

PREDIKSI RISIKO KESEHATAN BAYI BERBASIS PARAMETER TUMBUH KEMBANG DENGAN MENGGUNAKAN GRADIENT BOOSTING

Astatia Hulu¹, Juan Sebastian Aimar², Firyal Aufa Nabilah³, Syifa Nur Rakhmah⁴,
Findi Ayu Sariasih⁵, Imam Sutoyo⁶

^{1,2,3,4,5,6}Universitas Bina Sarana Informatika

Jl. Kramat Raya No. 98, RT.2/RW.9, Kwitang, Kec. Senen, Kota Jakarta Pusat, Daerah Khusus Ibukota Jakarta,
10450, Indonesia

e-mail: ¹15230813@bsi.ac.id, ²15230635@bsi.ac.id, ³fryalaufa242@gmail.com, ⁴syifa.snr@bsi.ac.id,
⁵findi.fav@bsi.ac.id, ⁶imam.itv@bsi.ac.id

Abstrak - Kesehatan bayi merupakan indikator penting kualitas generasi masa depan, namun deteksi dini risiko kesehatan sering terkendala keterbatasan tenaga medis dan sistem pemantauan efektif. Penelitian ini mengembangkan sistem prediksi risiko kesehatan bayi berusia 0-30 hari menggunakan algoritma Gradient Boosting berdasarkan parameter tumbuh kembang. Metode pengembangan sistem menggunakan Agile Scrum dengan dataset "*Infant Wellness and Risk Evaluation*" yang melalui tahap pra-pemrosesan data dan *feature engineering*. Hasil evaluasi menunjukkan model mencapai akurasi 94%, recall 84% untuk kelas berisiko, dan precision 71%. Analisis feature importance mengidentifikasi *age_days*, *oxygen_saturation*, dan *heart_rate_zscore* sebagai fitur paling berpengaruh. Sistem prediksi berbasis web yang dihasilkan ini nantinya diharapkan dapat menjadi alat bantu yang efektif bagi tenaga medis.

Kata Kunci : Prediksi Kesehatan Bayi, Gradient Boosting, Machine Learning

Abstracts - *Infant health is an important indicator of future generation quality, but early detection of health risks is often constrained by limitations of medical personnel and effective monitoring systems. This research develops a health risk prediction system for infants aged 0-30 days using Gradient Boosting algorithm based on growth and development parameters. The system development method uses Agile Scrum with "Infant Wellness and Risk Evaluation" dataset through data preprocessing and feature engineering stages. Evaluation results show the model achieves 94% accuracy, 84% recall for at-risk class, and 71% precision. Feature importance analysis identifies age_days, oxygen_saturation, and heart_rate_zscore as the most influential features. The resulting web-based system has potential as an effective assistance tool for medical personnel.*

Keywords : *Infant Wellness Prediction, Gradient Boosting, Machine Learning*

PENDAHULUAN

Kesehatan selalu menjadi tantangan bagi manusia, di Indonesia sendiri, tantangan ini tidak terlepas dari kesehatan bayi dan balita (Saputro & Sucihermayanti, 2021). Kesehatan dan tumbuh kembang bayi merupakan indikator penting dalam menentukan kualitas generasi masa depan. Pada masa awal kehidupan, bayi sangat rentan terhadap berbagai resiko kesehatan seperti gangguan pertumbuhan, gizi buruk, ataupun infeksi. Dari indikator tersebut muncul kasus gangguan kesehatan yang tidak terdeteksi sejak dini karena kurangnya pemantauan rutin dan keterbatasan alat bantu dalam mengenali risiko Kesehatan bayi.

Terdapat beragam faktor yang berpotensi memengaruhi kesehatan bayi ketika lahir, mulai dari parameter tumbuh kembang hingga pendidikan orang tua (Fuad & Indriyani, 2023), serta pengetahuan yang dimiliki ibu mengenai gizi (Mariyani, 2021). Pemantauan Kesehatan bayi umumnya dilakukan dengan mencatat berat badan, dan lingkaran kepala setiap kunjungan ke fasilitas Kesehatan. Namun, proses ini masih bersifat manual dan tidak terintegrasi dengan sistem digital yang berarti proses analisis masih memakan waktu lebih lama karena kurangnya alat bantu digital berbasis Machine Learning yang memanfaatkan data bayi yang dapat mempercepat proses prediksi Kesehatan. Tenaga medis juga seringkali menghadapi tantangan dalam melakukan analisis cepat terhadap kondisi bayi, terutama dengan banyaknya data yang harus dipertimbangkan.

