recognition learning media. The method used is Deep Learning (CNN) with the Resnet18 architecture. Resnet-18 architecture is chosen because it preserves gradients and image features even as the layers go deeper, allowing the connected layer to accurately recognize objects. This study covers 21 popular and unique fruits with voice features in Indonesian and English. With 2100 fruit images, a learning rate of 0.0002, and a maximum epoch of 100, the system achieves a classification accuracy of 96% (training) and 95% (testing).

Keywords: Learning Media, *Fruits Zone*, Deep Learning, ResNet18

1. PENDAHULUAN

Media pembelajaran secara umum adalah alat bantu proses belajar mengajar. Selain itu, media pembelajaran juga dapat digunakan untuk merangsang pikiran, perasaan, kemampuan murid sehingga dapat mendorong terjadinya proses belajar yang lebih efektif (**Magdalena dkk., 2021**). Media pembelajaran sangat penting dalam menunjang kegiatan pembelajaran pada anak kelompok belajar karena pada masa ini anak sedang menjalani suatu proses perkembangan yang pesat. Salah satu aspek penting yang perlu dikembangkan adalah aspek kognitif. Tingkat pencapaian perkembangan anak dalam aspek perkembangan kognitif terbagi atas enam indikator, salah satunya adalah mengenal benda berdasarkan warna, bentuk, ukuran, serta fungsinya (**Sulaiman dkk., 2019**), selain itu, aspek perkembangan anak mencakup pembentukan nilai agama, moral, kognitif, bahasa, motorik, emosional, serta kemandirian (**Maghfiroh & Shofia Suryana, 2021**).


Menilai pentingnya penggunaan media dalam menunjang kegiatan belajar, Politeknik Negeri Jember telah mengembangkan sebuah media pembelajaran untuk pengenalan buah menggunakan *computer vision* yang telah diterapkan pada program pengabdian masyarakat, namun media pembelajaran tersebut dinilai kurang efektif karena algoritma cerdas yang digunakan adalah *K-Nearest Neighbor* (KNN) yang proses klasifikasinya dilakukan dengan pendekatan nilai $K=1$ pada atribut objek yang paling dekat sehingga sangat besar kemungkinan terjadi *overfitting*. Selain itu, media pembelajaran tersebut masih dijalankan pada platform desktop yang hanya dapat digunakan pada perangkat komputer atau laptop, sehingga dinilai kurang efisien (**Z. E. Fitri dkk., 2022**). Lalu dikembangkan menggunakan metode *Backpropagation*, dengan hasil akurasi 98,73 namun kelas buah yang dikenalkan hanya 11 kelas buah (**Z. E. Fitri dkk., 2024**). Menimbang kekurangan media pembelajaran terdahulu, maka peneliti melakukan pengembangan media pembelajaran dengan menerapkan *Convolutional Neural Network* (CNN) yang termasuk ke dalam *deep learning*. Algoritma CNN memiliki banyak kelebihan yang powerful terutama pada arsitektur Resnet-18. Arsitektur Resnet-18 dipilih karena tidak menghilangkan *gradien* dan fitur citra meski layer yang digunakan semakin dalam, sehingga *connectcd layer* dapat mengenali objek dengan akurat walaupun *background* pada citra beragam dan dataset yang digunakan lebih dinamis sehingga dapat menambahkan lebih banyak kelas buah (**I. Wulandari dkk., 2020**). Tujuan penelitian ini adalah mengembangkan media pembelajaran yang menerapkan CNN dengan arsitektur Resnet-18 agar mendapatkan akurasi yang tinggi. Pengembangan media pembelajaran terdahulu juga berupa penambahan beberapa fitur seperti keluaran berupa nama buah dalam bahasa Indonesia dan bahasa Inggris, serta suara penyebutan nama buah dalam bahasa Indonesia dan bahasa Inggris.

Media Pembelajaran terdahulu sudah diterapkan pada KB Nurul Kharomah Kabupaten Jember, dan berhasil mengenalkan buah dengan baik (**Sahenda dkk., 2022**). Media Pembelajaran *Fruits Zone* diterapkan di Pos PAUD Alamanda 105 yang berlokasi di Kel. Jumerto, Kec. Patrang, Kab. Jember, pemilihan lokasi didasarkan pada adanya keterbatasan sarana dan prasarana media pembelajaran pada Pos PAUD Alamanda 105 yang masih berupa poster buah-buahan dan buah imitasi sebagai perlengkapan dalam menunjang proses pembelajaran anak usia dini (**D. Fitri dkk., 2023**). Tentunya dengan adanya penerapan penggunaan Aplikasi Media Pengenalan Buah (*Fruits Zone*) pada Pos PAUD Alamanda 105 dapat membantu menunjang proses pembelajaran sehingga siswa dapat lebih mengetahui dan mengenal berbagai jenis buah yang populer maupun unik dalam bahasa Indonesia dan bahasa Inggris melihat pentingnya pembelajaran menggunakan Bahasa Inggris bagi pendidikan anak usia dini (**Na'imah, 2022**). Tiga ciri yang merupakan kelebihan media pembelajaran yang dapat membantu guru melakukan proses pembelajaran yaitu; ciri fiksatif, ciri manipulatif, ciri distributif (**A. P. Wulandari dkk., 2023**) yang merupakan alasan mengapa Pos PAUD Alamanda105 membutuhkan media pembelajaran interaktif seperti *Fruits Zone* .

