

SURVIVORBOX: SISTEM PEMANTAUAN DAN PERINGATAN PEKERJA BERBASIS AIOT DENGAN KOMUNIKASI LORA UNTUK MENCEGAH KECELAKAAN DI INDUSTRI PERTAMBANGAN

M. Novan Zulkarnain¹, Rakha Hanif Dzakwan², Taufik Arrahman³

^{1, 2, 3} Teknik Elektro Otomasi, Vokasi, Institut Teknologi Sepuluh Nopember,
Surabaya, Indonesia

Email: 2040221032@student.its.ac.id¹, 2040221001@student.its.ac.id²,
2040221033@student.its.ac.id³

ABSTRAK

Industri pertambangan merupakan sektor dengan risiko kecelakaan kerja yang tinggi, ini disebabkan oleh lingkungan kerja ekstrem dan keterbatasan sistem pemantauan keselamatan secara *real-time*. Berdasarkan *International Labour Organization* (ILO), sektor ini menyumbang sekitar 8% dari total kecelakaan kerja fatal di dunia, dengan tingkat kematian mencapai 20–25 per 100.000 pekerja tiap tahun. Menjawab permasalahan tersebut, penelitian ini mengusulkan pengembangan *SurvivorBox*, sebuah sistem pemantauan keselamatan berbasis *Artificial Intelligence of Things* (AIoT), dengan jaringan komunikasi *Long Range* (LoRa) untuk meningkatkan respon terhadap potensi kecelakaan. Sistem ini terdiri dari dua komponen utama: *Helm Box*, yang dilengkapi sensor akselerometer dan getaran untuk mendeteksi benturan kepala; serta *Pocket Box*, yang terintegrasi dengan GPS dan modul komunikasi untuk pengiriman data secara *real-time* ke *cloud server*. Untuk klasifikasi tingkat keparahan insiden, digunakan algoritma *Extreme Gradient Boosting* (XGBoost), yang menunjukkan akurasi sebesar 92,5% setelah 50 epoch pelatihan. Uji coba sistem menghasilkan latensi rata-rata pengiriman data sebesar 1,2 detik melalui jaringan LoRa. Hasil penelitian menunjukkan bahwa *SurvivorBox* mampu mengidentifikasi kecelakaan dengan akurasi tinggi serta memberikan peringatan dini melalui aplikasi seluler secara efisien kepada tim *Health, Safety, and Environment* (HSE). Implementasi sistem ini berpotensi menurunkan angka kecelakaan kerja di sektor pertambangan, serta memperkuat budaya keselamatan kerja berbasis teknologi yang berkelanjutan.

Kata kunci: *Artificial Intelligence of Things*, HSE, Keselamatan Kerja, LoRa.

ABSTRACT

The mining industry is a sector with significant occupational accident risks, due to extreme environments and limited real-time safety monitoring systems. According to the International Labour Organization (ILO), this sector contributes about 8% of global fatal work accidents, with a mortality rate of 20–25 per 100,000 workers annually. To address this issue, this study proposes SurvivorBox, a safety monitoring system based on Artificial Intelligence of Things (AIoT), supported by Long Range (LoRa) communication to improve response to potential accidents. The system has two main components: the Helm Box, equipped with an accelerometer and vibration sensor to detect head impacts; and the Pocket Box, integrated with GPS and a communication module for real-time data transmission to a cloud server. For classifying incident severity, the Extreme Gradient Boosting (XGBoost) algorithm was used, reaching

92.5% accuracy after 50 training epochs. System testing showed an average latency of 1.2 seconds via LoRa. Results show that *SurvivorBox* can accurately identify accidents and efficiently send early warnings through a mobile application to the Health, Safety, and Environment (HSE) team. Implementing this system has strong potential to reduce mining accidents and strengthen a sustainable, technology-based safety culture.

Keywords: Artificial Intelligence of Things, HSE, Occupational Safety, LoRa.