Di dunia medis, penerapan Machine Learning terbukti dapat meningkatkan efektivitas serta kualitas layanan (Agam Syahputra & Rahmi Hanifah, 2024). Penerapan Machine Learning juga dapat membantu para tenaga medis



dalam melakukan pekerjaan mereka. Misalnya, dokter dapat mendiagnosa penyakit jantung dengan bantuan Machine Learning, serta mempermudah proses klasifikasi penyakit (Telaumbanua et al., 2019).

Algoritma Gradient Boosting merupakan salah satu metode Machine Learning yang unggul dalam memproses data kompleks dan menghasilkan prediksi dengan akurasi tinggi. Model ini dipilih karena mampu menangani masalah ketidakseimbangan data melalui pendekatan ensemble yang menggabungkan beberapa model lemah menjadi satu model yang kuat (Azhari & Hidajat, 2024). Dengan memanfaatkan data tumbuh kembang seperti berat badan, Panjang badan, frekuensi makan, dan parameter vital lainnya, sistem ini diharapkan dapat membantu proses identifikasi risiko Kesehatan pada bayi.

Penelitian sebelumnya yang dilakukan oleh Jajang Jaya Purnama dan rekan - rekan, algoritma Gradient Boosting memiliki hasil akurasi tertinggi dalam memprediksi risiko kesehatan ibu hamil, yaitu di angka 79,03%. Hasil ini menunjukkan bahwa algoritma dapat memprediksi risiko kesehatan dengan sangat baik dibandingkan algoritma lainnya seperti Random Forest, Extra Trees, dan Decision Tree (Hamil et al., 2024). Pada penelitian lainnya yang dilakukan oleh Mawadatul Maulidah dan Nadiyah Hidayati, algoritma Gradient Boosting memiliki akurasi sangat tinggi yaitu 91% dalam memprediksi Kesehatan tidur. Hasil ini menunjukkan bahwa algoritma Gradient Boosting unggul dibandingkan algoritma lainnya seperti Random Forest, Support Vector Machine, Logistic Regression, KKN, dan Decision Tree dalam memprediksi Kesehatan (Maulidah & Hidayati, 2024).

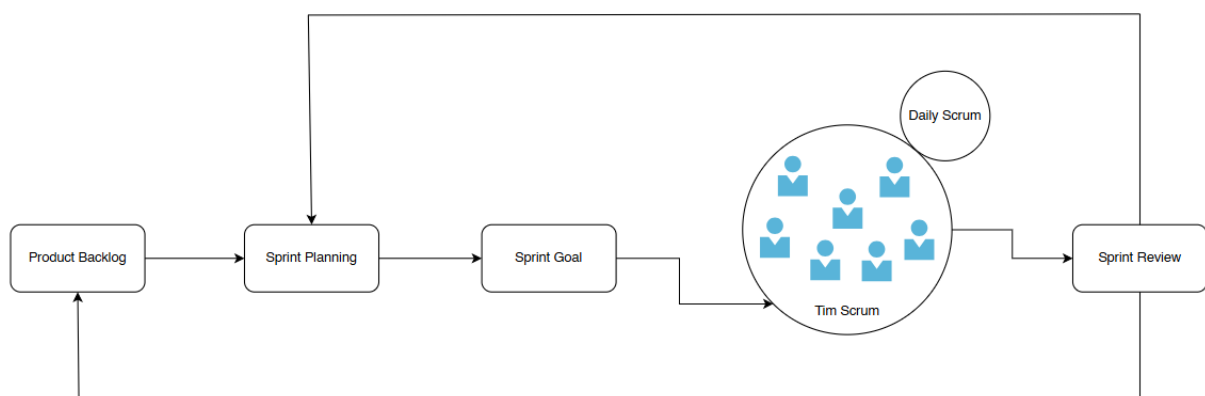
Maka, fokus penelitian ini adalah mengembangkan aplikasi berbasis web yang dapat memprediksi status risiko kesehatan bayi. Penelitian ini bertujuan untuk membangun sistem yang dapat memprediksi serta memberi rekomendasi pencegahan terhadap risiko kesehatan bayi berusia 0 – 30 hari berbasis algoritma Gradient Boosting, yang diharapkan dapat membantu orang tua dan tenaga medis sebagai alat bantu dan bukan pengganti dalam mendeteksi masalah Kesehatan bayi sejak dini dan melakukan tindakan pencegahan yang tepat.