Media pembelajaran pengenalan buah (fruits zone) untuk anak KB menggunakan *deep learning*

2. METODE PENELITIAN

Tahapan penelitian yang dilakukan terdiri dari pengumpulan data, pelatihan model CNN, proses klasifikasi, dan hasil klasifikasi model media pembelajaran interaktif yang dapat dilihat Gambar 1.



Gambar 1. Tahapan Proses Klasifikasi CNN

2.1 Dataset citra buah

Pengumpulan dataset gambar buah meliputi pengambilan data secara primer dan sekunder. Data citra primer diperoleh dengan mengambil gambar buah secara langsung menggunakan kamera. Adapun data sekunder diperoleh dari situs Kaggle.com. Terdapat 21 kelas buah yang akan dikenalkan pada penelitian ini, terdiri dari buah alpukat, anggur, apel, belimbing, buah naga, delima, durian, jeruk, kiwi, lemon, mangga, manggis, melon, nanas, pir, pisang, rambutan, salak, semangka, srikaya, dan strawberry. Contoh dataset gambar buah seperti pada Gambar 2.



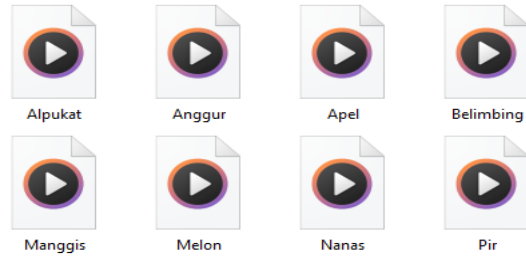
Gambar 2. Sampel Dataset Buah Alpukat

Setiap kelas buah memiliki masing-masing jumlah data 100 gambar yang terdiri dari 30 gambar primer dan 70 gambar sekunder dengan total keseluruhan dataset adalah 2.100 citra buah (Tabel 1). Proses awal yang dilakukan adalah menormalisasi ukuran citra dataset atau *resize* menjadi berukuran 224 x 224 piksel. Kemudian dataset dibagi menjadi data untuk pelatihan 85% dan data untuk pengujian 15%.

Tabel 1. Jumlah Dataset dan pembagian datanya

| Jumlah Data | | | |
|-------------|---------------|------------|----------|
| Data Primer | Data Sekunder | Data Latih | Data Uji |
| 630 | 1.470 | 1.731 | 369 |
| 2.100 | | 2.100 | |


Selain itu peneliti membuat 42 audio penyebutan nama buah baik dalam Bahasa Indonesia dan Bahasa Inggris yang dipersiapkan untuk media pembelajaran interaktif seperti pada Gambar 3.



Gambar 3. Audio Nama Buah

2.3. Convolution Neural Network


Convolutional Neural Network (CNN) merupakan metode cerdas *deep learning* yang paling sering digunakan pada pengolahan citra (Qotrunnada & Utomo, 2022). Terdiri dari layer neuron 3D, yaitu layer yang memiliki lebar, tinggi, dan kedalaman. CNN memiliki Arsitektur jaringan yang terdiri dari tahap *feature learning* dan *classification*. Convolution Layer merupakan lapisan yang melakukan proses konvolusi pada keluaran dari layer sebelumnya, yaitu antara matriks citra input dengan matriks filter (kernel) sehingga menghasilkan keluaran berupa *feature map*. Tujuan konvolusi citra yaitu untuk mengekstraksi fitur dari citra *input*. Proses Convolution Layer adalah tahap kunci dalam pengolahan gambar yang melibatkan filter (kernel) berisi bobot yang digunakan untuk mendeteksi karakter dari objek seperti tepi, kurva, atau warna gambar buah-buahan (Arrofiqoh & Harintaka, 2018) seperti pada ilustrasi operasi konvolusi (Gambar 4) menggunakan Persamaan (1) :



Gambar 4. Ilustrasi Operasi Konvolusi

$$FM[i]_{j,k} = \left(\sum_m \sum_n N_{[j-m, k-n]} F_{[m, n]} + bF \right) \quad (1)$$

Pooling Layer biasanya digunakan setelah *convolutional layer* (Muhammadiyah Jember dkk., 2022) merupakan komponen penting yang digunakan untuk mengurangi dimensi spasial dari *feature map* yang dihasilkan oleh lapisan konvolusi (Hibatullah & Maliki, 2019). Dilakukan dengan membagi *feature map* menjadi area yang lebih kecil dan mengambil nilai representatif dari setiap area, seperti nilai maksimum dalam *max pooling* (Gambar 5).