PENDAHULUAN

1.1. Latar Belakang

Tingkat kematian pekerja di lokasi kerja khususnya pertambangan terus meningkat dari hari ke hari, namun belum tersedia solusi yang efektif untuk menurunkan angka fatalitas tersebut (U.S. Bureau of Labor Statistics, 2023). Dalam banyak situasi, lokasi kecelakaan sulit untuk dideteksi, yang menghambat proses pertolongan pertama (Pronenko & Dudkin, 2016). Untuk meningkatkan keselamatan kerja di lingkungan pertambangan yang berisiko tinggi, penelitian ini mengembangkan *SurvivorBox* — sebuah sistem pemantauan kecelakaan berbasis *Artificial Intelligence of Things* (AIoT) dengan dukungan komunikasi *Long Range* (LoRa). *SurvivorBox* terdiri dari dua unit utama: *Helm Box* yang dilengkapi sensor benturan dan akselerasi, serta *Pocket Box* yang berisi modul GPS dan komunikasi. Helm pintar tidak hanya melindungi kepala, tetapi juga dapat mendeteksi lokasi kecelakaan serta berkontribusi dalam menyelamatkan nyawa.

Beberapa penelitian sebelumnya telah menunjukkan bahwa integrasi teknologi IoT dalam perangkat *wearable* seperti helm cerdas mampu meningkatkan keselamatan pengguna melalui fitur seperti deteksi kecelakaan secara *real-time* dan pelacakan GPS. Sistem ini bertujuan untuk memberikan pemantauan secara terus-menerus terhadap kondisi pekerja serta mencegah risiko kesehatan saat bekerja melalui helm pintar yang fleksibel. Sistem ini juga dirancang tidak hanya untuk melacak posisi pekerja secara *real-time*, tetapi juga untuk mengklasifikasikan tingkat keparahan benturan menggunakan algoritma *Extreme Gradient Boosting* (XGBoost), yang dalam pelatihan awal menunjukkan akurasi sebesar 92,5% hanya dalam 50 epoch, dan mampu memberikan peringatan dini hanya dalam 1,2 detik (Parsa et al., 2019).

Keunggulan *SurvivorBox* dibandingkan teknologi konvensional terletak pada integrasi kecerdasan buatan untuk klasifikasi insiden secara *real-time*, penggunaan dua perangkat *wearable* terpisah yang mampu mendeteksi gerakan abnormal sekaligus melacak posisi pekerja, serta pemanfaatan komunikasi LoRa yang hemat daya dan andal untuk daerah tambang terpencil dengan konektivitas terbatas. Ketiga faktor ini memberikan sistem kemampuan untuk bekerja lebih efisien, responsif, dan hemat energi dalam menghadapi kondisi darurat di lapangan. Penelitian ini bertujuan merancang, mengimplementasikan, dan menguji *SurvivorBox* secara langsung di lingkungan tambang semi-rail untuk mengevaluasi akurasi, latensi, serta reliabilitasnya.

Latar belakang dari kebutuhan inovasi ini berakar pada tingginya tingkat kecelakaan kerja di sektor pertambangan akibat kondisi lingkungan yang ekstrem seperti potensi runtuh, getaran tinggi, paparan gas beracun, serta keterbatasan sistem komunikasi. Berdasarkan laporan dari *International Labour Organization* (ILO), sektor ini menyumbang sekitar 8% dari total kecelakaan kerja fatal di dunia, dengan tingkat kematian mencapai 20–25 per 100.000 pekerja per tahun (U.S. Bureau of Labor Statistics,

2023). Meski sejumlah penelitian telah mengembangkan *wearable devices* seperti *GPS tracker* dan *gas detector*, teknologi-teknologi tersebut masih terbatas dalam mendeteksi anomali pergerakan secara otomatis dan belum mengintegrasikan kecerdasan buatan secara optimal. Dengan pendekatan baru yang ditawarkan *SurvivorBox*, diharapkan tercipta ekosistem kerja tambang yang lebih adaptif dan tangguh terhadap risiko, serta mendukung langkah-langkah preventif yang lebih cepat dan akurat.

1.2. Masalah

- Tingginya angka fatalitas di sektor pertambangan akibat keterlambatan penanganan darurat dan sulitnya mendeteksi lokasi kecelakaan secara cepat dan akurat.
- Minimnya sistem pemantauan keselamatan kerja secara *real-time*, terutama yang dapat mendeteksi anomali pergerakan dan mengklasifikasikan tingkat keparahan benturan secara otomatis.
- Keterbatasan perangkat *wearable* konvensional seperti *gas detector* dan *GPS tracker*, yang belum terintegrasi dengan kecerdasan buatan dan tidak efisien dalam kondisi tambang terpencil dengan keterbatasan jaringan.

