

Perancangan dan Evaluasi Sistem Antropometri Cerdas Berbasis Bioelectrical Impedance Analysis dan Kecerdasan Buatan untuk Prediksi Risiko Penyakit Degeneratif

1st Ghazy Ahmad Fahreza

Program Studi S1 Teknik Biomedis

Fakultas Teknik Elektro, Universitas Telkom

Bandung, Indonesia

ghazyahmadfhrz@student.telkomuniversity.ac.id

2nd Ardisatria Surya Muhammad

Program Studi S1 Teknik Biomedis

Fakultas Teknik Elektro, Universitas Telkom

Bandung, Indonesia

ardisatria@student.telkomuniversity.ac.id

3rd Hilman Fauzi TSP, S.T., M.T., Ph.D

Program Studi S1 Teknik Biomedis

Fakultas Teknik Elektro, Universitas Telkom

Bandung, Indonesia

hilmanfauzitsp@telkomuniversity.ac.id

4th Muhammad Hablul Barri, S.T., M.T.

Program Studi S1 Teknik Biomedis

Fakultas Teknik Elektro, Universitas Telkom

Bandung, Indonesia

mhbbarri@telkomuniversity.ac.id

Abstract—Meningkatnya prevalensi obesitas di Indonesia menuntut adanya sistem pemantauan kesehatan yang lebih komprehensif. Indeks Massa Tubuh (IMT) sebagai standar saat ini memiliki keterbatasan fundamental karena tidak mampu membedakan antara massa lemak dan massa otot, sehingga kurang akurat untuk diagnosis individu. Penelitian ini bertujuan untuk merancang, membangun, dan mengevaluasi sebuah sistem ukur antropometri cerdas berbasis Bioelectrical Impedance Analysis (BIA) yang terintegrasi dengan kecerdasan buatan, guna menyediakan penilaian risiko penyakit degeneratif yang lebih personal dan akurat. Sistem yang dikembangkan terdiri dari prototipe timbangan perangkat keras berbasis Arduino Mega yang mengintegrasikan sensor load cell, IR Sharp, rangkaian BIA, serta aplikasi Android "SmartScale". Hasil evaluasi kinerja perangkat keras menunjukkan adanya deviasi yang signifikan saat divalidasi dengan alat ukur referensi (rata-rata error 12,9%), menyoroti sensitivitas metode BIA terhadap implementasi perangkat keras. Di sisi perangkat lunak, dari tiga model AI yang diuji, model Deep Neural Network (DNN) menunjukkan performa prediktif terbaik dengan akurasi 88,75%, secara signifikan melampaui target penelitian sebesar 83%. Analisis signifikansi parameter menggunakan metode SHAP lebih lanjut memvalidasi relevansi klinis model dengan mengidentifikasi IMT dan kadar lemak sebagai prediktor paling dominan. Penelitian ini berhasil membuktikan kelayakan integrasi sistem pengukuran antropometri BIA dengan model prediksi AI berakurasi tinggi, menawarkan pendekatan yang lebih holistik sebagai alternatif unggul dari skrining konvensional berbasis IMT.

Index Terms—Antropometri, Bioelectrical Impedance Analysis, Kecerdasan Buatan, Deep Neural Network, Prediksi Kesehatan, Sistem Tertanam.

I. PENDAHULUAN

Prevalensi *overweight* dan obesitas di Indonesia telah mencapai tingkat yang mengkhawatirkan, di mana data terbaru menunjukkan bahwa sekitar 33% orang dewasa dan 1 dari 5

anak usia sekolah terdampak [1]. Kondisi ini merupakan faktor risiko utama bagi berbagai penyakit tidak menular (PTM) atau penyakit degeneratif, yang menjadi penyebab utama morbiditas dan mortalitas di negara ini. Indikator utama yang saat ini digunakan secara luas untuk skrining, Indeks Massa Tubuh (IMT), memiliki kelemahan mendasar. IMT dihitung hanya berdasarkan berat dan tinggi badan, sehingga tidak mampu membedakan antara massa otot yang padat dan massa lemak yang bervolume, menjadikannya tidak ideal untuk diagnosis klinis individu yang akurat [2].