Gambar 5. Ilustrasi Proses Max Pooling

Media pembelajaran pengenalan buah (fruits zone) untuk anak KB menggunakan *deep learning*

Flatten berperan dalam mengonversi array multidimensional ke dalam bentuk vektor, sehingga memungkinkan data dari lapisan sebelumnya dapat diolah oleh lapisan *fully connected* (**Bambang Pilu Hartato, 2021**). *Flatten* juga langkah yang dilakukan setelah tahap konvolusi dan *pooling* serta bertujuan untuk mengubah tensor multidimensional hasil ekstraksi fitur menjadi vektor satu dimensi. Hal ini penting karena lapisan-lapisan berikutnya dalam jaringan saraf biasanya memerlukan input berupa vektor satu dimensi.

Fully Connected Layer bertanggung jawab atas tugas klasifikasi gambar buah ke dalam kategori yang sesuai, seperti apel, jeruk, atau pisang. Lapisan-lapisan *fully connected* ini mengambil vektor fitur yang telah diekstrak oleh *Flatten Layer* dan menghubungkannya dengan sejumlah neuron yang sesuai dengan jumlah kategori buah (**Suartika E. P, 2016**).

Softmax merupakan fungsi aktivasi yang digunakan untuk mengklasifikasikan suatu data dengan melihat nilai probabilitas tertinggi (**Qotrunnada & Utomo, 2022**). *Softmax* digunakan dalam lapisan output untuk menghitung probabilitas relatif dari setiap kelas, dan kelas dengan probabilitas tertinggi akan menjadi prediksi akhir, pada Persamaan (2).

$$Z_{ini} = \sum_{j=1}^n X_j * V_{j,i} + V_{o,i} \quad (2)$$

Pada penelitian ini arsitektur jaringan yang digunakan yaitu ResNet-18 (*Residual Network 18 layers*). ResNet-18 adalah salah satu model dalam keluarga ResNet yang dikenal dengan keunggulannya dalam mengatasi masalah vanishing gradient. Arsitektur ini terdiri dari 18 lapisan, yang mengoptimalkan ekstraksi fitur dari citra serta akan menghasilkan akurasi yang baik (**Thongpance dkk., 2023**).

2.4. Confusion Matrix

Confusion Matrix adalah suatu metode yang digunakan untuk melakukan perhitungan akurasi pada konsep data mining (**Elvin & Lubis, 2022**). *Confusion Matrix* akan mencantumkan berapa banyak buah dari setiap jenis yang berhasil diidentifikasi dengan benar (*True Positive*) dan berapa yang salah diidentifikasi (*False Positive*), serta berapa yang gagal diidentifikasi (*False Negative*) seperti pada Tabel 2. Berdasarkan ilustrasi confusion matrix tersebut, kita bisa mencari akurasi, presisi dan recall menggunakan Persamaan (3) - Persamaan(5):

$$Akurasi = \frac{A + D}{A + B + C + D} \times 100\% \quad (3)$$

$$Presisi = \frac{A}{A + C} \quad (4)$$

$$Recall = \frac{A}{A + D} \quad (5)$$

Tabel 2. Confusion Matrix

| Aktual | Klasifikasi | |
|--------|---------------------------|--------------------------|
| | + | - |
| + | <i>True Positive (A)</i> | <i>True Negatif (B)</i> |
| - | <i>False Positive (C)</i> | <i>False Negatif (D)</i> |

3. HASIL DAN PEMBAHASAN

Proses awal tahapan yaitu melakukan normalisasi ukuran citra dataset menjadi berukuran 224 x 224 piksel. Hal ini digunakan untuk mengurangi beban komputasi. Kemudian citra dataset tersebut

menjadi input dari metode klasifikasi CNN. Arsitektur jaringan yang digunakan yaitu ResNet-18 yang dijabarkan pada Tabel 3. Langkah-langkah dalam mengaplikasikan ResNet-18 untuk pengenalan buah dalam media pembelajaran sesuai dengan tabel 4. Pertama data gambar buah yang akan diinput di *resize* sehingga berukuran 224 x 224 piksel dan terdiri dari tiga saluran warna yaitu RGB (*Red, Green, Blue*) diolah dan dipersiapkan untuk pelatihan model ResNet-18. Data tersebut akan dibagi menjadi kategori buah yang berbeda sesuai dengan jenisnya.

