



Implementasi Metode CNN Untuk Klasifikasi Status Stunting Pada Balita

Syariful Abrori^{1*}, Zaehol Fatah²

¹ Teknologi Informasi, Universitas Ibrahimy, Indonesia

² Sistem Informasi, Universitas Ibrahimy, Indonesia

^{1*} syarifulabrori2307@gmail.com ^{2*} zaeholfatah@gmail.com

Abstrak

Stunting pada balita merupakan permasalahan kesehatan masyarakat yang serius dan memerlukan penanganan segera melalui deteksi dini yang akurat. CNN (Convolutional Neural Network) merupakan metode yang akurat, efektif dan tepat sasaran dalam memberikan hasil yang akurat dan presisi. Implementasi metode CNN dapat mengklasifikasikan status stunting pada balita berdasarkan parameter antropometri dan karakteristik kesehatan. Dataset yang digunakan terdiri dari 6.500 sampel data balita dengan 8 variabel meliputi jenis kelamin, usia, berat lahir, panjang lahir, berat badan, panjang badan, riwayat ASI eksklusif, dan status stunting. Metodologi yang digunakan melibatkan serangkaian tahapan preprocessing data termasuk standardisasi fitur menggunakan StandardScaler, pemisahan data training (80%) dan testing (20%), serta penggunaan arsitektur CNN yang terdiri dari layer konvolusi 1D dengan 32 filter, max pooling, dan dense layer. Model dilatih menggunakan optimizer Adam dengan fungsi loss categorical crossentropy selama 10 epoch dan batch size 32. Evaluasi performa model dilakukan menggunakan berbagai metrik termasuk accuracy, precision, recall, dan F1-score.

Hasil penelitian menunjukkan bahwa model CNN yang dikembangkan mencapai performa yang sangat baik dengan akurasi 90%, precision 89%, recall 92%, dan F1-score 91%. Analisis confusion matrix mengkonfirmasi kemampuan model dalam mengklasifikasikan kedua kelas yaitu pada stunting dan non-stunting secara seimbang. Temuan ini mengindikasikan bahwa implementasi CNN efektif dalam mengidentifikasi status stunting pada balita dan berpotensi menjadi alat bantu yang berharga dalam screening stunting di fasilitas kesehatan.

Kata Kunci: Stunting, Convolutional Neural Network, Deep Learning, Klasifikasi

PENDAHULUAN

Stunting merupakan salah satu masalah gizi kronis yang masih menjadi tantangan serius di berbagai negara berkembang, termasuk Indonesia. Kondisi ini ditandai dengan gangguan pertumbuhan pada anak balita yang menyebabkan tinggi badan tidak sesuai dengan usianya, akibat kekurangan gizi dalam jangka panjang. Dampak stunting bersifat multidimensi, tidak hanya mempengaruhi pertumbuhan fisik, tetapi juga berdampak signifikan terhadap perkembangan kognitif, sistem kekebalan tubuh, dan produktivitas ekonomi di masa dewasa. Fenomena stunting mencerminkan kompleksitas masalah kesehatan masyarakat yang melibatkan berbagai faktor, termasuk nutrisi, sanitasi, akses layanan kesehatan, dan kondisi sosial ekonomi (Lonang & Normawati, 2022).

Stunting merupakan kondisi gangguan pertumbuhan fisik pada balita yang disebabkan oleh kekurangan gizi kronis atau berkepanjangan. Dampak stunting tidak hanya terbatas pada aspek fisik, tetapi juga memiliki konsekuensi luas dan signifikan terhadap perkembangan anak secara menyeluruh. Penelitian terkini menunjukkan bahwa stunting dapat mempengaruhi kondisi psikologis anak, termasuk menurunnya kepercayaan diri dan harga diri, yang pada gilirannya dapat mengganggu interaksi sosial anak dengan lingkungannya (Yuliana & Hakim W, 2019). Lebih lanjut, stunting berdampak negatif terhadap kemampuan kognitif, perkembangan motorik, dan meningkatkan risiko penyakit kronis di masa depan. Pada masa dewasa, individu yang mengalami stunting di masa kecil cenderung memiliki tingkat kecerdasan yang lebih rendah, prestasi akademik yang kurang optimal, serta produktivitas kerja yang lebih rendah (Jalil et al., 2024).