Sebagai alternatif yang lebih superior, metode *Bioelectrical Impedance Analysis* (BIA) menawarkan presisi lebih tinggi dengan kemampuannya mengukur komposisi tubuh secara detail, termasuk kadar air, persentase lemak, dan massa otot secara non-invasif [3]. BIA bekerja dengan mengalirkan arus listrik lemah dan aman ke tubuh, kemudian mengukur impedansi (hambatan) yang ditemui. Prinsipnya, jaringan lemak memiliki konduktivitas listrik yang lebih rendah dibandingkan massa bebas lemak (otot dan air), sehingga memungkinkan estimasi komposisi tubuh yang lebih akurat.

Meskipun demikian, adopsi perangkat BIA di Indonesia menghadapi beberapa kendala, seperti harga yang relatif mahal, keterbatasan akses, dan kurangnya integrasi dengan platform digital yang memudahkan pemantauan mandiri secara berkala. Di sisi lain, kemajuan dalam bidang kecerdasan buatan (AI) membuka peluang baru. Integrasi data BIA dengan algoritma AI telah terbukti mampu meningkatkan akurasi prediksi risiko penyakit degeneratif seperti stroke, penyakit jantung, ginjal, dan diabetes tipe 2 [4]. Penelitian sebelumnya oleh Abbas et al. menunjukkan bahwa model AI seperti *Random Forest* dapat mencapai akurasi prediksi di atas 80%,

sebuah standar yang diakui secara internasional sebagai "sangat baik" untuk aplikasi klinis [5].

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengatasi kesenjangan yang ada dengan merancang, mengimplementasikan, dan mengevaluasi sebuah sistem timbangan cerdas terintegrasi yang menggabungkan keunggulan BIA dan AI. Tujuan spesifik penelitian ini adalah: (1) Membangun prototipe timbangan BIA dengan target bias pengukuran $\leq 4,8\%$ dibandingkan alat standar. (2) Mengembangkan model AI untuk prediksi risiko penyakit dengan akurasi minimal 83%. (3) Mengimplementasikan sistem ini dalam sebuah platform yang fungsional dan mudah digunakan. Sistem ini diharapkan dapat menjadi alat bantu skrining kesehatan yang lebih akurat, terjangkau, dan mudah diakses oleh masyarakat luas, mendukung upaya pencegahan dini penyakit degeneratif.

II. METODE PENELITIAN

Penelitian ini menerapkan pendekatan rekayasa sistem terintegrasi yang mencakup perancangan perangkat keras, pengembangan perangkat lunak, dan implementasi model AI.

A. Desain Arsitektur Sistem

Sistem secara keseluruhan terdiri dari dua komponen utama: unit perangkat keras (timbangan cerdas) dan unit perangkat lunak (aplikasi mobile). Perangkat keras bertugas mengakuisisi data antropometri dan BIA dari pengguna. Data ini kemudian dikirim secara nirkabel melalui Bluetooth ke aplikasi mobile. Aplikasi kemudian memproses data, menjalankan model AI untuk menghasilkan prediksi risiko kesehatan, dan menyajikan hasilnya kepada pengguna dengan antarmuka yang intuitif.

B. Perancangan Perangkat Keras

Perangkat keras dirancang sebagai timbangan cerdas portabel berbasis mikrokontroler Arduino Mega 2560. Pemilihan Arduino Mega didasarkan pada jumlah pin I/O yang melimpah dan memori yang cukup untuk menangani beberapa sensor dan modul secara simultan. Komponen utama meliputi:

1) *Pengukuran Berat Badan*: Sistem penimbangan menggunakan empat buah sensor *load cell* 50kg yang ditempatkan di setiap sudut platform. Sinyal analog dari *load cell* sangat lemah, sehingga diperkuat dan dikonversi menjadi data digital oleh modul HX711, sebuah ADC 24-bit presisi tinggi yang dirancang khusus untuk aplikasi penimbangan.

2) *Estimasi Tinggi Badan*: Tinggi badan diestimasi secara tidak langsung untuk meningkatkan kepraktisan. Sistem menggunakan sensor inframerah (IR) Sharp GP2Y0A21 untuk mengukur panjang telapak kaki pengguna. Data panjang telapak kaki (PTK) dalam cm kemudian dimasukkan ke dalam model regresi linear yang divalidasi dari penelitian sebelumnya [6] untuk mengestimasi tinggi badan (TB), seperti pada Persamaan (1) dan (2).

$$TB_{pria} = 80.301 + (3.522 \times PTK) \quad (1)$$

$$TB_{wanita} = 86.8763 + (3.149 \times PTK) \quad (2)$$




Fig. 1. Diagram blok arsitektur sistem keseluruhan, menunjukkan alur data dari akuisi perangkat keras hingga penyajian hasil di aplikasi mobile.