Kemudian data melalui proses blok konvolusi layer yang berfungsi mengekstrak fitur-fitur dari gambar inputan, setiap blok terdiri dari basic blok dan blok identitas. Blok konvolusi ini dimulai dengan mengalikan gambar input dengan kernel (filter) 7x7 (64) sehingga dihasilkan output dengan ukuran 112x112 piksel yang selanjutnya akan dijadikan inputan pada layer selanjutnya. Pada blok konvolusi ke-2 inputan 112x112 piksel melalui proses perkalian dengan kernel 3x3 lalu *max pooling* sehingga didapat output berukuran 56x56 piksel.

Tabel 3. Arsitektur ResNet-18

| Layer Name | Output Size | 18-Layer |
|---------------|-------------|---|
| Conv1 | 112 x 112 | 7 x 7, 64, stride 2 |
| | | 3 x 3 max pool, stride 2 |
| Conv2_x | 56 x 56 | $\begin{bmatrix} 3 \times 3, & 64 \\ 3 \times 3, & 64 \end{bmatrix} \times 2$ |
| Conv3_x | 28 x 28 | $\begin{bmatrix} 3 \times 3, & 128 \\ 3 \times 3, & 128 \end{bmatrix} \times 2$ |
| Conv4_x | 14 x 14 | $\begin{bmatrix} 3 \times 3, & 256 \\ 3 \times 3, & 256 \end{bmatrix} \times 2$ |
| Conv5_x | 7 x 7 | $\begin{bmatrix} 3 \times 3, & 512 \\ 3 \times 3, & 512 \end{bmatrix} \times 2$ |
| Average pool, | | 1000-d fc, softmax |
| FLOOPs | | 1.8 x 10 ⁹ |

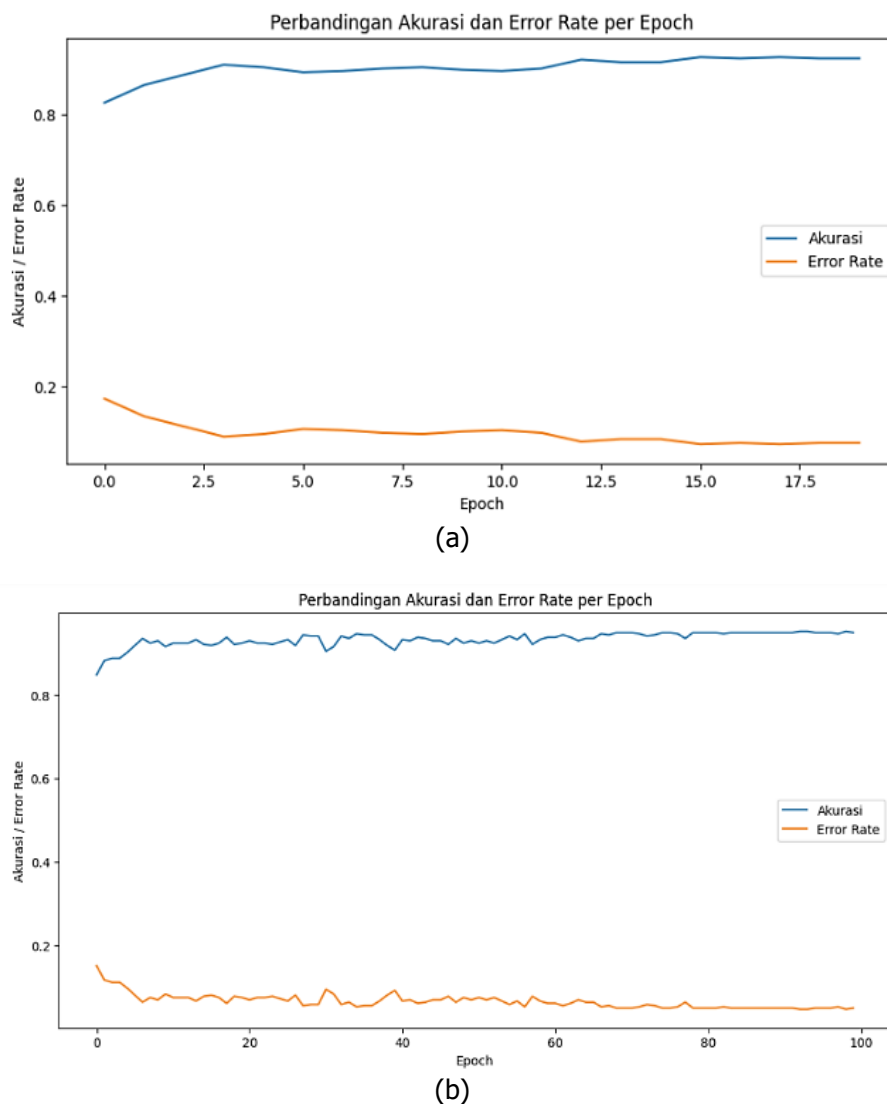
Blok konvolusi ke-3 inputan berukuran 56x56 dikalikan dengan kernel 3x3 (128) sehingga didapat output 28x28. Masuk ke blok konvolusi ke-4 dimana inputan berukuran 28x28 dikalikan kembali dengan kernel 3x3 (256) sehingga diperoleh output berukuran 14x14. Dilanjutkan blok konvolusi ke-5 dimana inputan berukuran 14x14 dikalikan dengan filter atau kernel 3x3 (512) sehingga didapat output berukuran 7x7 yang kemudian melalui proses *average pooling* untuk mendapatkan output berukuran 1x1. Lalu dilanjutkan dengan proses *flattening*. Pada proses *flattening*, data yang masih bernilai array multidimensi selanjutnya akan diubah menjadi sebuah vektor agar dapat diproses pada *fully connected layer* karena pada *fully connected layer* terjadi proses klasifikasi jenis buah yang didapat, seperti apel atau pisang.

