

Klasifikasi Penyakit Stunting Menggunakan Algoritma Multi-Layer Perceptron

PUTRI INTAN ASHURI, INDAH ARDHIA CAHYANI, CHRISTIAN SRI KUSUMA ADITYA

Universitas Muhammadiyah Malang, Malang, Indonesia
Email: christianskaditya@umm.ac.id

Received 16 Desember 2023 | *Revised* 7 Februari 2024 | *Accepted* 13 Maret 2024

ABSTRAK

Stunting adalah gangguan pertumbuhan dan perkembangan yang disebabkan kekurangan gizi yang ditandai dengan tinggi anak kurang dari dua kali standar deviasi yang ditetapkan oleh WHO. Kekurangan asupan gizi mengakibatkan menurunnya pertumbuhan anak, hal ini berhubungan dengan meningkatnya resiko sakit, kematian, hambatan pertumbuhan fisik maupun gangguan metabolisme tubuh. Beberapa metode telah dilakukan untuk membantu mengklasifikasi stunting pada anak salah satunya C4.5. Tujuan penelitian ini adalah mengklasifikasikan penyakit stunting menggunakan metode Multi-Layer Perceptron (MLP) dengan hyperparameter tuning RandomSearchCV. MLP memiliki beberapa kelebihan diantaranya mampu merepresentasikan hubungan lebih kompleks antara fitur input dan output, serta memproses data dalam berbagai bentuk, termasuk data tidak terstruktur. Penelitian ini menunjukkan model MLP menggunakan hyperparameter tuning RandomSearchCV mendapatkan performa terbaik berdasarkan hasil evaluasi didapatkan accuracy sebesar 81.78%, precision 85.00%, recall 94.34%, dan F1-Score 89.43%.

Kata kunci: *Stunting, Kekurangan gizi, Multi-Layer Perceptron (MLP), Hyperparameter tuning, RandomSearchCV*

ABSTRACT

Stunting is a growth and development disorder caused by malnutrition which is characterized by a child's height being less than twice the standard deviation set by WHO. Lack of nutritional intake results in decreased growth in children, this is associated with an increased risk of illness, death, physical growth restrictions and metabolic disorders. Several methods have been used to help classify stunting in children, one of which is C4.5. The aim of this research is to classify stunting using the Multi-Layer Perceptron (MLP) method with RandomSearchCV hyperparameter tuning. MLP has several advantages, including being able to represent more complex relationships between input and output features, as well as processing data in various forms, including unstructured data. This research shows that the MLP model using RandomSearchCV hyperparameter tuning got the best performance based on the evaluation results, which obtained accuracy of 81.78%, precision of 85.00%, recall of 94.34%, and F1-Score of 89.43%.

Keywords: *author's guideline, document's template, format, style, abstract*

1. PENDAHULUAN

Stunting saat ini merupakan permasalahan serius di bidang kesehatan dan kesejahteraan. Hal ini menjadi perhatian di berbagai negara, termasuk Indonesia. Berdasarkan hasil Survei Status Gizi Indonesia, pada tahun 2022 Indonesia memiliki prevalensi stunting mencapai 21,6% dinilai sebagai angka yang tinggi menurut standar yang ditentukan oleh *World Health Organization* (WHO) yakni kurang dari 20% (**Kemenkes RI, 2023**). Bahkan menurut WHO, pada tahun 2022 terdapat 148,1 juta anak dibawah usia 5 tahun mengalami stunting (**WHO, 2023**). Stunting merupakan gangguan tumbuh kembang pada anak yang disebabkan oleh asupan gizi yang kurang dalam waktu yang cukup lama akibat pemberian makan yang tidak sesuai dengan kebutuhan gizi dan infeksi berulang yang ditandai dengan kondisi bayi memiliki tinggi kurang dari dua kali standar deviasi rata-rata pertumbuhan yang ditetapkan oleh WHO (**Rahmi, dkk., 2022**). Stunting banyak dialami pada anak dibawah usia 5 tahun, dimana sebanyak 70% terjadi pada anak berusia 0-23 bulan (**Yunus, dkk., 2023**). Kekurangan asupan gizi mengakibatkan menurunnya pertumbuhan anak hal ini berhubungan dengan meningkatkan resiko sakit, kematian dan hambatan pertumbuhan fisik maupun gangguan metabolisme tubuh (**Astarani, dkk., 2020**).

Asupan gizi yang tidak sesuai selama masa kandungan maupun balita sangat berpengaruh timbulnya stunting (**Wahyudin, dkk., 2023**). Ada beberapa faktor yang dapat menyebabkan gangguan pertumbuhan pada anak, termasuk (1) faktor perawatan maternal dan antenatal, (2) kondisi lingkungan di rumah, (3) praktik pemberian Air Susu Ibu (ASI), dan (4) cara memberikan makanan kepada balita. (**Mediani, dkk., 2023**).