3) *Analisis Komposisi Tubuh (BIA)*: Ini adalah inti dari perangkat keras. Sebuah rangkaian BIA kustom dirancang untuk mengukur impedansi tubuh (Z) melalui empat elektroda plat stainless steel. Rangkaian ini terdiri dari tiga blok fungsional utama yang dirancang untuk mengatasi tantangan pengukuran in-vivo [8]:

- **Howland Current Source**: Menghasilkan dan menginjeksikan arus bolak-balik (AC) sinusoidal yang stabil dan aman (0.27 mA, 50 kHz) ke tubuh pengguna.
- **Instrumentation Amplifier**: Memperkuat sinyal tegangan biologis yang sangat kecil yang timbul sebagai respons terhadap injeksi arus.
- **Precision Rectifier**: Mengubah sinyal AC yang telah diperkuat menjadi sinyal DC yang level tegangannya dapat dibaca secara akurat oleh ADC pada mikrokontroler.

Nilai impedansi (Z) yang terukur kemudian digunakan dalam formula empiris untuk menghitung *Fat-Free Mass* (FFM), seperti pada Persamaan (3) dan (4).

$$FFM_{pria} = (0.520 \times \frac{TB^2}{Z}) + (0.350 \times BB) + 6.20 \quad (3)$$

$$FFM_{wanita} = (0.495 \times \frac{TB^2}{Z}) + (0.312 \times BB) + 5.85 \quad (4)$$

di mana BB adalah berat badan dalam kg.

4) *Komunikasi dan Tampilan*: Data hasil pengukuran ditampilkan secara lokal pada layar LCD TFT 2.4 inci dan secara bersamaan dikirimkan secara nirkabel ke aplikasi Android melalui modul Bluetooth HC-05 yang beroperasi pada protokol SPP (*Serial Port Profile*).

C. Pengembangan Perangkat Lunak dan Model AI

Perangkat lunak berupa aplikasi Android native bernama "SmartScale" dikembangkan menggunakan Android Studio. Aplikasi ini berfungsi sebagai antarmuka pengguna utama, pusat pemrosesan data, dan platform visualisasi hasil.

1) *Arsitektur Model AI*: Inti dari perangkat lunak adalah model prediksi AI yang dirancang untuk mengklasifikasikan risiko enam penyakit degeneratif secara simultan (*multi-label classification*). Tiga pendekatan model dieksperimentasikan untuk menemukan performa terbaik:

- 1) **Rule-Based System**: Sebuah model dasar yang menggunakan serangkaian logika IF-THEN yang diturunkan dari ambang batas medis standar.
- 2) **Random Forest (RF)**: Sebuah model *ensemble learning* yang terdiri dari 100 *decision trees*.
- 3) **Deep Neural Network (DNN)**: Sebuah model jaringan saraf tiruan dengan arsitektur sekuensial yang terdiri dari satu lapisan input, dua *hidden layer* (64 dan 32 neuron, aktivasi ReLU), dan satu lapisan output (6 neuron, aktivasi Sigmoid). Regularisasi *dropout* (rate=0.2) diterapkan untuk mencegah *overfitting*.

2) *Dataset dan Pelatihan*: Dataset sintetis yang terdiri dari 5000 sampel data digunakan untuk pelatihan dan evaluasi. Setiap sampel memiliki 7 fitur input (IMT, Kadar Lemak, Massa Otot, Kadar Air, BMR, Lemak Visceral, Jenis Kelamin) dan 6 label output biner. Dataset dibagi menjadi 64% untuk pelatihan, 16% untuk validasi, dan 20% untuk pengujian. Proses *preprocessing* data meliputi normalisasi fitur numerik menggunakan *StandardScaler* dan *encoding* variabel kategorikal. Model DNN dilatih selama 50 epoch menggunakan *Adam optimizer* dan *binary crossentropy* sebagai *loss function*.