Proses terakhir adalah *Softmax*, dimana dalam konteks pengenalan buah, *softmax* memungkinkan model untuk mengeluarkan hasil yang menunjukkan sejauh mana gambar tersebut cocok dengan setiap jenis buah, yang sangat berguna dalam mengklasifikasikan gambar-gambar berdasarkan jenis buahnya. Misalnya, jika gambar mengandung sebuah apel, *softmax* akan menghasilkan probabilitas yang lebih tinggi untuk kelas "apel" dibandingkan dengan kelas-kelas lain seperti

Media pembelajaran pengenalan buah (fruits zone) untuk anak KB menggunakan *deep learning*

"jeruk" atau "pisang". Hal ini memungkinkan sistem untuk memberikan prediksi akhir yang paling mungkin, yang kemudian dapat digunakan untuk mengklasifikasikan buah dalam gambar. Dengan demikian, *softmax* adalah langkah terakhir dalam proses pengenalan buah yang memungkinkan model CNN untuk menghasilkan hasil yang lebih terstruktur.

Pada proses perancangan model dilakukan penentuan banyaknya *epoch* yang akan digunakan, *epoch* ini merupakan proses pengulangan CNN dalam mempelajari seluruh dataset. Peneliti mencoba melakukan perancangan model menggunakan maksimal *epoch* 20 dan *epoch* 100 lalu akan membandingkannya untuk mengetahui hasil yang terbaik jika *learning rate* yang digunakan adalah 0.0002. Grafik dapat dilihat pada Gambar 6.



Gambar 6. (a) Grafik Epoch 20 dengan Learning rate 0.0002 dan (b) Epoch 100 dengan Learning rate 0.0002

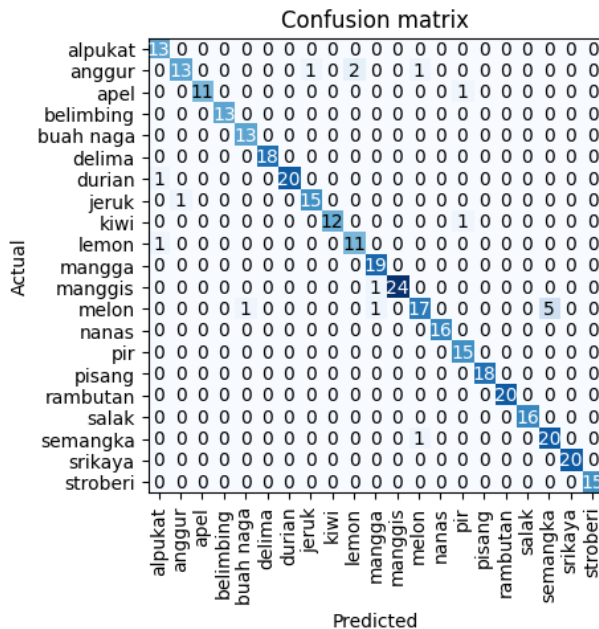
Gambar 6 menunjukkan grafik model menggunakan *learning rate* 0.0002 namun *epoch* yang digunakan berbeda yaitu *epoch* 20 dan *epoch* 100. Pada *epoch* 20, nilai akurasi cenderung naik dan *error rate* cenderung menurun secara stabil dengan nilai akhir akurasi sebesar 92% dan nilai *error rate* sebesar 0.7. kemudian saat menggunakan *epoch* 100 hasil yang diperoleh hampir sama yaitu nilai akurasi meningkat hingga mencapai nilai akhir sebesar 95% dengan nilai *error rate* yang menurun hingga 0.5 . Berdasarkan hal tersebut dapat disimpulkan bahwa pada penelitian ini menggunakan *learning rate* 0.0002 lebih baik menggunakan *epoch* 100 karena hasil yang

didapatkan lebih baik. Hasil pelatihan dan validasi seluruh *epoch* terhadap akurasi dapat dilihat pada Tabel 4.