METODE PENELITIAN

Penelitian menggunakan metode Agile Development Scrum. Pendekatan ini dipilih karena sifatnya yang iterative, adaptif dan kolaboratif, sehingga sangat cocok untuk proyek pengembangan sistem berbasis Machine Learning (ML) yang memerlukan eksperimen, evaluasi, dan penyempurnaan model secara berkelanjutan. Secara khusus, metode Agile dan Scrum telah diakui efektif dalam pengembangan sistem Machine Learning karena mampu menangani sifat eksperimental dan tidakpastian terkait dengan proyek Machine Learning (Alatawi et al., 2020). Berada dengan model *Waterfall*, Scrum tetap menjadi salah satu *framework agile* yang paling banyak digunakan karena siklus pengembangan iteratifnya, dan kemampuan adaptasi terhadap perubahan (Sunder V, 2025).

Dalam konteks penelitian ini, setiap sprint difokuskan pada penyelesaian suatu aspek kunci pengembangan model *Machine Learning*, seperti persiapan data, *feature engineering*, atau pelatihan model. Hal ini memungkinkan validasi cepat terhadap setiap komponen yang dikembangkan dan meminimalkan risiko kegagalan di akhir proyek.

Algoritma yang digunakan untuk membangun model prediksi adalah Gradient Boosting. Gradient Boosting adalah teknik *ensemble learning* yang menggabungkan beberapa model prediktif untuk menghasilkan sebuah model yang kuat dan akurat (Siswoyo et al., 2021). Algoritma ini bekerja secara sekuensial di mana setiap model baru dilatih untuk mengoreksi kesalahan yang dibuat oleh model – model sebelumnya. Implementasi algoritma ini dalam penelitian akan menggunakan *library* Scikit-learn menggunakan bahasa pemrograman Python dengan memanfaatkan *platform* Google Colab untuk mengembangkan serta melatih model. Untuk pengembangan aplikasi, sistem ini akan dibuat berbasis web dan peneliti menggunakan *code editor* Visual Studio Code beserta Flask untuk membangun sistem *backend*.




Gambar 1. Diagram *Framework Scrum*

Framework Scrum yang diimplementasikan dalam penelitian ini terdiri dari beberapa elemen dan tahapan utama, yang diadaptasi untuk konteks pengembangan sistem prediksi berbasis *Machine Learning*. Tahapan – tahapan tersebut dijelaskan sebagai berikut:

1. Product Backlog, berisi daftar utama kebutuhan fitur serta komponen sistem yang akan dikembangkan. Dalam penelitian ini mencakup:
 - a. Pengumpulan dataset “*Infant Wellness and Risk Evaluation Dataset*” dari platform Kaggle.
 - b. Pembersihan dan *preprocessing data*
 - c. *Feature engineering* berupa pembuatan fitur pertumbuhan harian serta penambahan berat terhadap frekuensi menyusui
 - d. Pengembangan model Gradient Boosting Classifier
 - e. Metriks evaluasi berupa *Accuracy, Precision, Recall, F1-Score, AUC-ROC*
 - f. Analisis *Feature Importance*
 - g. Desain *User Interface* untuk input data prediksi
 - h. Tampilan untuk hasil prediksi
2. *Sprint Planning*, bertujuan untuk menentukan tujuan *Sprint* atau *Sprint Goal*. Pembagian *sprint* sebagai berikut:
 - a. *Sprint 1*, persiapan data dan *preprocessing data*
 - b. *Sprint 2*, *feature engineering* dan eksplorasi data
 - c. *Sprint 3*, pengembangan dan penyesuaian model Gradient Boosting
 - d. *Sprint 4*, evaluasi model dan visualisasi hasil
 - e. *Sprint 5*, pengembangan *prototype* sistem
3. *Sprint Execution* (Iterasi Pengembangan), aktivitas penelitian dilakukan secara iteratif.
 - a. *Sprint* Persiapan Data
 - 1) Mengimputasi *missing values*
 - 2) Normalisasi dan *encoding data*
 - 3) Deteksi dan penanganan *outlier*
 - b. *Sprint Feature Engineering*
 - 1) Pembuatan fitur pertumbuhan harian
 - 2) Analisis korelasi antar variabel
 - c. *Sprint Modeling*
 - 1) Pelatihan model Gradient Boosting
 - 2) Optimasi *hyperparameter* (*n_estimators, learning_rate, max_depth*)
 - 3) Evaluasi dengan *cross-validation*
 - d. *Sprint* Evaluasi
 - 1) Pengujian model dengan data uji
 - 2) Analisis metriks performa
 - 3) Pembuatan *prototype* aplikasi
4. *Daily Scrum*, selama pelaksanaan *sprint*, dilakukan pertemuan singkat untuk membahas apa yang sudah dikerjakan, apa yang akan dikerjakan selanjutnya, tantangan yang dihadapi (misalnya kendala data atau performa model).
5. *Sprint Review*, setiap akhir *sprint* dilakukan *review* untuk meninjau hasil iterasi.
 - a. Menilai kualitas model yang dihasilkan
 - b. Memeriksa peningkatan akurasi atau *recall* dibandingkan *sprint* sebelumnya.
6. *Sprint Retrospective*, tahap ini dilakukan setelah *sprint review* untuk:
 - a. Mengevaluasi proses pengembangan seperti apa yang sudah baik dan perlu diperbaiki
 - b. Menentukan strategi peningkatan untuk *sprint* berikutnya seperti optimasi *preprocessing*
7. Hasil, hasil akhir dari metode ini berupa:
 - a. Model prediksi risiko kesehatan bayi berusia 0 – 30 hari berbasis Gradient Boosting
 - b. Analisis fitur penting yang memengaruhi status berisiko
 - c. *Prototype* sistem dengan tampilan sederhana