Berkembangnya teknologi saat ini, *metode machine learning* dan *deep learning* banyak digunakan untuk memberikan solusi dari berbagai permasalahan yang terjadi salah satunya pada bidang medis (**Purbolaksono, dkk., 2021**). *Deep learning* merupakan sub bidang pada *machine learning* yang berfokus pada penggunaan jaringan saraf tiruan (*neural networks*), Meskipun begitu, *deep learning* telah menjadi salah satu teknologi yang sangat diminati karena kemampuannya dalam mengenali objek dengan tingkat akurasi yang tinggi dan menggambarkan representasi konsep kompleks menjadi serangkaian konsep yang lebih simpel. *Deep learning* memanfaatkan data sebagai input, lalu memprosesnya melalui sejumlah lapisan tersembunyi (*hidden layer*). Setelah itu, dilakukan transformasi non-linier dari data masukan untuk menghitung nilai output (**Hasma & Silfianti, 2018**). kelebihan jaringan syaraf tiruan yaitu lebih *reliable* terhadap *noise* dalam data (**Wibawa & Maysanjaya, 2018**). Selain itu, jaringan syaraf tiruan juga memiliki kemampuan untuk menghasilkan prediksi yang baik untuk memecahkan suatu permasalahan meskipun menggunakan jumlah sampel yang terbatas (**Panca Saputra & Panca, 2020**).

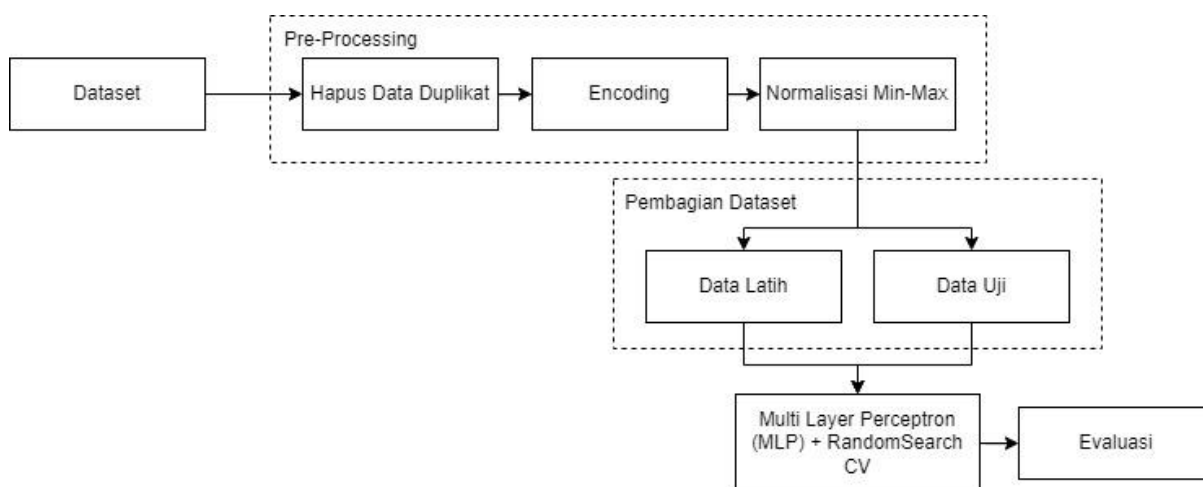
Salah satu metode *deep learning* yang dapat digunakan dalam klasifikasi adalah metode *Multi-Layer Perceptron (MLP)*. MLP merupakan algoritma *deep learning* yang disebut juga *multilayer feedforward neural network* salah satu algoritma yang paling luas digunakan serta algoritma yang unggul dalam penentuan nilai bobot dibandingkan dengan metode lain (**Riyanto, 2018**). MLP memiliki tiga layer yaitu *input layer*, *hidden layer*, dan *output layer* (**Nurrokhman, 2023**). MLP memiliki kemampuan beradaptasi terhadap data masukan dan mampu memprediksi hubungan antara kelas target dan atribut objek, serta memiliki kemampuan dalam mengatasi permasalahan yang cukup baik. Keunggulan tersebut menjadikan MLP populer dalam klasifikasi (**Jiang & Xu, 2022**). Oleh karena itu penelitian tersebut difokuskan pada metode klasifikasi MLP, yang merupakan salah satu algoritma pembelajaran mendalam utama karena memiliki potensi lebih besar dalam teknologi kedokteran (**Sharma, dkk., 2022**).