D. Prosedur Pengujian

Evaluasi sistem dilakukan secara komprehensif melalui serangkaian pengujian terstruktur:

- **Kinerja Perangkat Keras**: Akurasi sensor divalidasi dengan alat ukur manual dan dibandingkan dengan timbangan komersial Onemed iF-2050A pada 17 subjek.
- **Akurasi Prediksi Model**: Model AI divalidasi dengan membandingkan prediksinya dengan status hipertensi aktual dari 15 responden. Status aktual ditetapkan menggunakan *sphygmomanometer* digital Omron sebagai *ground truth*.
- **Konektivitas**: Latensi dan *packet loss* komunikasi Bluetooth diuji dalam 5 skenario.
- **Usability**: Kemudahan penggunaan aplikasi dievaluasi oleh 10 responden menggunakan kuesioner *System Usability Scale* (SUS), sesuai metodologi yang divalidasi [10].

III. HASIL

A. Kinerja Perangkat Keras

Pengujian subsistem perangkat keras menunjukkan hasil yang bervariasi. Sensor berat badan menunjukkan akurasi yang sangat baik dengan rata-rata *error* hanya 2,12%. Metode estimasi tinggi badan juga memberikan hasil yang dapat diterima dengan rata-rata *error* sebesar 3,33%.

Namun, perbandingan parameter turunan BIA dengan alat pembandingan komersial menunjukkan deviasi yang signifikan. Rata-rata *error* gabungan untuk parameter-parameter ini mencapai 12,9%, yang belum memenuhi target awal penelitian ($\leq 4,8\%$). Hasil perbandingan detail disajikan pada Tabel I.

TABLE I
PERBANDINGAN RATA-RATA ERROR PENGUKURAN

Parameter	Rata-Rata Error (%)
Berat Badan	2,67
IMT	8,60
Kadar Lemak	24,31
Kadar Air	5,79
Massa Otot	15,86
Visceral Fat	17,02
Total Rata-Rata (BIA)	12,90

B. Kinerja Model AI

Dari tiga model yang diuji, model DNN menunjukkan keunggulan mutlak. Hasil perbandingan kinerja disajikan pada Tabel II. DNN berhasil mencapai akurasi rata-rata sebesar 88,75%, secara signifikan melampaui target penelitian sebesar 83%. DNN juga mencatatkan F1-Score tertinggi (0.8671), yang mengindikasikan keseimbangan terbaik antara presisi dan *recall*.

TABLE II
PERBANDINGAN KINERJA TIGA MODEL AI

Parameter	Rule-Based	DNN	RF
Akurasi	0.6998	0.8875	0.8098
Recall	0.9799	0.8647	0.8136
Presisi	0.6731	0.8711	0.8161
F1-Score	0.7723	0.8671	0.8099

Analisis signifikansi parameter menggunakan metode SHAP pada model DNN mengonfirmasi bahwa IMT dan Kadar Lemak adalah dua prediktor paling berpengaruh.

C. Kinerja Sistem Terintegrasi

Sistem sebagai satu kesatuan menunjukkan performa teknis dan fungsional yang baik. Dalam pengujian validasi pada 15 responden untuk prediksi hipertensi, model mencapai akurasi 66,7% dengan sensitivitas yang sempurna (*False Negative*=0). Koneksi Bluetooth terbukti sangat stabil, dengan latensi serendah 12 ms dan *packet loss* maksimal hanya 3,5%. Evaluasi *usability* menghasilkan skor SUS rata-rata 76,75, yang termasuk dalam kategori "Good" (Baik).




Fig. 2. Analisis SHAP untuk prediksi penyakit jantung, menunjukkan IMT dan Kadar Lemak sebagai fitur paling dominan.

IV. PEMBAHASAN

Hasil penelitian ini menunjukkan keberhasilan dalam mengintegrasikan teknologi BIA dengan model AI prediktif yang sangat akurat. Poin diskusi utama adalah dualitas antara keberhasilan perangkat lunak dan tantangan pada perangkat keras.

Keunggulan utama penelitian ini adalah performa model DNN yang mencapai akurasi 88,75%. Capaian ini tidak hanya melampaui target yang ditetapkan, tetapi juga memenuhi standar "superior predictive accuracy" yang diakui secara internasional [5]. Validasi melalui analisis SHAP memperkuat kepercayaan pada model, karena logika internalnya dalam memprioritaskan IMT dan kadar lemak terbukti selaras dengan alur diagnosis klinis standar, terutama dalam mengidentifikasi risiko penyakit kardiovaskular [9].