Berikut adalah diagram alur penelitian:



Gambar 2. Diagram Alur Tahapan Penelitian

HASIL DAN PEMBAHASAN

Sistem prediksi risiko kesehatan bayi berbasis parameter tumbuh kembang dikembangkan untuk membantu tenaga kesehatan dalam melakukan deteksi dini terhadap potensi gangguan kesehatan pada bayi. Sistem ini dirancang agar mampu mengolah data tumbuh kembang bayi secara lebih efektif dan memberikan hasil prediksi yang akurat dengan memanfaatkan algoritma *Gradient Boosting*. Dengan adanya sistem ini, proses analisis data dapat dilakukan secara lebih cepat dan objektif, sehingga dapat mendukung pengambilan keputusan dalam upaya pemantauan dan pencegahan risiko kesehatan bayi.

Dalam penelitian ini, model prediksi berbasis *Gradient Boosting* telah berhasil dikembangkan dan diimplementasikan melalui serangkaian tahapan mulai dari pengumpulan data, prapemrosesan, pelatihan model, hingga evaluasi kinerja. Berikut ini disajikan hasil dari setiap tahapan yang telah dilaksanakan beserta pembahasan mengenai performa model, pengaruh variabel, serta interpretasi hasil prediksi.

1. Dataset

Data yang digunakan adalah dataset dengan nama “*Infant Wellness and Risk Evaluation Dataset*” yang diambil dari platform publik Kaggle.

	baby_id	name	gender	gestational_age_weeks	birth_weight_kg	birth_length_cm	birth_head_circumference_cm	date	age_days	weight_kg
0	B001	Sara	Female	40.2	3.3	50.0	31.9	2024-12-10	1	3.28
1	B001	Sara	Female	40.2	3.3	50.0	31.9	2024-12-11	2	3.35
2	B001	Sara	Female	40.2	3.3	50.0	31.9	2024-12-12	3	3.35
3	B001	Sara	Female	40.2	3.3	50.0	31.9	2024-12-13	4	3.48
4	B001	Sara	Female	40.2	3.3	50.0	31.9	2024-12-14	5	3.50

oxygen_saturation	feeding_type	feeding_frequency_per_day	urine_output_count	stool_count	jaundice_level_mg_dl	apgar_score	immunizations_done	reflexes_normal	risk_level
98	Formula	11	9	0	4.2	7.0	Yes	Yes	At Risk
99	Formula	11	5	2	10.6	NaN	No	No	At Risk
97	Breastfeeding	7	6	5	9.8	NaN	No	No	Healthy
97	Mixed	11	8	4	8.1	NaN	No	Yes	Healthy
96	Breastfeeding	11	7	1	11.6	NaN	No	Yes	At Risk

Gambar 3. Sampel Dataset

2. Hasil Training Model untuk Data Tidak Seimbang

Pelatihan dilakukan menggunakan data yang telah diseimbangkan dengan teknik SMOTE (*Synthetic Minority Oversampling Technique*) untuk mengatasi ketidakseimbangan kelas antara kategori *Healthy* dan *At Risk*. Hasil *cross-validation* menunjukkan nilai F1-Score rata – rata sebesar 0.9536. Nilai ini menandakan bahwa model memiliki konsistensi performa yang tinggi dan cukup stabil terhadap variasi data pelatihan.

Cross-validation F1 scores: ['0.9344', '0.9294', '0.9331', '0.9508', '0.9303']
 Mean CV F1: 0.9356 (+/- 0.0156)

Gambar 4. Hasil Training Model dengan Ketidakseimbangan Data

3. Evaluasi Model

Evaluasi pada data uji menghasilkan akurasi sebesar 93.89%, meningkat 5.89% dari *baseline* (88.0%) yang menggambarkan bahwa model berhasil melakukan klasifikasi lebih baik dibandingkan pendekatan sederhana.