Penggunaan metode MLP juga dilakukan pada penelitian lainnya, mengklasifikasikan penyakit pada jantung dengan menghasilkan nilai *accuracy* sebesar 98% (**Hasan, dkk., 2017**). Kemudian penelitian dengan metode yang sama untuk mengidentifikasi ginjal kronis mendapatkan nilai *accuracy* yang tinggi yaitu 92.5% (**Vashisth, dkk., 2020**). Terdapat pula penelitian yang dilakukan untuk klasifikasi dan prediksi penyakit alzheimer mendapatkan nilai *accuracy* sebesar 94% (**Jyotiyana & Kesswani, 2020**). Berdasarkan beberapa penelitian yang telah dilakukan, terlihat bahwa penggunaan metode MLP terbukti berhasil dalam memberikan tingkat *accuracy* yang tinggi dalam memprediksi dan mengklasifikasikan di berbagai bidang medis atau Kesehatan.

Berdasarkan studi literatur pada beberapa penelitian sebelumnya, penelitian ini bertujuan untuk meningkatkan performa hasil pemodelan klasifikasi dari penelitian sebelumnya dengan mengusulkan penggunaan metode *Multi-Layer Perceptron (MLP)* untuk mengidentifikasi stunting pada anak. Pencarian kombinasi nilai parameter yang optimal dilakukan untuk meningkatkan performa model dari MLP, penggunaan *RandomSearchCV* mampu menjelajahi secara acak ruang hyperparameter dengan efisien sehingga akan memperoleh tingkat *accuracy* yang lebih tinggi dalam mengidentifikasi stunting pada anak (**Asha & Meenakowshalya., 2021**).

2. METODE PENELITIAN

Metode penelitian yang digunakan dalam penelitian ini dapat dilihat pada Gambar 1, yang dibagi menjadi beberapa tahap. Pertama, peneliti mengumpulkan data yang diperlukan untuk penelitian dengan beberapa atribut berupa jenis kelamin, umur, berat badan lahir, panjang lahir, berat badan, panjang tubuh, menyusui dan stunting. Kedua, pra-pemrosesan data mencakup penghapusan data duplikat, pengkodean variabel kategori menjadi numerik, dan normalisasi data. Ketiga, data dibagi menjadi dua subset yaitu data latih dan data uji. Keempat, pembentukan model algoritma MLP untuk melatih model klasifikasi stunting dengan menggunakan data latih. Kelima, model evaluasi kinerja yang telah dilatih menggunakan beberapa metrik evaluasi yang umum digunakan dalam klasifikasi meliputi *accuracy*, *precision*, *recall*, dan *F1-score*. Metrik ini akan memberikan informasi seberapa baik model dapat mengklasifikasikan data stunting (**Wang, dkk., 2019**).



Gambar 1. Alur Penelitian

2.1. Dataset

Dataset yang digunakan dalam penelitian ini adalah dataset stunting bersifat tabular yang bersumber dari Kaggle, yang merupakan *online repository database* dengan alamat *Uniform Resource Locator* (URL) <https://www.kaggle.com/datasets/muhtarom/stunting-dataset>. Dataset yang digunakan terdiri dari 8 buah atribut dan berjumlah sebanyak 10.000 seperti yang dapat dilihat pada Tabel 1. Dataset akan dibagi menjadi dua bagian yaitu data latih dan data uji.

Tabel 1. Dataset

Atribut	Tipe Data
Jenis Kelamin	Data numerik, menunjukkan nilai 'Pria' dan 'Wanita'
Umur	Data numerik, menunjukkan nilai usia balita
Berat Badan Lahir	Data numerik, menunjukkan berat badan balita ketika lahir
Panjang Lahir	Data numerik, menunjukkan panjang badan balita ketika lahir
Berat Badan	Data numerik, menunjukkan berat badan balita
Panjang Tubuh	Data numerik, yang menunjukkan panjang badan balita saat seusianya
Menyusui	Data kategorik, menunjukkan status balita menyusui
Stunting	Data kategorik, menunjukkan status balita stunting

2.2. Penghapusan Data Duplikat

Data duplikat adalah entri data yang sama muncul lebih dari satu kali. Adanya data kotor dapat menyebabkan masalah seperti buruknya kualitas, konsistensi dan integritas data (**Venkateswara Reddy & Damodaram, 2022**). Dilakukan penghapusan data duplikat agar tidak mengganggu saat proses analisis model pelatihan. Setelah proses pengecekan ditemukan data duplikat sebanyak 2.427. Oleh karena itu, dilakukan penghapusan data duplikat yang dimana data awal berjumlah 10.000 menjadi 7.573 data.