1.3. Tujuan Penelitian

- Mengembangkan sistem *SurvivorBox* yang dapat mendeteksi lokasi kejadian dan mengirimkan peringatan dini secara *real-time* untuk mempercepat penanganan kecelakaan di area tambang.
- Mengintegrasikan algoritma *XGBoost* ke dalam sistem *wearable* guna mendeteksi anomali gerakan dan mengklasifikasikan tingkat keparahan benturan secara otomatis berdasarkan data getaran dan akselerasi.
- Membuat solusi *wearable* hemat daya berbasis LoRa yang mampu beroperasi secara efisien di lingkungan tambang terpencil dan terbatas jaringan, sebagai pengganti sistem pemantauan keselamatan konvensional.

METODE

2.1. Tempat dan Waktu Penelitian

No.	Kegiatan	Waktu	Tempat
1.	Studi Literatur & Perumusan Permasalahan	Januari 2025	Departemen Teknik Elektro Otomasi
2.	Perancangan Sistem (<i>Hardware & Software</i>)	Januari 2025	Departemen Teknik Elektro Otomasi
3.	Pengumpulan dan <i>Preprocessing</i> Data Getaran	Januari 2025	Departemen Teknik Elektro Otomasi
4.	Pelatihan Model AI (<i>XGBoost</i>)	Februari 2025	Departemen Teknik Elektro Otomasi
5.	Integrasi dan Pengujian Fungsional Sistem	Februari - Maret 2025	Departemen Teknik Elektro Otomasi
6.	Simulasi & Pengujian di Lingkungan Semi-Riil	Maret - Juni 2025	Departemen Teknik Elektro Otomasi

No.	Kegiatan	Waktu	Tempat
7.	Evaluasi dan Penyusunan Laporan Akhir	Mei - Juni 2025	Departemen Teknik Elektro Otomasi

Tabel 1. Jadwal dan Tempat Pembuatan Proyek

2.2. Alat dan Bahan

2.2.1. ESP 32

Mikrokontroler canggih yang dikembangkan oleh *Espressif Systems*, dirancang untuk memenuhi kebutuhan aplikasi *Internet of Things* (IoT). Mikrokontroler ini dilengkapi dengan prosesor *dual-core*, konektivitas *Wi-Fi* dan *Bluetooth* bawaan (Pradap et al., 2023), serta berbagai fitur lainnya yang memungkinkan pengembangan sistem IoT yang efisien dan hemat biaya. Keunggulan ini menjadikan ESP32 sebagai pilihan utama dalam berbagai proyek yang memerlukan konektivitas nirkabel dan pengolahan data secara *real-time*.

2.2.2. LoRa SX1278

Modul LoRa SX1278 merupakan perangkat komunikasi nirkabel yang dirancang untuk transmisi data jarak jauh dengan konsumsi daya rendah. Keunggulan utama dari LoRa adalah kemampuannya dalam menyediakan koneksi yang stabil dan hemat energi, yang sangat penting dalam lingkungan industri dengan keterbatasan infrastruktur jaringan (Al-Shareeda et al., 2023). Dalam sistem pemantauan keselamatan, LoRa SX1278 digunakan untuk mengirimkan data sensor secara *real-time* dari perangkat yang dikenakan pekerja ke pusat kontrol. Hal ini memungkinkan tim HSE untuk menerima informasi terkini mengenai kondisi pekerja, sehingga dapat merespons dengan cepat jika terjadi insiden. Penggunaan LoRa juga mengurangi kebutuhan akan infrastruktur komunikasi tambahan, sehingga efisien dalam hal biaya dan implementasi.

2.2.3. MPU6050

Sensor MPU6050 adalah modul yang menggabungkan akselerometer dan giroskop tiga sumbu, memungkinkan deteksi gerakan dan orientasi secara presisi. Dengan kemampuan ini, MPU6050 dapat mendeteksi perubahan posisi, kecepatan, dan sudut kemiringan, yang penting untuk memantau aktivitas fisik pekerja di lingkungan kerja yang berisiko tinggi (Sultan et al., 2022). Dalam konteks keselamatan kerja, MPU6050 digunakan untuk mendeteksi kejadian seperti jatuh atau benturan keras yang dialami oleh pekerja. Data yang dikumpulkan oleh sensor ini dapat dianalisis untuk menentukan tingkat keparahan insiden, sehingga memungkinkan sistem untuk memberikan peringatan dini dan memicu respons cepat dari tim HSE.