Seiring dengan pesatnya perkembangan teknologi, metode kecerdasan buatan, khususnya deep learning, telah menunjukkan efektivitas yang luar biasa dalam berbagai bidang, termasuk kesehatan. Convolutional Neural Network (CNN), sebagai salah satu arsitektur deep learning yang unggul, telah membuktikan potensinya yang besar dalam tugas-tugas klasifikasi dan pengenalan pola kompleks. Keunggulan CNN terletak pada kemampuannya untuk secara otomatis mengekstraksi fitur-fitur penting dari data input, terutama data visual. Dalam konteks medis, CNN telah berhasil diterapkan dalam berbagai aplikasi, mulai dari analisis citra radiologi, deteksi penyakit, hingga klasifikasi status kesehatan berdasarkan data antropometri (Arhami, 2024). Implementasi CNN dalam bidang kesehatan tidak hanya meningkatkan akurasi diagnostik, tetapi juga berpotensi mengoptimalkan alokasi sumber daya kesehatan dan mempercepat proses pengambilan keputusan klinis.

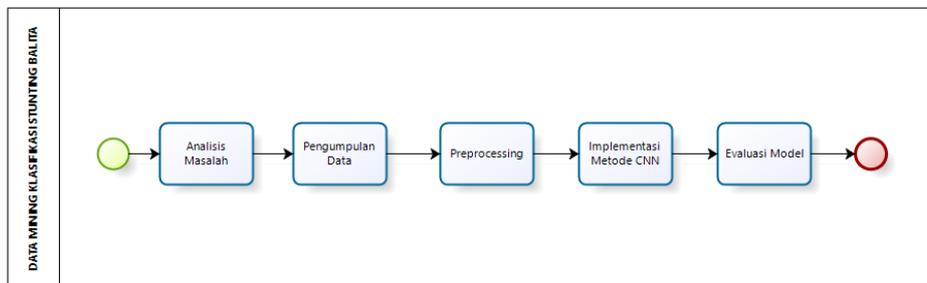
Penelitian ini bertujuan untuk mengimplementasikan metode Convolutional Neural Network (CNN) dalam klasifikasi status stunting pada balita, yang merupakan bagian dari upaya global untuk mengatasi masalah gizi kronis pada anak-anak. Dengan memanfaatkan kombinasi data antropometri dan citra medis, pendekatan ini diharapkan dapat menghasilkan model klasifikasi yang memiliki akurasi tinggi dan kemampuan generalisasi yang baik. Implementasi CNN dalam konteks ini tidak hanya bertujuan untuk meningkatkan presisi diagnosis, tetapi juga untuk mengoptimalkan proses skrining stunting di berbagai setting kesehatan, mulai dari fasilitas kesehatan primer hingga rumah sakit rujukan. Pengembangan model berbasis deep learning ini diharapkan dapat menjadi alat pendukung keputusan yang efektif bagi tenaga kesehatan, memungkinkan deteksi dini dan intervensi yang lebih tepat sasaran dalam penanganan stunting (Batubara & Awangga, 2020).

Pendekatan berbasis Convolutional Neural Network (CNN) memiliki keunggulan signifikan dalam kemampuannya untuk mengekstraksi fitur secara otomatis dari data input yang kompleks. Karakteristik ini memungkinkan CNN untuk menangkap pola-pola halus dan interdependensi antar variabel yang mungkin sulit dideteksi oleh metode konvensional, sehingga berpotensi meningkatkan akurasi klasifikasi secara substansial. Lebih lanjut, pemanfaatan teknik transfer learning membuka peluang untuk mengoptimalkan model pada kasus-kasus spesifik seperti stunting, bahkan dalam kondisi keterbatasan data (Wiliani et al., 2023). Pendekatan ini memungkinkan model untuk memanfaatkan pengetahuan yang diperoleh dari dataset besar dan ditransfer ke domain target, mengatasi tantangan kelangkaan data yang sering dihadapi dalam penelitian kesehatan di berbagai negara berkembang. Dengan demikian, integrasi CNN dan transfer learning tidak hanya meningkatkan performa model, tetapi juga memperluas aplikabilitasnya dalam konteks global, memungkinkan adaptasi model untuk berbagai populasi dan setting kesehatan yang berbeda.