2.3. Encoding

Encoding merupakan salah satu teknik dalam pemrosesan data dalam *machine learning* dan *data mining*. Encoding bertujuan memproses penempatan urutan karakter (huruf, angka, tanda baca, dan simbol tertentu) ke dalam format khusus sehingga menjadi sebuah sandi. Proses *encoding* pada atribut yang mengandung tipe data kategorik yaitu jenis kelamin, menyusui, dan stunting.

2.4. Pembagian Data

Data perlu dibagi menjadi dua bagian utama, yaitu data pelatihan (*training data*) dan data pengujian (*testing data*). Data latih adalah data yang tersedia berdasarkan fakta yang terjadi, sedangkan data uji adalah data yang memiliki label yang akan digunakan untuk melakukan perhitungan sesuai dengan persamaan metode perhitungan *accuracy* klasifikasi yang ada (**Anggreani, dkk., 2018**). Pada penelitian ini digunakan 80% data latih dan 20% data uji.

2.5. Data Normalisasi

Normalisasi data adalah proses mengubah skala atau cakupan data agar seluruh variabel mempunyai pengaruh yang seimbang terhadap model. Normalisasi data harus dilakukan untuk mengurangi potensi kesalahan dengan mengubah data aktual ke nilai dalam kisaran sekitar 0-1 (**Suryani, dkk., 2022**). Seperti terlihat pada Tabel 2, terdapat beberapa atribut yang mempunyai nilai numerik pada rentang 0 – 1 yang akan dinormalisasi, sedangkan nilai atribut dengan tipe data kategorik bernilai antara 0 atau 1 hasil dari encoding.

Tabel 2. Nilai Normalisasi


Jenis Kelamin	Usia	Berat Badan Lahir	Panjang Kelahiran	Berat badan	Panjang Tubuh	Menyusui	Stunting
1	0.21	0.81	0.50	0.55	0.50	0	0
0	0.14	0.90	0.50	0.73	0.32	0	1
0	0.11	0.27	1.00	0.46	0.36	0	1
1	0.04	0.63	0.50	0.63	0.36	0	1
1	0.16	0.90	1.00	0.46	0.53	0	1

2.6. Hyperparameter Tuning RandomSearchCV

Penyetelan *Hyperparameter* pada jaringan syaraf tiruan *Multi Layer Perceptron* (MLP) adalah proses pengoptimalan pengembangan sebuah model pembelajaran mesin yang lebih baik (Panda, 2019). *RandomSearchCV* merupakan metode alternatif yang digunakan untuk menentukan parameter terbaik dalam suatu model, sehingga model tersebut dapat memprediksi data secara akurat (Putri, dkk., 2023). Kelebihan dari *RandomSearchCV* jika dibandingkan dengan *GridSearchCV* adalah kemampuannya untuk menjelajahi ruang hyperparameter dengan efisien, terutama ketika ruang *hyperparameter* sangat besar. Hal ini karena *RandomSearchCV* tidak menguji semua kombinasi mungkin, tetapi hanya sampel secara acak dari ruang hyperparameter (Roder, dkk., 2023).

2.7. Pelatihan Model Multi-Layer Perceptron (MLP)

Pembelajaran mesin dilakukan melalui tahap proses latih menggunakan data pelatihan. Tujuannya adalah untuk mengidentifikasi pola data yang dapat digunakan untuk menentukan apakah seorang anak mengalami stunting berdasarkan variabel yang dikumpulkan. Model MLP adalah topologi dari jaringan syaraf tiruan dimana perceptron terhubung membentuk beberapa lapisan (*layer*). Sebuah MLP mempunyai lapisan (*input layer*), minimal satu lapisan tersembunyi (*hidden layer*), dan lapisan luaran (*output layer*), seperti yang dapat dilihat pada Gambar 2. (Castro, dkk., 2017). MLP termasuk dalam kategori algoritma *feedforward*, karena input digabungkan dengan bobot awal dalam jumlah tertimbang dan dikenakan fungsi aktivasi, seperti pada *perceptron*. Namun perbedaannya adalah setiap kombinasi linier disebarkan ke lapisan berikutnya (Amato, dkk., 2017).