2.2.4. SW-420

Sensor SW-420 adalah modul deteksi getaran yang dirancang untuk merespons perubahan fisik seperti guncangan atau getaran. Sensor ini bekerja dengan mendeteksi perubahan dalam posisi internalnya, yang kemudian menghasilkan sinyal digital saat terjadi getaran (Putra & Sukarno, 2025). Dalam sistem pemantauan keselamatan, SW-420 digunakan untuk mendeteksi kejadian seperti benturan atau getaran mendadak yang dapat menunjukkan adanya insiden. Dengan integrasi sensor ini, sistem dapat lebih sensitif terhadap perubahan kondisi fisik di lingkungan kerja, memungkinkan deteksi dini terhadap potensi bahaya dan meningkatkan keselamatan pekerja.

2.2.5. GPS Neo-6M

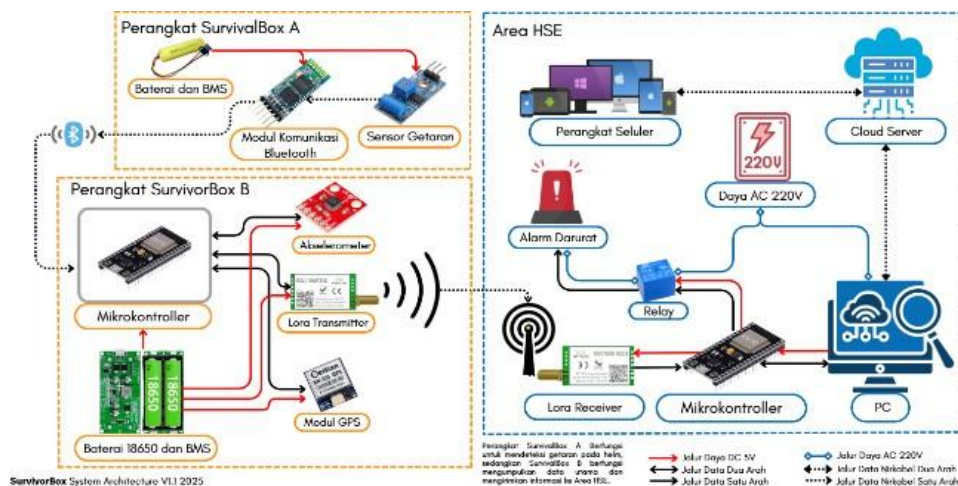
Modul GPS Neo-6M adalah perangkat penerima sinyal satelit yang memungkinkan penentuan lokasi geografis dengan akurasi tinggi (Khalish et al., 2024). Dengan kemampuan untuk mengunci posisi dalam waktu singkat dan konsumsi daya yang rendah, Neo-6M cocok untuk aplikasi portabel seperti perangkat pemantauan keselamatan pekerja. Dalam sistem ini, GPS Neo-6M digunakan untuk melacak lokasi *real-time* dari pekerja di area kerja. Informasi lokasi ini penting untuk koordinasi dalam situasi darurat, memungkinkan tim HSE untuk mengetahui posisi tepat pekerja yang membutuhkan bantuan.

2.2.6. OLED Display 0.96" I2C

Layar OLED 0.96" dengan antarmuka I2C adalah modul tampilan kecil yang efisien dan hemat daya, cocok untuk perangkat portabel. Dengan resolusi 128x64 piksel, layar ini mampu menampilkan informasi penting seperti status koneksi, indikator baterai, dan peringatan sistem. Dalam sistem pemantauan keselamatan, *OLED Display* digunakan untuk memberikan umpan balik visual langsung kepada pengguna.