METODE

Tahapan Penelitian

Penelitian ini mengadopsi pendekatan sistematis dalam mengimplementasikan metode Convolutional Neural Network (CNN) untuk klasifikasi status stunting pada balita. Alur penelitian terdiri dari lima tahap utama: pengumpulan data, preprocessing, data mining, evaluasi model. Tahap pertama melibatkan pengumpulan data komprehensif yang mencakup informasi antropometri balita, riwayat kesehatan, pola makan, dan faktor sosio-ekonomi yang relevan. Data ini diperoleh dari berbagai sumber terpercaya, termasuk rekam medis dan survei kesehatan nasional (Alrasyid et al., 2024). Selanjutnya, data melalui tahap preprocessing yang meliputi pembersihan data, penanganan missing values, normalisasi, dan pemilihan fitur. Proses ini penting untuk memastikan kualitas dan konsistensi data yang akan digunakan dalam analisis selanjutnya.



Gambar 1. Tahapan Penelitian

Pada tahap data mining, metode CNN diimplementasikan untuk membangun model klasifikasi stunting. Arsitektur CNN dirancang secara khusus untuk mengoptimalkan ekstraksi fitur dari data antropometri dan faktor-faktor terkait stunting. Proses pelatihan model melibatkan optimisasi hyperparameter untuk meningkatkan akurasi prediksi. Setelah model dilatih, tahap evaluasi dilakukan menggunakan metrik-metrik seperti akurasi, presisi, recall, dan F1-score untuk mengukur kinerja model secara komprehensif. Aplikasi ini dirancang untuk memberikan antarmuka yang user-friendly, memungkinkan tenaga kesehatan atau peneliti untuk memasukkan data balita dan mendapatkan prediksi status stunting secara real-time (Dkk, 2016). Pendekatan ini tidak hanya meningkatkan aksesibilitas model prediktif stunting, tetapi juga berpotensi untuk mempercepat proses skrining dan intervensi dini dalam penanganan stunting di Indonesia.

Pengumpulan Data

Proses pengumpulan data dalam penelitian ini dilakukan secara sistematis dengan mengumpulkan informasi kesehatan balita yang mencakup berbagai parameter pertumbuhan dan karakteristik demografis. Data diperoleh dari rekam medis dan pemeriksaan rutin balita di berbagai fasilitas kesehatan, termasuk Puskesmas, Posyandu, dan klinik kesehatan anak di wilayah penelitian. Total sampel yang berhasil dikumpulkan adalah 6500 data balita, yang mewakili populasi dengan berbagai karakteristik sosio-demografis. Dalam proses pengumpulan data, beberapa parameter kunci diukur dan dicatat dengan teliti. Pengukuran antropometri meliputi pengambilan data berat badan menggunakan timbangan digital yang terkalibrasi, serta pengukuran panjang/tinggi badan menggunakan alat ukur standar sesuai dengan prosedur WHO

(World Health Organization). Data historis seperti berat lahir dan panjang lahir diperoleh dari catatan medis atau buku KIA (Kesehatan Ibu dan Anak)(L. Tri Wijaya Nata K., 2016). Informasi tentang pemberian ASI eksklusif dikumpulkan melalui wawancara terstruktur dengan orang tua atau pengasuh balita.

Untuk menjamin kualitas data, proses pengumpulan dilakukan oleh tenaga kesehatan terlatih yang telah mendapatkan standardisasi dalam pengukuran antropometri. Setiap pengukuran dilakukan dua kali untuk memastikan akurasi, dan jika terdapat perbedaan signifikan, dilakukan pengukuran ketiga. Data yang dikumpulkan kemudian melalui proses verifikasi untuk memastikan kelengkapan dan konsistensi informasi. Kasus dengan data yang tidak lengkap atau mencurigakan divalidasi ulang atau dieksklusi dari dataset.