Gambar 2. MLP Arsitektur

2.8. Evaluation

Tahap terakhir setelah data dilatih adalah mengevaluasi kinerja model menggunakan data pengujian yang telah dipisahkan sebelumnya. Metode evaluasi digunakan dalam penelitian klasifikasi adalah *accuracy*. *Accuracy* akan mengukur sejauh mana model memprediksi

dengan benar. Metode lainnya terdapat *precision* dan *recall*. Metode *precision* digunakan untuk mengukur kelas positif model dalam memprediksi dan *recall* proses ini dilakukan untuk mengukur sejauh mana model dapat mengidentifikasi semua *instance* dari kelas positif. Selain itu terdapat juga metode *F-1 Score* dan *confusion matrix*. *F1-Score* adalah harmonik rata-rata dari *precision* dan *recall*. Sedangkan *confusion matrix* adalah matrik yang menyediakan campuran dari kelas yang diprediksi dengan aktual (**Markoulidakis, dkk., 2021**). Hasil evaluasi akan menunjukkan sejauh mana model mampu mengklasifikasikan stunting dengan baik, dan apakah model tersebut perlu dilakukan perbaikan atau peningkatan lebih lanjut pada model.

3. HASIL DAN PEMBAHASAN

Hasil penelitian ini memberikan tingkatan berupa *accuracy* yang didapatkan dari pengujian yang telah dilakukan dengan tujuan untuk menguji *accuracy* dan performa dari metode MLP dengan menerapkan *hyperparameter tuning RandomSearchCV*. Penggunaan Jumlah lapisan dan ukuran setiap lapisan dalam jaringan saraf tiruan mempengaruhi kapasitas model, yang dapat memengaruhi kemampuan jaringan untuk mempelajari pola dalam data (**Bromberg & Gitzinger, 2020**). *hidden_layer_sizes* dengan penentuan konfigurasi [(100,), (30,20), (20,10)] yang digunakan sudah dilakukan eksperimen dan validasi silang untuk mencapai keseimbangan yang optimal antara *underfitting* dan *overfitting*, serta kinerja model secara keseluruhan pada data pengujian (**Liu, dkk., 2023**). Pemilihan nilai *max_iter* yang optimal penting dikarenakan nilai yang terlalu kecil mungkin tidak mencapai konvergensi yang cukup, sementara nilai yang terlalu besar dapat menyebabkan *overfitting* atau meningkatkan waktu pelatihan tanpa peningkatan signifikan dalam kinerja model. Oleh karena itu, penggunaan *max_iter* dengan nilai konfigurasi [100, 200, 500] optimal untuk model yang diberikan (**Alghamdi & Almuhammadi, 2022**). Berikut nilai dari hasil konfigurasi *hyperparameter tuning* dapat dilihat pada Tabel 3.

Tabel 3. Konfigurasi Hyperparameter Tuning

Hyperparameter	Configuration	Best Parameters
<i>hidden_layer_sizes</i>	[(100,), (30,20), (20,10)]	(100,)
<i>activation</i>	['softmax', 'relu', 'tanh']	relu
<i>alpha</i>	[0.0001, 0.001, 0.01, 0.1]	0.01
<i>max_iter</i>	[100, 200, 500]	100

Hasil penelitian menunjukkan bahwa tuning hyperparameter *RandomsearchCV* dapat memberikan nilai *accuracy* yang baik. *RandomSearchCV* mendapatkan nilai *accuracy* yang baik yaitu 81.78 dengan nilai *precision* 85.00, nilai *recall* 94.34, nilai *F1-Score* 89.43. Dapat dilihat pada hasil *confusion matrix* dari *RandomSearchCV* bahwa model tersebut memiliki performa yang cukup baik, Namun nilai *False Positive* (FP) yang tinggi juga mempengaruhi hasil dari model karena cukup sering melakukan prediksi yang tidak sesuai dan hasil yang didapatkan hanya memiliki selisih sedikit. 20% dari data uji dengan total 1.515 data akan dievaluasi menggunakan *confusion matrix* seperti yang ditunjukkan di bawah ini.

Tabel 4. Confusion Matrix RandomsearchCV

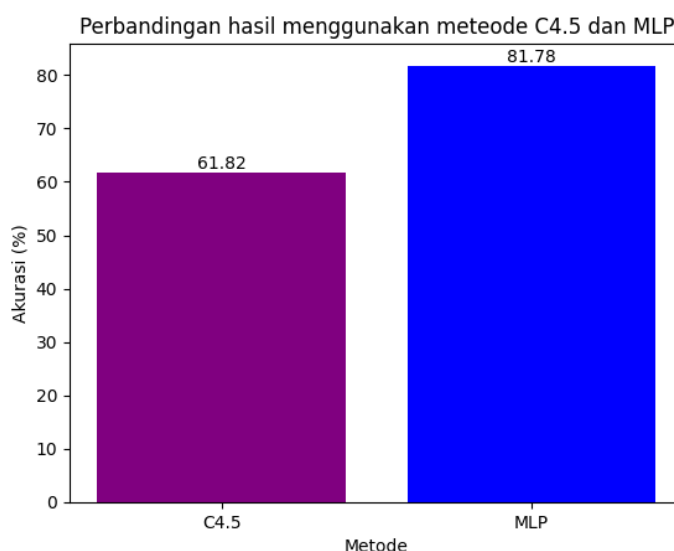
		Nilai Aktual	
		Positif	Negatif
Nilai Prediksi	Positif	71 (TP)	206 (FP)
	Negatif	70 (FN)	1168 (TN)