Classification Report:				
	precision	recall	f1-score	support
At Risk	0.71	0.84	0.77	108
Healthy	0.98	0.95	0.96	792
accuracy			0.94	900
macro avg	0.84	0.90	0.87	900
weighted avg	0.95	0.94	0.94	900

Gambar 5. Hasil Metriks Evaluasi

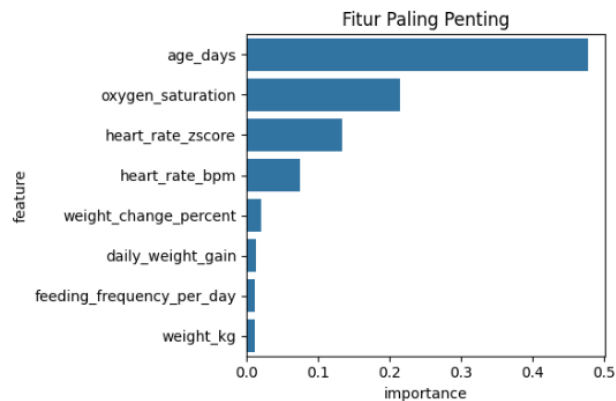
Dari gambar 3 di atas, terlihat bahwa *precision* untuk kelas *At Risk* adalah 0.71 atau 71%, yang artinya dari 100 data, model dapat memprediksi 71 data secara benar dan sisanya salah. Sedangkan, untuk kelas *Healthy*, model memiliki akurasi sebesar 0.98 atau 98% yang artinya model dapat memprediksi 98 data secara benar dari 100 data.

Recall *At Risk* dan *Healthy* masing – masing adalah 0.84 dan 0.95 yang berarti model dapat mendeteksi 84% bayi yang berisiko dan 95% bayi yang memang dinyatakan sehat.

F1-Score adalah rata – rata harmonik antara *precision* dan *recall*, yang berarti menggambarkan keseimbangan antara keduanya. F1-Score 0.77 untuk kelas *At Risk* berarti model cukup seimbang dan untuk kelas *healthy* sebesar 0.96 menunjukkan model sangat kuat untuk mendeteksi bayi sehat.

4. Analisis Feature Importance

Berdasarkan hasil analisis, kontribusi relatif dari setiap fitur dalam model dievaluasi. Delapan fitur dengan tingkat kepentingan tertinggi, yang menjadi penentu utama akurasi prediksi model.



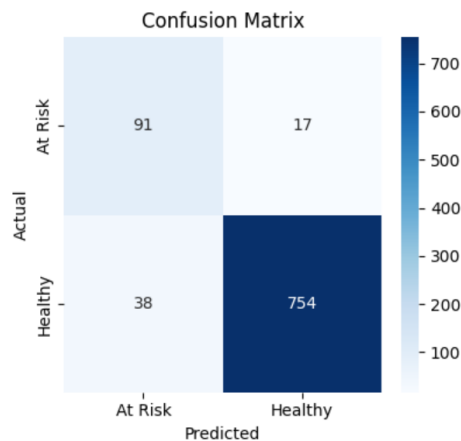
Gambar 6. Grafik *Feature Importance*

Dari grafik tersebut, terlihat bahwa berdasarkan pelatihan model, model menganggap urutan fitur tersebut mengindikasikan bahwa tanda – tanda vital dan pola pertumbuhan bayi merupakan prediktor yang paling informatif.

5. *Confusion Matrix*

Untuk mengevaluasi kinerja model klasifikasi dalam memprediksi risiko kesehatan bayi, digunakan *Confusion Matrix*. *Confusion Matrix* merupakan matriks yang menggambarkan performa model dengan membandingkan hasil prediksi terhadap nilai aktual dari data *testing*.

Evaluasi pada data uji menghasilkan akurasi sebesar 93.89%, meningkat 5.89% dari *baseline* (88.0%) yang menggambarkan bahwa model berhasil melakukan klasifikasi lebih baik dibandingkan pendekatan sederhana.