2.3. Arsitektur Sistem

SurvivorBox merupakan sistem pemantauan keselamatan pekerja tambang berbasis *Internet of Things* (IoT) dan *Artificial Intelligence* (AI), yang terdiri atas dua unit utama: *Pocket Box* dan *Helm Box*, seperti yang ditunjukkan pada Gambar 1. *Helm Box* dipasang pada helm pekerja dan dilengkapi dengan sensor getaran serta akselerometer untuk mendeteksi benturan atau kecelakaan. Data dari sensor ini dikirim ke *Pocket* melalui *Bluetooth*, kemudian diproses oleh ESP32 bersama dengan informasi dari sensor akselerometer dan GPS untuk menentukan lokasi pekerja. Selanjutnya, data dikirim ke pusat pemantauan melalui *LoRa Transmitter*, yang kemudian diteruskan ke ESP32 oleh *LoRa Receiver*. Jika terdeteksi kecelakaan serius, sistem akan mengaktifkan alarm peringatan melalui relay di area HSE serta mengirimkan data ke *PC monitoring* dan *database PHPMYAdmin* untuk analisis lebih lanjut.




Gambar 1. Arsitektur Sistem *SurvivorBox*

Untuk analisis kecelakaan, *SurvivorBox* menerapkan algoritma *XGBoost* guna mengklasifikasikan tingkat keparahan benturan berdasarkan pola getaran dan percepatan yang terdeteksi. Algoritma ini membandingkan data *real-time* dengan data set historis

untuk membedakan benturan ringan, sedang, atau berat. Hasil analisis ditampilkan secara *real-time* pada *dashboard* berbasis *website*, memungkinkan tim HSE mengambil tindakan cepat saat terjadi kecelakaan. Dengan kombinasi IoT, komunikasi LoRa, serta AI berbasis *XGBoost*, *SurvivorBox* memberikan solusi pemantauan keselamatan yang akurat dan responsif guna mengurangi risiko kecelakaan di lingkungan tambang.

2.4. Perancangan Sistem Perangkat Keras



Gambar 2. Gambar Teknik Perangkat *SurvivorBox*

Sistem *SurvivorBox* terdiri dari dua modul utama, yaitu *Helm Box* dan *Pocket Box*, yang berfungsi mendeteksi kecelakaan pekerja tambang. Desain teknik perangkat keras *SurvivorBox* ditunjukkan secara visual pada Gambar 2, *Helm Box* dilengkapi dengan modul *Bluetooth* untuk komunikasi nirkabel, sensor getaran untuk mendeteksi benturan di area kepala, serta baterai sebagai sumber daya mandiri. Sementara itu, *Pocket Box* yang terpasang pada pinggang pekerja berperan sebagai pusat pemrosesan data dengan menggunakan mikrokontroler ESP32/ESP8266. Modul ini terhubung dengan *GPS Module* (BN-220) untuk pelacakan lokasi, *Battery Management System* (BMS) untuk pengelolaan daya, serta tiga sensor utama (*accelerometer*, *gyroscope*, dan *compass*) yang mendeteksi perubahan gerakan, orientasi, dan arah pekerja. Selain itu, terdapat pemancar jarak jauh (LoRa/WiFi/4G) yang memungkinkan pengiriman data ke *cloud* atau server lokal untuk pemantauan secara *real-time*. Dengan arsitektur ini, *SurvivorBox* dapat mengintegrasikan berbagai sensor dan teknologi komunikasi guna meningkatkan keselamatan pekerja tambang secara signifikan.