Dari Tabel 4 dapat dilihat bahwa nilai FP lebih besar dari TP. Hal ini karena data yang tidak representatif menyebabkan terjadinya ketidakseimbangan kelas. Perbandingan jumlah kelas positif lebih besar dibandingkan dengan kelas negatif dengan jumlah kelas positif sebesar 6120 dan kelas negatif sebesar 1452. Hal ini dapat mempengaruhi fitur yang akan digunakan oleh model karena tidak cukup untuk membedakan antara kelas positif dan negatif. Model dapat cenderung mengoptimalkan hasil kelas yang mayoritas berbobot positif dan kurang terhadap kelas negatif yang menyebabkan peningkatan nilai *False Positive* (FP).

Tabel 5. Evaluasi Matriks

Model	Accuracy (%)	Class	Precision (%)	Recall (%)	F1-Score(%)
MLP + RandomSearchCV	81,78	0	50.35	25.63	33.97
		1	85.00	94.34	89.43

Dari Tabel 5. diketahui bahwa nilai *precision*, *recall* dan *F1-Score* untuk kelas 0 mendapatkan hasil yang lebih kecil dibandingkan dengan kelas 1. Hal ini dapat dikatakan bahwa model yang telah dibuat lebih akurat dalam memprediksi data yang memenuhi kriteria tertentu untuk kelas 1 dibandingkan dengan kelas 0. Sehingga dapat menyebabkan nilai FP lebih besar dari nilai TN.



Gambar 3. MLP Lebih Akurat dari C4.5

Dari Gambar 3. menunjukkan bahwa algoritma MLP yang diusulkan dapat menghasilkan nilai *accuracy* yang lebih tinggi dibandingkan dengan menggunakan algoritma C4.5 (Yunus, dkk., 2023). Metode yang digunakan pada penelitian sebelumnya, karena MLP memiliki kemampuan untuk memodelkan data yang memiliki struktur kompleks dan penggunaan dataset yang lebih besar dalam klasifikasi. Dapat dilihat secara keseluruhan baik dari nilai *precision*, *recall*, dan *accuracy*, tabel tersebut menunjukkan bahwa model MLP yang diusulkan lebih unggul dibandingkan dengan model C4.5. Selain itu, penggunaan *hyperparameter tuning* pada MLP juga berpengaruh pada *accuracy* yang semakin tinggi. hal ini

mengindikasikan bahwa MLP lebih diandalkan dalam memprediksi kasus positif dan negatif secara akurat.

4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan untuk mengklasifikasi penyakit stunting menggunakan metode *Multi Layer Perceptron* (MLP). Dimana, *hyperparameter tuning RandomSearchCV* menghasilkan nilai *accuracy* yang cukup baik yaitu sebesar 81.78 dengan nilai *precision* 85.00, nilai *recall* 94.34, nilai *F1-Score* 89.43. Hal ini menunjukkan bahwa metode MLP berhasil dalam mengklasifikasi penyakit stunting. Untuk mencapai hasil yang lebih optimal perlu dilakukan perbaikan terus-menerus terhadap model yang digunakan dengan melibatkan eksplorasi lebih lanjut pada jumlah lapisan, jumlah neuron per lapisan, dan fungsi aktivasi yang akan digunakan. Saran untuk penelitian berikutnya dapat dilakukan penyeimbangan distribusi jumlah dataset pada tiap kelas sebelum dilakukan tahap pemodelan, hal ini diharapkan dapat meningkatkan performa secara menyeluruh terutama nilai *precision*, *recall* dan *F1-score* yang masih rendah untuk kelas yang masih berjumlah sedikit atau minoritas sesuai yang ditunjukkan pada hasil penelitian.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak Laboratorium Informatika UMM yang telah mendukung terlaksananya dan kelancaran pada penelitian ini