Gambar 7. *Confusion Matrix*

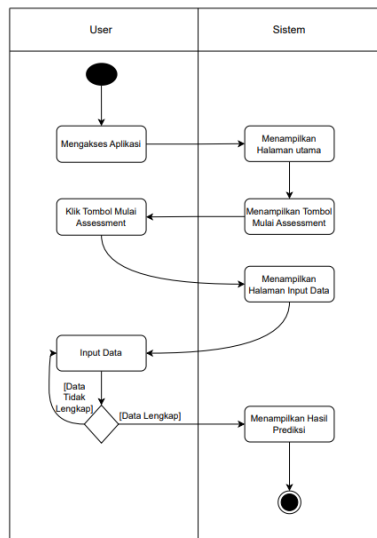
Berdasarkan *Confusion Matrix* di atas, model menunjukkan performa yang sangat baik dengan karakteristik sebagai berikut:

1. Akurasi 94%, tingkat keseluruhan prediksi yang benar.
2. *Recall* untuk *At Risk* adalah 84%, model berhasil mendeteksi 84% dari seluruh bayi yang benar – benar berisiko, dengan hanya 16% kasus berisiko yang gagal terdeteksi.
3. *Precision* untuk *At Risk* sebesar 71%, dari semua bayi yang diprediksi berisiko, 71% di antaranya merupakan benar – benar berisiko.

Confusion Matrix mengonfirmasi bahwa model memiliki performa yang sangat baik dengan kemampuan deteksi dini yang kuat dan akurasi keseluruhan prediksi yang sangat baik, sehingga dapat berpotensi digunakan sebagai alat bantu medis.

6. Activity Diagram

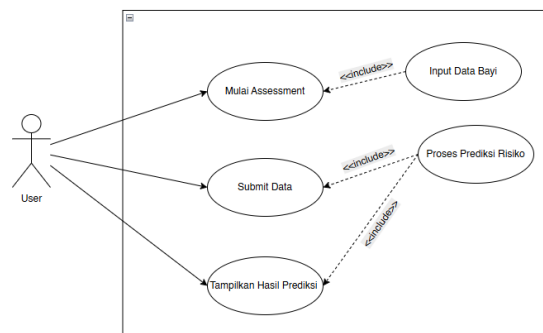
Salah satu jenis UML (*Unified Modeling Language*) yang menggambarkan alur kerja suatu sistem dari awal hingga selesai. Diagram di bawah ini menggambarkan alur sistem mulai dari pengguna mengakses aplikasi, membuka halaman input data, sampai sistem menampilkan hasil prediksi berdasarkan data yang telah di-*input* oleh pengguna.



Gambar 8. Activity Diagram

7. Use Case Diagram

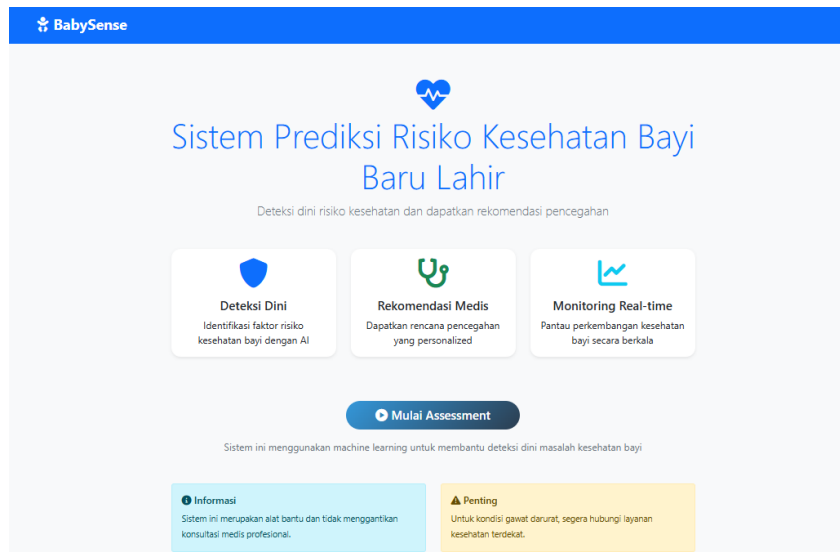
Salah satu UML yang menggambarkan interaksi antara aktor baik *user* atau sistem lain dengan sistem yang dibuat. Berikut adalah *Use Case Diagram* sistem ini. Pengguna dapat memulai *assessment* yang termasuk proses input data, lalu mengirim data serta mendapatkan hasil prediksi dari sistem yang merupakan bagian dari proses prediksi risiko oleh aplikasi.