HASIL DAN PEMBAHASAN

Pada bagian ini berisi hasil dan pembahasan dari topik penelitian, yang bisa di buat terlebih dahulu metodologi penelitian. Bagian ini juga merepresentasikan penjelasan yang berupa penjelasan, gambar, tabel dan lainnya. Banyaknya kata pada bagian ini berkisar.

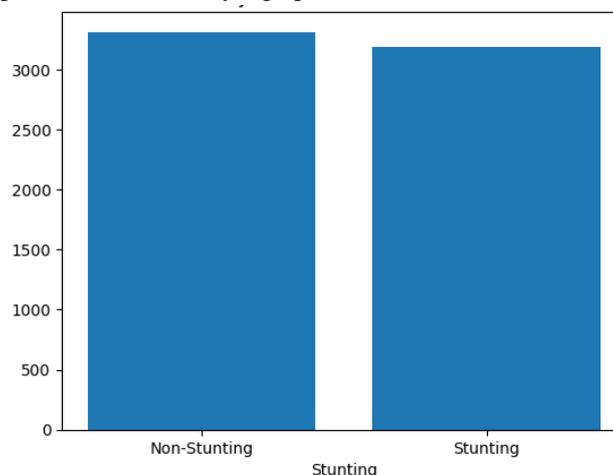
Dataset Stunting

Dataset yang digunakan dalam penelitian ini merupakan kumpulan data status stunting pada balita yang terdiri dari 6500 sampel dengan 8 variabel atau fitur. Dataset ini mencakup berbagai parameter pertumbuhan dan karakteristik balita yang berpotensi mempengaruhi status stunting. Variabel-variabel tersebut meliputi jenis kelamin (Sex) yang dikodekan secara biner, usia balita yang diukur dalam satuan bulan (Age), serta parameter antropometri saat lahir yang terdiri dari berat lahir (Birth_Weight) dan panjang lahir (Birth_Length). Selain itu, dataset juga mencakup pengukuran terkini berupa berat badan (Body_Weight) dan panjang badan (Body_Length) balita. Riwayat pemberian ASI Eksklusif juga dimasukkan sebagai salah satu variabel penting yang dicatat dalam bentuk data biner.

Tabel 1. Head Database Stunting Balita

Sex	Age	Birth_Weight	Birth_Length	Body_Weight	Body_Length	ASI_Eksklusif	Stunting
0	56	2,9	50	11	90	1	No
0	20	3,3	49	11,1	80,5	0	No
1	4	2,8	48	6,5	63	0	No
0	14	2	49	7	71	1	No
1	32	3,2	49	11	88,7	1	No
0	56	2,9	50	11	90	1	No
0	20	3,3	49	11,1	80,5	0	No

Dalam konteks distribusi data, dataset menunjukkan keseimbangan yang baik antara kelas positif dan negatif, dimana terdapat 3312 sampel balita yang teridentifikasi mengalami stunting (Yes) dan 3188 sampel balita dengan status tidak stunting (No). Keseimbangan distribusi ini sangat penting dalam membangun model klasifikasi yang robust, karena dapat menghindari bias pembelajaran yang sering terjadi pada dataset yang tidak seimbang. Proporsi yang hampir setara ini juga memungkinkan model untuk mempelajari pola dan karakteristik dari kedua kelas dengan baik, sehingga diharapkan dapat menghasilkan performa klasifikasi yang optimal.



Gambar 2. Data Pembagian Stunting

Preprocessing Data

Tahap preprocessing data merupakan langkah krusial dalam mempersiapkan dataset untuk proses pembelajaran mesin menggunakan metode CNN. Langkah pertama yang dilakukan adalah standardisasi fitur menggunakan StandardScaler, dimana proses ini mentransformasi seluruh variabel numerik ke dalam skala yang seragam dengan mean 0 dan standar

deviasi 1. Standardisasi ini sangat penting untuk memastikan bahwa setiap fitur memiliki kontribusi yang setara dalam proses pembelajaran, mengingat variabel-variabel dalam dataset memiliki rentang nilai yang berbeda-beda. Misalnya, variabel usia dalam bulan memiliki skala yang jauh berbeda dengan berat badan, sehingga standardisasi membantu mencegah dominasi fitur tertentu dalam proses pembelajaran model.