Di sisi lain, tantangan utama terletak pada kinerja perangkat keras prototipe. Rata-rata *error* sebesar 12,9% pada parameter BIA menunjukkan adanya ruang signifikan untuk perbaikan. Deviasi ini kemungkinan besar disebabkan oleh sensitivitas tinggi metode BIA terhadap kondisi fisiologis subjek dan variabilitas prosedur pengukuran. Hal ini menggarisbawahi bahwa untuk mencapai akurasi perangkat keras yang lebih tinggi, diperlukan optimasi pada desain mekanik dan penyusunan protokol penggunaan yang lebih ketat.

Meskipun terdapat deviasi pada pengukuran BIA, sistem secara keseluruhan terbukti fungsional dan andal. Konektivitas yang stabil dan skor *usability* yang baik (SUS 76,75) menunjukkan bahwa fondasi sistem ini kuat dan siap digunakan oleh pengguna akhir, yang merupakan kunci adopsi teknologi kesehatan personal.

V. KESIMPULAN

Penelitian ini berhasil merancang dan mengevaluasi prototipe sistem ukur antropometri cerdas berbasis BIA dan AI. Kesimpulan utama adalah: (1) Model prediksi DNN berhasil dikembangkan dengan akurasi superior (88,75%), melebihi

target dan terbukti valid secara klinis. (2) Kinerja perangkat keras prototipe masih memerlukan optimasi, dengan rata-rata *error* BIA sebesar 12,9%. (3) Sistem secara keseluruhan fungsional, andal, dan diterima baik oleh pengguna (skor SUS 76,75), menegaskan potensinya sebagai alat deteksi dini. Untuk pengembangan selanjutnya, disarankan optimasi perangkat keras dan penggunaan dataset medis nyata untuk pelatihan model AI.

REFERENCES

- [1] UNICEF Indonesia, "10 facts about overweight and obesity," 2022. [Online]. Available: <https://www.unicef.org/indonesia/media/21491/file/10%20facts%20about%20overweight%20and%20obesity.pdf>
- [2] D. Khanna, C. Peltzer, and P. Kahar, "Body Mass Index (BMI): A Screening Tool Analysis," *Cureus*, vol. 14, no. 2, 2022, doi: 10.7759/cureus.22119.
- [3] M. S. Mialich, J. M. F. Sicchieri, and A. A. Junior, "Analysis of Body Composition: A Critical Review of the Use of Bioelectrical Impedance Analysis," *International Journal of Clinical Nutrition*, vol. 2, no. 1, pp. 1-10, Jan. 2014.
- [4] G. Singhanian, N. Maurya, P. Sharma, and R. Bhardwaj, "Revolutionizing Disease Prediction with Deep Learning and Predictive Analysis," *International Journal for Research in Applied Science and Engineering Technology*, vol. 12, no. 5, pp. 2571-2577, May 2024.
- [5] S. Abbas, M. Iftikhar, M. M. Shah, and S. J. Khan, "ChatGPT-Assisted Machine Learning for Chronic Disease Classification and Prediction: A Developmental and Validation Study," *Cureus*, Dec. 2024, doi: 10.7759/cureus.75851.
- [6] N. S. Mohamad, B. Omar, H. H. Soe, M. A. A. Bakar, N. H. A. Rahim, and N. Othman, "Stature Estimation Based on Foot Length and Foot Breadth in a Malaysian Population," *Journal of Agromedicine and Medical Sciences*, vol. 8, no. 2, pp. 73-81, Aug. 2020.
- [7] M. N. Fadhlurrahman, "Perancangan Alat Ukur Komposisi Tubuh dengan Bioelectrical Impedance Analysis pada Timbangan Berat Badan," *Open Library Telkom University*, 2024. [Online]. Available: <https://openlibrary.telkomuniversity.ac.id/home/catalog/id/212622/>
- [8] L. Pîslaru-Dănescu, G. C. Zărnescu, G. Telipan, and V. Stoica, "Design and Manufacturing of Equipment for Investigation of Low Frequency Bioimpedance," *Micromachines*, vol. 13, no. 11, p. 1858, Oct. 2022.
- [9] T. M. Powell-Wiley et al., "Obesity and Cardiovascular Disease: A Scientific Statement From the American Heart Association," *Circulation*, vol. 143, no. 21, Apr. 2021, doi: 10.1161/cir.0000000000000973.
- [10] J. R. Lewis and J. Sauro, "The Factor Structure of the System Usability Scale," in *Human Centered Design*, Berlin, Heidelberg: Springer, 2009, pp. 94-103.