Tabel 4. Hasil Pelatihan Model Menggunakan Epoch 100

| Epoch | Train Loss | Valid Loss | Akurasi | Error Rate | Time |
|-------|------------|------------|----------|------------|-------|
| 10 | 0.500841 | 0.291809 | 0.915966 | 0.084034 | 01:22 |
| 20 | 0.289420 | 0.294542 | 0.924370 | 0.075630 | 01:19 |
| 30 | 0.243133 | 0.371901 | 0.941176 | 0.058824 | 01:20 |
| 40 | 0.197710 | 0.358979 | 0.907563 | 0.092437 | 01:25 |
| 50 | 0.139993 | 0.340635 | 0.929972 | 0.070028 | 01:23 |
| 60 | 0.118484 | 0.309995 | 0.938375 | 0.061625 | 01:24 |
| 70 | 0.085669 | 0.302909 | 0.949580 | 0.050420 | 01:25 |
| 80 | 0.073428 | 0.315439 | 0.949580 | 0.050420 | 01:26 |
| 90 | 0.064818 | 0.312708 | 0.949580 | 0.050420 | 01:26 |
| 100 | 0.062231 | 0.309757 | 0.959580 | 0.050420 | 01:26 |

Berdasarkan Tabel 4, pada *epoch* ke-10 akurasi sistem 91,59% kemudian akurasi tersebut naik seiring pertambahan jumlah *epoch* sehingga pada *epoch* ke-100 sistem menghasilkan nilai akurasi tertinggi yaitu 95,95% atau 96% dengan nilai *error rate* sebesar 0.5. Hal tersebut juga berlaku pada nilai *error rate* contohnya pada *epoch* ke-40, didapatkan *error rate* sebesar 0.9% kemudian mulai menurun hingga mencapai nilai stabil sebesar 0.5% pada *epoch* ke-70 hingga *epoch* ke-100. Hal ini menunjukkan bahwa semakin banyak *epoch* yang digunakan, nilai akurasi cenderung semakin tinggi dan *error rate* yang semakin menurun. Hal tersebut dikarenakan semakin banyak data yang dilatih secara berulang ulang sehingga sistem dapat mengenali pola dari objek buah tersebut. Setelah proses pelatihan dilakukan proses pengujian dengan total data uji sebanyak 369 data citra buah. Hasil pengujian dihitung menggunakan *confusion matrix* untuk mengetahui kemampuan model dalam melakukan klasifikasi jenis buah (Gambar 7).



Gambar 7. Pengujian Confusion Matrix

Selanjutnya perhitungan menggunakan Micro F1 dimana nilai TP = 339 ; FP = 18 ; FN = 18. Perhitungan ini menghitung metrik secara global berdasarkan nilai TP total, FP total dan FN total pada model maka:

Media pembelajaran pengenalan buah (fruits zone) untuk anak KB menggunakan *deep learning*

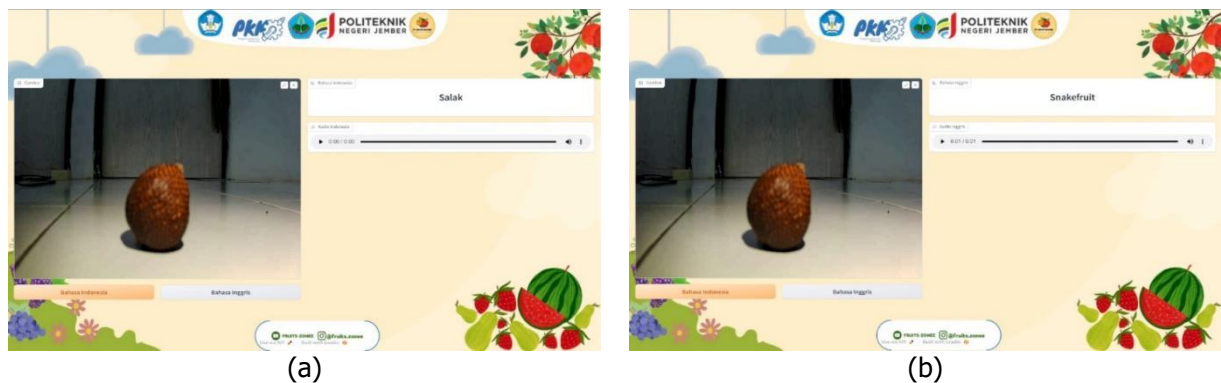
$$Presisi = \frac{TP}{TP + FP} = \frac{339}{339 + 18} = \frac{339}{357} = 0.9495 = 0.95$$