Setelah standardisasi, dataset dibagi menjadi dua bagian yaitu data training dan data testing dengan proporsi 80:20. Pembagian ini menggunakan metode stratified splitting untuk memastikan proporsi kelas (stunting dan tidak stunting) tetap seimbang pada kedua subset data. Sebanyak 80% data (5200 sampel) digunakan untuk melatih model, sementara 20% sisanya (1300 sampel) digunakan sebagai data testing untuk evaluasi performa model. Strategi pembagian ini penting untuk memastikan model dapat diuji pada data yang independen dan belum pernah dilihat selama proses training.

Untuk mempersiapkan data input CNN 1D, dilakukan proses reshape data menjadi format tiga dimensi (samples, timesteps, features). Dalam konteks ini, setiap sampel data diubah dari bentuk vektor 1D menjadi matriks 2D yang sesuai dengan arsitektur CNN 1D. Proses reshape ini mengubah dimensi data dari (n_samples, n_features) menjadi (n_samples, n_features, 1), dimana angka 1 pada dimensi terakhir merepresentasikan channel input untuk CNN. Selanjutnya, dilakukan konversi label kelas menggunakan teknik one-hot encoding, yang mengubah label kategorikal (Yes/No) menjadi representasi vektor biner. Proses ini menghasilkan matriks label dengan dimensi (n_samples, n_classes), dimana setiap sampel direpresentasikan sebagai vektor dengan nilai 1 pada posisi kelas yang sesuai dan 0 pada posisi lainnya. Transformasi label ini diperlukan karena arsitektur CNN yang digunakan menggunakan fungsi aktivasi softmax pada layer output untuk klasifikasi multi-kelas.

berat badan (Body_Weight) dan panjang badan (Body_Length) balita. Riwayat pemberian ASI Eksklusif juga dimasukkan sebagai salah satu variabel penting yang dicatat dalam bentuk data biner.

Dalam konteks distribusi data, dataset menunjukkan keseimbangan yang baik antara kelas positif dan negatif, dimana terdapat 3312 sampel balita

Arsitektur Model CNN

Dalam penelitian ini, arsitektur Convolutional Neural Network (CNN) dirancang secara khusus untuk menangani klasifikasi status stunting pada balita. Model CNN yang dikembangkan memiliki struktur sequential dengan beberapa layer yang disusun secara berurutan. Layer input dirancang dengan shape (7,1), menyesuaikan dengan jumlah fitur dalam dataset, dimana 7 merepresentasikan jumlah variabel input (Sex, Age, Birth_Weight, Birth_Length, Body_Weight, Body_Length, dan ASI_Eksklusif), sementara dimensi 1 merepresentasikan channel input untuk operasi konvolusi 1D.

Arsitektur dilanjutkan dengan Convolution 1D layer yang terdiri dari 32 filter dan kernel size 2. Layer konvolusi ini berperan penting dalam ekstraksi fitur dari data input melalui operasi konvolusi yang menggeser kernel sepanjang sekuens input. Pemilihan 32 filter memungkinkan model untuk mempelajari berbagai pola dan karakteristik dari data, sementara kernel size 2 memungkinkan model untuk menangkap interaksi antara fitur-fitur yang berdekatan. Hasil dari operasi konvolusi kemudian diproses melalui fungsi aktivasi ReLU (Rectified Linear Unit) yang memperkenalkan non-linearitas ke dalam model dan membantu dalam pembelajaran pola yang kompleks. Adapun model CNN yang dibangun sebagai berikut:

```
“model = Sequential()
model.add(Conv1D(32, kernel_size=2, activation='relu', input_shape=(X_reshaped.shape[1], 1)))
model.add(MaxPooling1D(pool_size=2))
model.add(Flatten())
model.add(Dense(50, activation='relu'))
model.add(Dense(2, activation='softmax'))”
```

Setelah layer konvolusi, diterapkan MaxPooling1D layer dengan pool size 2 yang berfungsi untuk mengurangi dimensi representasi dengan mempertahankan informasi yang paling signifikan. Operasi max pooling ini membantu mengurangi kompleksitas komputasi dan mencegah overfitting dengan melakukan down-sampling pada output konvolusi. Output dari layer pooling kemudian diratakan menggunakan Flatten layer, yang mengubah data dari format multidimensional menjadi vektor satu dimensi, mempersiapkannya untuk pemrosesan oleh layer dense berikutnya.