Gambar 9. Use Case Diagram

8. Tampilan Halaman Utama Aplikasi

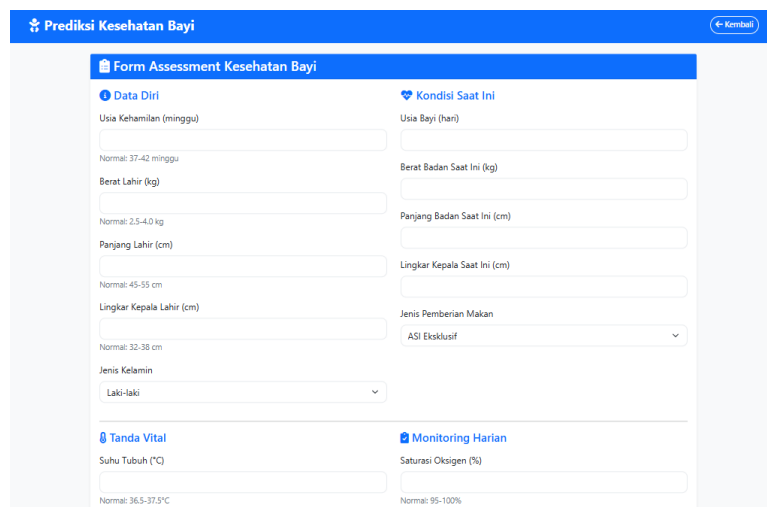
Model *Machine Learning* yang telah dibuat sebelumnya akan diintegrasikan ke dalam sebuah aplikasi berbasis web. Berikut adalah tampilan halaman utama dari sistem.



Gambar 10. Halaman Utama Aplikasi

9. Tampilan Halaman Input Data

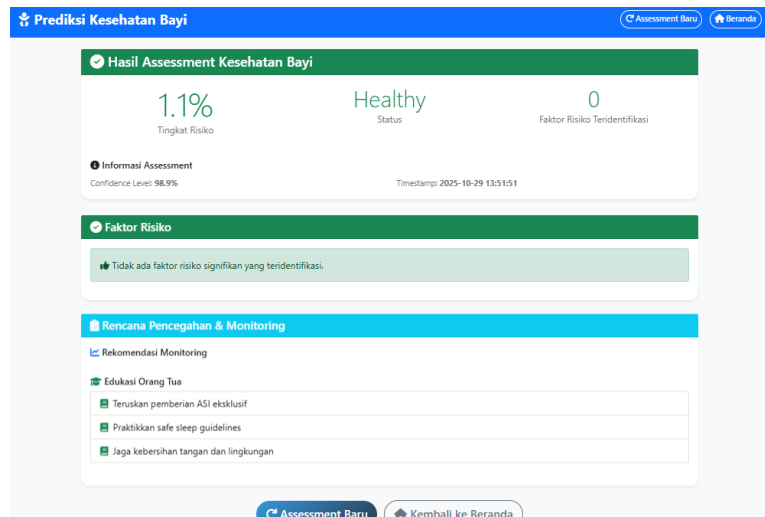
Pada gambar 6, ketika tombol “Mulai *Assesment*” diklik, *user* akan diarahkan ke halaman input data. Berikut adalah halaman input data yang dimaksud.



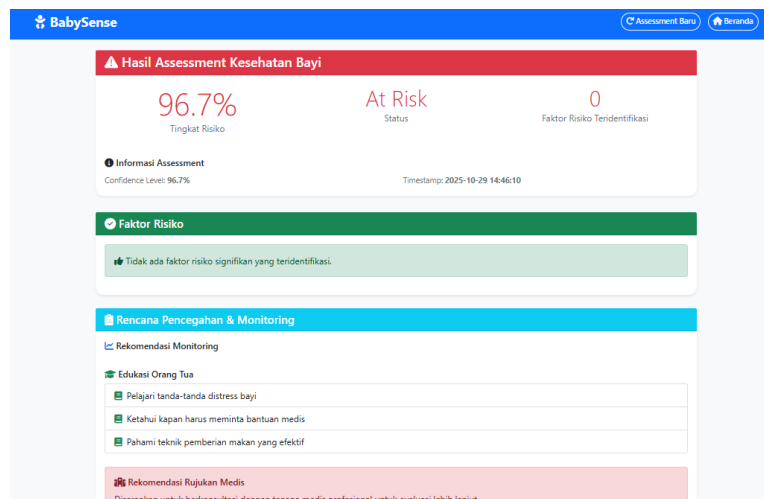
Gambar 11. Halaman Input Data

10. Tampilan Halaman Hasil Prediksi dan Rekomendasi

Setelah data di-*input*, *user* akan diarahkan ke halaman hasil prediksi untuk melihat hasil analisis beserta rekomendasi tindakan jika hasil menunjukkan status *At Risk*. Berikut tampilan dari halaman hasil prediksi.