$$Recall = \frac{TP}{TP + FN} = \frac{339}{339 + 18} = \frac{339}{357} = 0.95$$

Pada perhitungan Micro F1 umumnya nilai presisi = recall = akurasi, maka:

$$Akurasi\ Pengujian = \frac{339}{357} \times 100\% = 95\%$$

Berdasarkan perhitungan diatas, sistem mendapatkan tingkat akurasi pengujian sebesar 95%, Presisi 95%, dan *Recall* 95%. Berdasarkan hasil pengujian terdapat 18 data citra buah yang misklasifikasi. Contohnya pada kelas melon, total data uji sebanyak 24 citra namun sistem hanya mampu mengklasifikasikan dengan benar sesuai target sebanyak 17 citra sedangkan 9 citra diklasifikasikan menjadi kelas lain (1 citra sebagai buah naga, 1 citra sebagai buah manggis dan 5 citra sebagai buah semangka). Sedangkan pada buah semangka sendiri dari 21 data uji, hanya 1 data citra yang diklasifikasikan salah menjadi kelas buah melon. Kesalahan klasifikasi pada sistem di karenakan citra buah tersebut memiliki kemiripan baik dari warna atau bentuk dengan citra buah lain sehingga hal tersebut mengakibatkan sistem salah mengklasifikasikan. Hasil tampilan media pembelajaran pengenalan buah (*Fruit Zone*) untuk anak kelompok belajar ditunjukkan pada Gambar 8.



Gambar 8. (a) Tampilan *Fruits Zone* dalam Bahasa Indonesia dan (b) Tampilan *Fruits Zone* dalam Bahasa Inggris

Gambar 8 menunjukkan bahwa Media pembelajaran pengenalan buah (*Fruits Zone*) kami untuk anak kelompok belajar dikembangkan berbasis website yang memberikan keluaran berupa tulisan nama buah dan audio penyebutan nama buah baik dalam Bahasa Indonesia maupun Bahasa Inggris sehingga membantu siswa KB untuk mengenal buah. Aplikasi kami juga telah diimplementasikan ke Pos PAUD Alamanda 105 yang bertempat di Desa Jumerto, Kecamatan Patrang (Gambar 9).



Gambar 9. Dokumentasi kegiatan pengujian

4. KESIMPULAN

Berdasarkan hasil penelitian, penerapan *deep learning* pada media pembelajaran pengenalan buah untuk anak kelompok belajar menggunakan *convolutional neural network* dengan arsitektur Resnet-18 merupakan solusi yang efektif untuk mengenalkan buah pada anak usia dini di Pos PAUD Alamanda 105. Jumlah data sebanyak 2100 citra buah dengan *learning rate* sebesar 0.0002 dan maksimal *epoch* sebesar 100 mampu mengklasifikasikan buah dengan tingkat akurasi pelatihan sebesar 96% dan akurasi pengujian sebesar 95% menunjukkan bahwa media pembelajaran memiliki *performance* yang baik. Namun perlu adanya pengembangan lebih lanjut pada media pembelajaran *Fruits Zone*, termasuk untuk menambahkan jumlah data dan kelas buah agar lebih beragam.

UCAPAN TERIMA KASIH

Terima kasih kepada Kementerian Pendidikan, Kebudayaan, Riset, Dan Teknologi Republik Indonesia, khususnya Direktorat Jenderal Pendidikan Vokasi yang mendanai kami dalam program Program Kreativitas Mahasiswa Karya Inovatif (PKM KI). Serta kami sampaikan terima kasih kepada Politeknik Negeri Jember beserta pembimbing dan pakar ahli dari Universitas Jember.

DAFTAR RUJUKAN

- Arrofiqoh, E. N., & Harintaka, H. 2018. Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi. *Geomatika*, 24(2), 61. <https://doi.org/10.24895/jig.2018.24-2.810>
- Bambang Pulu Hartato. 2021. Penerapan Convolutional Neural Network pada Citra Rontgen Paru-Paru untuk Deteksi SARS-CoV-2. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 5(4), 747–759. <https://doi.org/10.29207/resti.v5i4.3153>
- Elvin, E., & Lubis, C. 2022. Klasifikasi Citra Ikan Menggunakan Convolutional Neural Network. *Jurnal Ilmu Komputer dan Sistem Informasi*, 10(1). <https://doi.org/10.24912/jiksi.v10i1.17827>
- Fitri, D., Putri, A., Komariah, S. I., Permatasari, I., Fitri, E., Mujibtamala, A., & Imron, N. 2023. *Peningkatan Kemampuan Berbahasa Inggris pada Anak Usia Dini Melalui Media Pembelajaran Fruits Zone di Pos Paud Alamanda 105 Kabupaten Jember*. 1(10), 2621–2630.