Arsitektur dilanjutkan dengan Dense layer yang terdiri dari 50 neuron dengan fungsi aktivasi ReLU. Layer ini memungkinkan model untuk mempelajari pola non-linear yang kompleks dari fitur-fitur yang telah diekstrak oleh layer konvolusi sebelumnya. Jumlah 50 neuron dipilih untuk memberikan kapasitas yang cukup bagi model dalam mempelajari representasi yang kompleks, namun tetap menjaga efisiensi komputasi. Akhirnya, output layer terdiri dari 2 neuron yang merepresentasikan dua kelas klasifikasi (stunting dan tidak stunting) dengan fungsi aktivasi softmax. Fungsi aktivasi softmax mengkonversi output menjadi probabilitas untuk masing-masing kelas, dimana total probabilitas seluruh kelas adalah 1, memungkinkan model untuk memberikan prediksi probabilistik tentang status stunting balita.

Training Model

Proses training model CNN untuk klasifikasi status stunting dilakukan dengan menggunakan berbagai parameter dan konfigurasi yang telah dioptimalkan. Model dikompilasi menggunakan optimizer Adam (Adaptive Moment Estimation), yang merupakan algoritma optimasi yang mengkombinasikan keunggulan dari dua optimizer populer lainnya: RMSprop dan Momentum. Adam dipilih karena kemampuannya dalam mengadaptasi learning rate untuk setiap

parameter, memungkinkan konvergensi yang lebih cepat dan stabil. Dalam konteks ini, Adam bekerja dengan mengupdate bobot jaringan secara adaptif berdasarkan estimasi moment pertama dan kedua dari gradien. Untuk fungsi loss, digunakan categorical crossentropy yang sangat sesuai untuk permasalahan klasifikasi multi-kelas dengan output berupa probabilitas. Fungsi ini mengukur perbedaan antara distribusi probabilitas prediksi model dengan distribusi probabilitas sebenarnya dari label yang telah di-one-hot-encoding. Categorical crossentropy memberikan penalti yang lebih besar ketika model membuat prediksi yang sangat yakin tetapi salah, mendorong model untuk memberikan prediksi yang lebih akurat dan terkalibrasi dengan baik. Adapun script python untuk training model seperti berikut:

```
“model.compile(optimizer='adam', loss='categorical_crossentropy', metrics=['accuracy'])
```

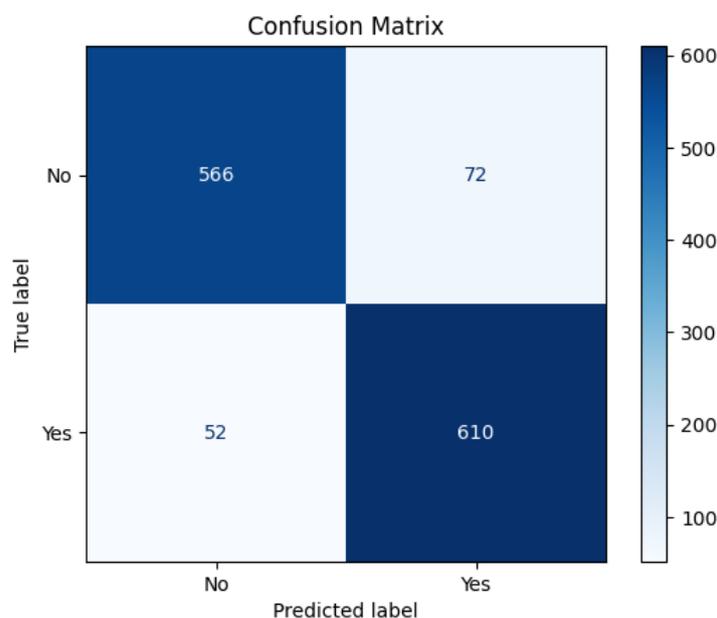
```
# Train model
```

```
model.fit(X_train, Y_train_categorical, epochs=10, batch_size=32, validation_data=(X_test, Y_test_categorical))”
```