DAFTAR RUJUKAN

- Alghamdi, S., & Almuhammadi, S. (2022). On the Capabilities of Quantum Machine Learning. *Proceedings - 2022 7th International Conference on Data Science and Machine Learning Applications, CDMA 2022*, 181–187. <https://doi.org/10.1109/CDMA54072.2022.00035>
- Anggreani, D., Herman, & Astuti, W. (2018). Kinerja Metode Naïve Bayes dalam Prediksi Lama Studi Mahasiswa Fakultas Ilmu Komputer. *Seminar Nasional Ilmu Komputer Dan Teknologi Informasi*, 3(2), 107–111. <http://e-journals.unmul.ac.id/index.php/SAKTI/article/view/1843>
- Astarani, K., Idris, D. N. T., & Oktavia, A. R. (2020). Prevention of Stunting Through Health Education in Parents of Pre-School Children. *STRADA Jurnal Ilmiah Kesehatan*, 9(1), 70–77. <https://doi.org/10.30994/sjik.v9i1.270>
- Amato, F., Mazzocca, N., Moscato, F., & Vivencio, E. (2017, March). Multilayer perceptron: an intelligent model for classification and intrusion detection. In 2017 31st International Conference on Advanced Information Networking and Applications Workshops (WAINA) (pp. 686-691). IEEE.

- Bromberg, Y. D., & Gitzinger, L. (2020). DroidAutoML: A Microservice Architecture to Automate the Evaluation of Android Machine Learning Detection Systems. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12135 LNCS, 148–165. https://doi.org/10.1007/978-3-030-50323-9_10
- Castro, W., Oblitas, J., Santa-Cruz, R., & Avila-George, H. (2017). Multilayer perceptron architecture optimization using parallel computing techniques. *PloS one*, 12(12), e0189369.
- Hasan, T. T., Jasim, M. H., & Hashim, I. A. (2017). Heart Disease Diagnosis System based on Multi-Layer Perceptron neural network and Support Vector Machine. *International Journal of Current Engineering and Technology*, 7(55), 2277–4106.
- Hasma, Y. A., & Silfianti, W. (2018). Implementasi Deep Learning Menggunakan Framework Tensorflow Dengan Metode Faster Regional Convolutional Neural Network Untuk Pendeteksian Jerawat. *Jurnal Ilmiah Teknologi Dan Rekayasa*, 23(2), 89–102. <https://doi.org/10.35760/tr.2018.v23i2.2459>
- Jiang, X., & Xu, C. (2022). Deep Learning and Machine Learning with Grid Search to Predict Later Occurrence of Breast Cancer Metastasis Using Clinical Data. *Journal of Clinical Medicine*, 11(19). <https://doi.org/10.3390/jcm11195772>
- Jyotiyana, M., & Kesswani, N. (2020). Classification and prediction of Alzheimer's disease using multi-layer perceptron. *International Journal of Reasoning-Based Intelligent Systems*, 12(4), 238–247. <https://doi.org/10.1504/IJRIS.2020.111785>
- Kemenkes RI. (2023). *Prevalensi Stunting di Indonesia Turun ke 21,6% dari 24,4%*. Kemenkes. <https://www.kemkes.go.id/id/rilis-kesehatan/prevalensi-stunting-di-indonesia-turun-ke-216-dari-244>
- Liu, Q., Gong, Z., Huang, Z., Liu, C., Zhu, H., Li, Z., Chen, E., & Xiong, H. (2023). *Multi-Dimensional Ability Diagnosis for Machine Learning Algorithms*. July 2017. <http://arxiv.org/abs/2307.07134>
- Markoulidakis, I., Rallis, I., Georgoulas, I., Kopsiaftis, G., Doulamis, A., & Doulamis, N. (2021). Multiclass Confusion Matrix Reduction Method and Its Application on Net