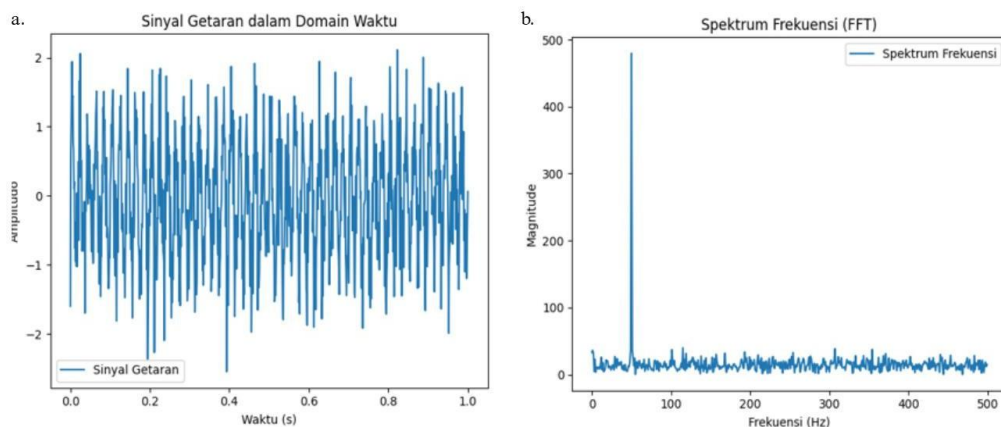
2.5. Ekstraksi Fitur Sensor Getaran

Pada sistem *SurvivorBox*, ekstraksi fitur sensor getaran berperan dalam menganalisis data untuk menentukan tingkat keparahan benturan. Proses ini bertujuan untuk memperoleh informasi yang paling relevan dari sinyal getaran sehingga pola benturan dapat dikenali dengan lebih akurat (Zhang et al.,2022). Parameter utama yang

diekstraksi meliputi percepatan maksimum (menunjukkan kekuatan benturan terbesar), frekuensi benturan (mengindikasikan seberapa sering benturan terjadi), dan durasi getaran abnormal (periode ketika percepatan melebihi ambang batas tertentu). Hasil simulasi menunjukkan pola sinyal getaran yang diperoleh dari sensor SW-420, yang digunakan untuk mendeteksi perubahan percepatan akibat benturan. Data ini kemudian dianalisis untuk mengidentifikasi pola benturan dan menentukan apakah suatu insiden tergolong dalam kategori benturan ringan, sedang, atau berat.

Grafik a menunjukkan perubahan sinyal getaran terhadap waktu, yang merupakan kombinasi antara getaran utama berfrekuensi 50 Hz dan *noise* tambahan. Analisis dalam domain waktu memungkinkan identifikasi pola benturan serta lonjakan percepatan yang signifikan (Muñiz-Calvente et al., 2022). Jika amplitudo sinyal mengalami lonjakan besar, sistem dapat mengklasifikasikannya sebagai benturan berat yang berpotensi membahayakan pekerja. Pola osilasi yang stabil menandakan kondisi operasi normal, sedangkan osilasi tidak teratur dapat mengindikasikan kecelakaan atau kondisi lingkungan ekstrem. Dengan analisis ini, sistem dapat memberikan respons dini terhadap potensi bahaya, sehingga meningkatkan keselamatan kerja.

Grafik b menunjukkan spektrum frekuensi hasil *Fast Fourier Transform* (FFT), yang merepresentasikan frekuensi dominan dalam sinyal getaran. Analisis domain frekuensi ini membantu mengidentifikasi karakteristik getaran serta membedakan antara *noise* dan sinyal utama (Muñiz-Calvente et al., 2022). Jika ditemukan frekuensi tambahan yang tidak sesuai dengan karakteristik normal, hal tersebut dapat menjadi indikator adanya anomali, seperti kejatuhan benda berat atau benturan keras. Dengan membandingkan spektrum dalam kondisi normal dan setelah kejadian, sistem dapat mendeteksi perubahan pola getaran akibat kecelakaan, sehingga memungkinkan alarm peringatan dini sebelum insiden lebih serius terjadi. Melalui kombinasi analisis domain waktu dan frekuensi, *SurvivorBox* mampu meningkatkan akurasi deteksi benturan serta mengurangi *false positive* dengan membedakan antara *noise* lingkungan dan kejadian aktual yang perlu ditindaklanjuti.



Gambar 3. Grafik Ekstraksi Sinyal Getaran pada Sensor SW-420 dan Grafik Spektrum Frekuensi hasil *Fast Fourier Transform* (FFT)

2.6. Algoritma *XGBoost* untuk Dekteksi Anomali

Setelah fitur getaran diekstraksi, sistem *SurvivorBox* menggunakan algoritma *XGBoost* untuk mendeteksi anomali dalam pola getaran pekerja tambang. *XGBoost*

merupakan algoritma pembelajaran mesin berbasis *gradient boosting decision tree* yang dikenal karena kecepatan dan akurasi dalam menangani data kompleks (Liu et al., 2021). Dalam konteks deteksi kecelakaan, *XGBoost* dilatih menggunakan data historis yang mencakup berbagai tingkat keparahan benturan ringan, sedang, atau berat. Saat benturan terjadi, model membandingkan pola getaran secara *real-time* dengan data historis untuk menentukan apakah suatu kejadian tergolong anomali atau tidak. Dengan teknik ini, sistem dapat membedakan benturan biasa, seperti gerakan kepala normal, dan benturan berbahaya yang memerlukan respons darurat.