Proses training dilaksanakan selama 10 epoch dengan batch size 32. Pemilihan jumlah epoch ini didasarkan pada observasi konvergensi model, dimana 10 epoch memberikan keseimbangan yang baik antara waktu training dan performa model. Batch size 32 dipilih sebagai kompromi antara kecepatan training dan penggunaan memori, memungkinkan update parameter yang cukup frequent untuk pembelajaran yang efektif namun tetap mempertahankan efisiensi komputasi. Setiap batch data diproses melalui model, gradien dihitung, dan bobot diupdate menggunakan optimizer Adam.

Evaluasi Model

Evaluasi komprehensif terhadap model CNN yang telah diimplementasikan untuk klasifikasi status stunting menunjukkan hasil yang sangat memuaskan dengan berbagai metrik performa yang tinggi. Model mencapai akurasi keseluruhan sebesar 90%, yang mengindikasikan bahwa dari seluruh prediksi yang dilakukan, 90% di antaranya berhasil mengklasifikasikan status stunting dengan benar. Tingkat akurasi ini menunjukkan kemampuan model yang sangat baik dalam membedakan antara balita yang mengalami stunting dan yang tidak.



Gambar 1. Evaluasi Model

Dalam konteks precision, model mencapai nilai 89% yang mengindikasikan tingkat ketepatan model dalam memberikan prediksi positif. Nilai ini menunjukkan bahwa ketika model memprediksi seorang balita mengalami stunting, prediksi tersebut benar dalam 89% kasus. Sementara itu, recall yang mencapai 92% menunjukkan kemampuan model yang sangat baik dalam mengidentifikasi kasus stunting yang sebenarnya. Nilai recall yang tinggi ini sangat penting dalam konteks kesehatan, karena mengindikasikan bahwa model memiliki tingkat false negative yang rendah, yang berarti hanya sedikit kasus stunting yang terlewatkan oleh model.

F1-Score sebesar 91% merepresentasikan harmonic mean antara precision dan recall, memberikan gambaran keseimbangan yang baik antara kedua metrik tersebut. Nilai F1-Score yang tinggi ini mengonfirmasi bahwa model berhasil mencapai keseimbangan yang optimal antara kemampuan untuk mendeteksi kasus stunting (recall) dan ketepatan dalam memberikan prediksi positif (precision). Hasil ini sangat penting dalam konteks aplikasi medis, dimana keseimbangan antara sensitifitas dan spesifisitas diagnosis sangat diperlukan.

KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan mengenai implementasi metode Convolutional Neural Network (CNN) untuk klasifikasi status stunting pada balita, dapat ditarik beberapa kesimpulan penting. Implementasi model CNN menunjukkan performa yang sangat baik dalam mengklasifikasikan status stunting, dengan mencapai akurasi sebesar 90%. Tingkat akurasi yang tinggi ini didukung oleh nilai precision 89%, recall 92%, dan F1-Score 91%, yang mengindikasikan bahwa model memiliki kemampuan yang seimbang dan handal dalam mengidentifikasi kasus stunting maupun non-stunting.

Keberhasilan implementasi ini tidak terlepas dari proses pengumpulan data yang sistematis dan preprocessing data yang komprehensif. Dataset yang terdiri dari 6500 sampel dengan distribusi kelas yang seimbang (3312 kasus stunting dan 3188 kasus non-stunting) memberikan dasar yang kuat untuk pelatihan model. Proses standardisasi data, pemilihan arsitektur CNN yang tepat, dan strategi training yang efektif berkontribusi signifikan terhadap performa model yang optimal. Arsitektur CNN dengan kombinasi layer konvolusi 1D, max pooling, dan dense layer terbukti mampu menangkap pola-pola kompleks dalam data antropometri dan karakteristik balita untuk menghasilkan prediksi yang akurat.