- Promoter Score Classification Problem. *Technologies*, 9(4).
<https://doi.org/10.3390/technologies9040081>
- Mediani, H. S., Setyawati, A., Hendrawati, S., Nurhidayah, I., & Firdianty, N. F. (2023). Pengaruh Faktor Maternal terhadap Insidensi Stunting pada Anak Balita di Negara Berkembang: Narrative Review. *Jurnal Obsesi: Jurnal Pendidikan Anak Usia Dini*, 7(2), 1868–1886. <https://doi.org/10.31004/obsesi.v7i2.4160>
- Ni Kadek Ary Indah Suryani, Oka Sudana, & Ayu Wirdiani. (2022). Forecasting Pneumonia Toddler Mortality Using Comparative Model ARIMA and Multilayer Perceptron. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 6(4), 528–537. <https://doi.org/10.29207/resti.v6i4.4106>
- Nurrokhman, M. Z. (2023). Perbandingan Algoritma Support Vector Machine dan Neural Network untuk Klasifikasi Penyakit Hati. *Indonesian Journal of Computer Science*, 12(4). <https://doi.org/10.33022/ijcs.v12i4.3274>
- Panca Saputra, E., & Panca, E. (2020). Classification Using Artificial Neural Network Method in Protecting Credit Fitness. *Indonesian Journal of Artificial Intelligence and Data Mining (IJAIDM)*, 3(1), 50–56.
- Panda, B. (2019). *A survey on application of Population Based Algorithm on Hyperparameter Selection*. *April*, 1–9. <https://doi.org/10.13140/RG.2.2.11820.21128>
- Purbolaksono, M. D., Irvan Tantowi, M., Imam Hidayat, A., & Adiwijaya, A. (2021). Perbandingan Support Vector Machine dan Modified Balanced Random Forest dalam Deteksi Pasien Penyakit Diabetes. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(2), 393–399. <https://doi.org/10.29207/resti.v5i2.3008>
- Putri, T. A. E., Widiharih, T., & Santoso, R. (2023). Penerapan Tuning Hyperparameter Randomsearchcv Pada Adaptive Boosting Untuk Prediksi Kelangsungan Hidup Pasien Gagal Jantung. *Jurnal Gaussian*, 11(3), 397–406. <https://doi.org/10.14710/j.gauss.11.3.397-406>
- Rahmi, I., Susanti, M., Yozza, H., & Wulandari, F. (2022). Classification of Stunting in Children Under Five Years in Padang City Using Support Vector Machine. *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, 16(3), 771–778.

<https://doi.org/10.30598/barekengvol16iss3pp771-778>

- Riyanto, U. (2018). Penerapan Algoritma Multilayer Perceptron (Mlp) Dalam Menentukan Kelayakan Kenaikan Jabatan: Studi Kasus Pt. Abc - Jakarta. *JIKA (Jurnal Informatika)*, 2(1), 58–65. <http://jurnal.umt.ac.id/index.php/jika/article/view/5481>
- Roder, M., Passos, L. A., Papa, J. P., & Rossi, A. L. D. (2023). Feature Selection and Hyperparameter Fine-Tuning in Artificial Neural Networks for Wood Quality Classification. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 14196 LNAI, 323–337. https://doi.org/10.1007/978-3-031-45389-2_22
- Sharma, R., Kim, M., & Gupta, A. (2022). Motor imagery classification in brain-machine interface with machine learning algorithms: Classical approach to multi-layer perceptron model. *Biomedical Signal Processing and Control*, 71(PA), 103101. <https://doi.org/10.1016/j.bspc.2021.103101>
- Vashisth, S., Dhall, I., & Saraswat, S. (2020). Chronic kidney disease (CKD) diagnosis using multi-layer perceptron classifier. *Proceedings of the Confluence 2020 - 10th International Conference on Cloud Computing, Data Science and Engineering, January 2020*, 346–350. <https://doi.org/10.1109/Confluence47617.2020.9058178>
- Venkateswara Reddy, L., & Damodaram, A. K. (2022). REMOVAL OF DUPLICATES IN DATABASE RELATIONS AND THE ASSOCIATED PROPAGATION MANAGEMENT. *Article in International Journal of Advanced Research in Computer Science*, 9(2). <https://doi.org/10.26483/ijarcs.v9i2>
- Wahyudin, W. C., Hana, F. M., Prihandono, A., Kudus, U. M., No, J. G., Email, I., Semarang, P. K., Classifier, N. B., Naive, A., Classifier, B., Classifier, N. B., & Classifier, N. B. (2023). *P Rediksi S Tunting P Ada B Alita D I R Umah S Akit K Ota. 2019*, 32–36.
- Wang, J., Xu, Z., & Che, Y. (2019). Power quality disturbance classification based on DWT and multilayer perceptron extreme learning machine. *Applied Sciences (Switzerland)*, 9(11). <https://doi.org/10.3390/app9112315>
- WHO. (2023). *Joint Child Malnutrition Estimates*. <https://www.who.int/data/gho/data/themes/topics/joint-child-malnutrition-estimates->

unicef-who-wb#:~:text=In 2022%2C 148.1 million children,for their height (overweight)

Wibawa, M. S., & Maysanjaya, I. M. D. (2018). Multi Layer Perceptron Dan Principal Component Analysis Untuk Diagnosa Kanker Payudara. *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, 7(1), 90. <https://doi.org/10.23887/janapati.v7i1.12909>

Yunus, M., Biddinika, M. K., & Fadlil, A. (2023). Classification of Stunting in Children Using the C4.5 Algorithm. *Jurnal Online Informatika*, 8(1), 99–106. <https://doi.org/10.15575/join.v8i1.1062>