Gambar 12. Tampilan Hasil Prediksi *Healthy*



Gambar 13. Tampilan Hasil Prediksi *At Risk*

KESIMPULAN

Model Gradient Boosting berhasil dikembangkan untuk memprediksi risiko kesehatan bayi dengan performa yang sangat baik, mencapai akurasi sebesar 94% pada data uji. Model ini menunjukkan peningkatan signifikan sebesar 5,89%. Model terbukti efektif dengan nilai *Recall* 84% dari seluruh bayi yang benar – benar berisiko. Analisis *feature importance* mengungkap bahwa parameter usia (hari) merupakan fitur paling berpengaruh, diikuti saturasi oksigen dan detak jantung. Aplikasi berbasis web juga berhasil diimplementasikan dan terintegrasi dengan model Machine Learning dengan menyediakan tampilan (UI) yang *user-friendly* untuk melakukan *assessment* secara efisien.

Untuk penelitian selanjutnya, peneliti menyarankan untuk menggunakan data primer yang diambil langsung berdasarkan data nyata di lapangan untuk meningkatkan akurasi prediksi model berdasarkan data keadaan yang realistis. Pengembangan atau integrasi sistem dengan perangkat *mobile* berbasis Android maupun iOS juga disarankan untuk memperluas aksesibilitas sistem. Eksplorasi teknik *ensemble* yang lebih dalam atau bahkan *deep learning* dapat dipertimbangkan untuk meningkatkan kemampuan deteksi model. Pengembangan fitur notifikasi dan monitoring berkelanjutan juga dapat ditambahkan untuk menciptakan sistem yang lebih komprehensif.

REFERENSI

- Agam Syahputra, R., & Rahmi Hanifah, M. (2024). Metode Analisis Kesehatan Dengan Menggunakan Mechine Learning Atau Artificial Inteligensi Atau Data Mining Literature Review. *Jurnal Industri & Inovasi (INVASI)*, 1(2), 27–38.
- Alatawi, A., Xu, W., & Xu, D. (2020). A Bigram-based Inference Model for Retrieving Abbreviated Phrases in Source Code. *ACM International Conference Proceeding Series*, 1, 11–20. <https://doi.org/10.1145/3383219.3383221>
- Azhari, D. M., & Hidajat, M. S. (2024). Klasifikasi Stunting pada Balita menggunakan Algoritma Gradient Bossting Clasifier. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 507–515. <https://doi.org/10.29408/edumatic.v8i2.27502>
- Fuad, A., & Indriyany, I. A. (2023). Sosialisasi Pencegahan Stunting sebagai Upaya Peningkatan Kualitas Kesehatan Bayi dan Anak di Kecamatan Munjul, Kabupaten Pandeglang. *Komunitas: Jurnal Pengabdian Kepada Masyarakat*, 3(1), 36–45. <https://doi.org/10.31506/komunitas:jpkm.v3i1.20556>
- Hamil, K. I., Purnama, J. J., Hikmawati, N. K., & Rahayu, S. (2024). *JOURNAL OF APPLIED COMPUTER SCIENCE AND TECHNOLOGY (JACOST) Analisis Algoritma Klasifikasi Untuk Mengidentifikasi Potensi Risiko*. 5(1), 120–127.
- Mariyani. (2021). Faktor yang Berhubungan dengan Kejadian Stunting pada Balita. *Jurnal Antara Kebidanan*, 4(2), 1177–1186. <https://doi.org/10.37063/jurnalantarakebidanan.v4i2.302>
- Maulidah, M., & Hidayati, N. (2024). *Prediksi Kesehatan Tidur Dan Gaya Hidup*. 4(1), 81–86.
- Saputro, D. T., & Sucihermayanti, W. P. (2021). Penerapan Klasterisasi Menggunakan K-Means untuk Menentukan Tingkat Kesehatan Bayi dan Balita di Kabupaten Bengkulu Utara. *Jurnal Buana Informatika*, 12(2), 146–155. <https://doi.org/10.24002/jbi.v12i2.4861>
- Siswoyo, B., Suryana, N., Abas, Z., & Dewi, A. (2021). Ensemble Learning Gradient Boosting in Improving Classification and Prediction in Machine Learning. *Turkish Journal of Computer and Mathematics Education*, 12(8), 1997–2002.
- Sunder V. (2025). Assessing the Significance of SCRUM in Agile Methodologies: Survey Insights and Proposals for Methodological Refinement. *Journal of Information Systems Engineering and Management*, 10(38s), 756–761. <https://doi.org/10.52783/jisem.v10i38s.6963>
- Telaumbanua, F. D., Hulu, P., Nadeak, T. Z., Lumbantong, R. R., & Dharma, A. (2019). Penggunaan Machine Learning. *Jurnal Teknologi Dan Ilmu Komputer Prima (JUTIKOMP)*, 3(2), 391–399.