Hasil penelitian ini menunjukkan bahwa metode deep learning, khususnya CNN, memiliki potensi yang besar dalam mendukung upaya screening dan deteksi dini kasus stunting pada balita. Model yang dikembangkan dapat menjadi alat bantu yang efektif bagi tenaga kesehatan dalam melakukan assessment status stunting secara cepat dan akurat. Namun, perlu dicatat bahwa model ini sebaiknya digunakan sebagai alat pendukung keputusan dan bukan sebagai pengganti penilaian klinis oleh profesional kesehatan.

DAFTAR PUSTAKA

- Alrasyid, H., Homaidi, A., Kom, M., Fatah, Z., & Kom, M. (2024). *Comparison Support Vector Machine and Random Forest Algorithms in Detect Diabetes*. 1(1), 447–453.
- Arhami, M. (2024). *Metodologi Penelitian Untuk Teknologi Informasi Dan Komputer*. https://www.google.co.id/books/edition/METODOLOGI_PENELITIAN_UNTUK_TEKNOLOGI_IN/XSf5EAAQBAJ?hl=id&gbpv=1&dq=metode+penelitian+cnn&pg=PA270&printsec=frontcover
- Batubara, N. A., & Awangga, R. M. (2020). *Tutorial Object Detection Plate Number With Convolution Neural Network (Cnn)*. Kreatif. [https://books.google.co.id/books?hl=id&lr=&id=JAgHEAAAQBAJ&oi=fnd&pg=PA1&dq=Batubara,++N.++A.,++%26++Awangga,++R.++M.++2020.++TUTORIAL+Object++Detection++Plate++Number++With++Convolut+ion+Neural+Network+\(Cnn\)+\(Vol.+1\).+Kreatif.&ots=3Wqi7k2pNw&sig=KgV94Wbdw](https://books.google.co.id/books?hl=id&lr=&id=JAgHEAAAQBAJ&oi=fnd&pg=PA1&dq=Batubara,++N.++A.,++%26++Awangga,++R.++M.++2020.++TUTORIAL+Object++Detection++Plate++Number++With++Convolut+ion+Neural+Network+(Cnn)+(Vol.+1).+Kreatif.&ots=3Wqi7k2pNw&sig=KgV94Wbdw)
- Dkk, M. F. (2016). Penelitian lapangan (field research) pada metode kualitatif. *Penelitian Lapangan*, 1–26.
- Jalil, A., Homaidi, A., & Fatah, Z. (2024). Implementasi Algoritma Support Vector Machine Untuk Klasifikasi Status Stunting Pada Balita. *G-Tech: Jurnal Teknologi Terapan*, 8(3), 2070–2079. <https://doi.org/10.33379/gtech.v8i3.4811>
- L. Tri Wijaya Nata K., D. P. A. (2016). *Aplikasi Komputer dan Pengolahan Data Pengantar Statistika Industri*. https://www.google.co.id/books/edition/Aplikasi_Komputer_dan_Pengolahan_Data_Pe/LlIKDwAAQBAJ?hl=id&gbpv=0
- Lonang, S., & Normawati, D. (2022). *Klasifikasi Status Stunting Pada Balita Menggunakan K-Nearest Neighbor Dengan Feature Selection Backward Elimination*. 6, 49–56. <https://doi.org/10.30865/mib.v6i1.3312>
- Wiliani, N., Hidayah, N., Rahman, T. K. A., & Ramli, S. (2023). *Perbandingan Arsitektur CNN AlexNet dan VGG16 untuk Klasifikasi pada Gambar Permukaan Solar Panel yang Rusak*. https://www.google.co.id/books/edition/Perbandingan_Arsitektur_CNN_AlexNet_dan/eJ32EAAAQBAJ?hl=id&gbpv=1&dq=cnn&pg=PA85&printsec=frontcover
- Yuliana & Hakim W, B. M. (2019). Darurat stunting dengan melibatkan keluarga. In *Yayasan Ahmar Cendekia Indonesia*. https://www.google.co.id/books/edition/Darurat_Stunting_dengan_Melibatkan_Kelua/xE-9DwAAQBAJ?hl=id&gbpv=1&dq=pertumbuhan+anak+dan+stunting&printsec=frontcover