Media pembelajaran pengenalan buah (fruits zone) untuk anak KB menggunakan *deep learning*

- Fitri, Z. E., Komariah, S. I., Sahenda, L. N., Phoa, V., Widiastuti, R. Y., Mujibtamala, A., & Imron, N. 2024. *Interactive Learning Media for Fruit Recognition in Early Childhood Using Backpropagation*. 2–8. <https://doi.org/10.4108/eai.18-11-2023.2342565>
- Fitri, Z. E., Sahenda, L. N., Oktaviari, R., Putra, P., Zulkarnain, M. I., Triasasti, A. A., & Mustofa, Z. A. 2022. *Attractive Learning Media for Introduction to Popular Fruits Using Computer Vision*. 14–19.
- Hibatullah, A., & Maliki, I. 2019. *Penerapan Metode Convolutional Neural Network Pada Pengenalan Pola Citra Sandi Rumput*. 1–8.
- Magdalena, I., Fatakhatus Shodikoh, A., Pebrianti, A. R., Jannah, A. W., Susilawati, I., & Tangerang, U. M. 2021. Pentingnya Media Pembelajaran Untuk Meningkatkan Minat Belajar Siswa Sdn Meruya Selatan 06 Pagi. *EDISI: Jurnal Edukasi dan Sains*, 3(2), 312–325.
- Maghfiroh, & Shofia Suryana, D. 2021. Pembelajaran di Pendidikan Anak Usia Dini. *Jurnal Pendidikan Tambusai*, 05(01), 1561.
- Muhamammadiyah Jember, U., Rizki Ramadhani, I., & Nilogiri, A. 2022. Klasifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network Classification Of Plants Based On Leaf Image Using Convolutional Neural Network Method. *Jurnal Smart Teknologi*, 3(3), 2774–1702.
- Na'imah, N. 2022. Urgensi Bahasa Inggris Dikembangkan Sejak Anak Usia Dini. *Jurnal Obsesi: Jurnal Pendidikan Anak Usia Dini*, 6(4), 2564–2572. <https://doi.org/10.31004/obsesi.v6i4.1916>
- Qotrunnada, F. M., & Utomo, P. H. 2022. Metode Convolutional Neural Network untuk Klasifikasi Wajah Bermasker. *Prisma*, 5, 799–807.
- Sahenda, L. N., Fitri, Z. E., Choirunnisa, S., & Ardi, P. 2022. *Game Edukasi Populer Fruit Bilingual sebagai Media Pembelajaran Anak Usia Dini di KB Nurul Kharomah Kabupaten Jember*. 20–25.
- Suartika E. P, I. W. 2016. Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) Pada Caltech 101Dewa, C. K., Fadhilah, A. L., & Afiahayati, A. (2018). Convolutional Neural Networks for Handwritten Javanese Character Recognition. *IJCCS (Indonesian Journal of Computing an. Jurnal Teknik ITS*, 5(1), 76.
- Sulaiman, U., Ardianti, N., & Selviana, S. 2019. Tingkat Pencapaian Pada Aspek Perkembangan Anak Usia Dini 5-6 Tahun Berdasarkan Strandar Nasional Pendidikan Anak Usia Dini. *NANAEKE: Indonesian Journal of Early Childhood Education*, 2(1), 52. <https://doi.org/10.24252/nananeke.v2i1.9385>
- Thongpance, N., Dangyai, P., Roongprasert, K., & Wongkamhang, A. 2023. *Exploring ResNet-18 Estimation Design through Multiple Implementation Iterations and Techniques in Legacy Databases*. 4(5), 650–661. <https://doi.org/10.18196/jrc.v4i5.19589>

- Wulandari, A. P., Salsabila, A. A., Cahyani, K., Nurazizah, T. S., & Ulfiah, Z. 2023. Pentingnya Media Pembelajaran dalam Proses Belajar Mengajar. *Journal on Education*, 5(2), 3928–3936. <https://doi.org/10.31004/joe.v5i2.1074>
- Wulandari, I., Yasin, H., & Widiharih, T. 2020. Klasifikasi Citra Digital Bumbu Dan Rempah Dengan Algoritma Convolutional Neural Network (Cnn). *Jurnal Gaussian*, 9(3), 273–282. <https://doi.org/10.14710/j.gauss.v9i3.27416>