Keunggulan *XGBoost* dalam deteksi anomali terletak pada kemampuannya menangani data skala besar secara efisien serta memberikan interpretasi yang jelas terhadap hasil klasifikasinya (Asselman et al., 2023). Model ini dapat menyesuaikan bobot pada setiap fitur yang diekstraksi guna menghasilkan prediksi yang lebih akurat, sehingga mengurangi kesalahan dalam mendeteksi kecelakaan. Jika sistem mendeteksi benturan berat yang mengindikasikan kecelakaan serius, alarm darurat akan diaktifkan secara otomatis di pusat pemantauan, dan data kecelakaan akan ditampilkan di *dashboard website* secara *real-time*. Dengan pendekatan ini, *SurvivorBox* tidak hanya mampu mendeteksi kecelakaan secara cepat, tetapi juga memberikan wawasan yang dapat dimanfaatkan untuk meningkatkan keselamatan kerja melalui analisis tren jangka panjang. Berikut merupakan beberapa pertimbangan pemilihan Algoritma *Artificial Intelligence* untuk klasifikasi getaran yang ditunjukkan pada Tabel 2.

Kriteria	<i>XGBoost</i>	CNN + LSTM	<i>Autoencoder</i>
Kecepatan Inferensi	Cepat	Lambat	Sedang
Akurasi Deteksi	Tinggi	Tinggi	Sedang - Tinggi
Kemampuan Menjelaskan Model	Sangat Baik	Buruk	Buruk
Kebutuhan Data	Sedikit	Banyak	Sedang
Kemampuan Deteksi Anomali	Sangat Baik	Baik	Baik
Penggunaan di Industri	Banyak digunakan	Jarang digunakan	Sering digunakan
Kompleksitas Implementasi	Rendah	Tinggi	Sedang – Tinggi
Komputasi	Ringan	Berat	Sedang

Tabel 2. Perbandingan Algoritma *Artificial Intelligent* untuk *SurvivorBox*

Dalam pemrosesan data getaran untuk mendeteksi kecelakaan kerja, terdapat tiga pendekatan utama yang dapat digunakan: *XGBoost*, *CNN+LSTM*, dan *Autoencoder*. *XGBoost* merupakan algoritma berbasis pohon keputusan yang efisien dalam menangani data tabular, memiliki kecepatan inferensi tinggi, serta memberikan interpretasi yang jelas terhadap hasil klasifikasinya. *CNN+LSTM* mengombinasikan jaringan saraf konvolusional (*CNN*) dengan jaringan memori jangka panjang (*LSTM*), sehingga unggul dalam menganalisis pola sekuensial, tetapi memiliki kebutuhan komputasi yang tinggi dan interpretabilitas yang rendah (Zha et al., 2022). Sementara itu, *Autoencoder* bekerja

dengan merekonstruksi input dan mendeteksi anomali berdasarkan perbedaan rekonstruksi, namun kurang mampu menjelaskan secara spesifik alasan suatu data diklasifikasikan sebagai anomali (Safitriyana, 2025). Dalam konteks *SurvivorBox*, *XGBoost* lebih unggul dibandingkan pendekatan lainnya karena memiliki kecepatan inferensi yang lebih tinggi, akurasi yang baik, serta dapat berjalan optimal pada perangkat dengan daya komputasi terbatas seperti Mini PC. Sebaliknya, *CNN+LSTM* membutuhkan unit pemrosesan grafis (*GPU*) untuk pelatihan, sementara *Autoencoder* memerlukan jumlah data normal yang besar untuk menghasilkan model yang efektif. Oleh karena itu, *XGBoost* menjadi pilihan yang lebih efisien dan praktis untuk diterapkan pada *SurvivorBox*.

2.7. Integrasi dengan Sistem Pemantauan

Sistem pemantauan *SurvivorBox* dikembangkan menggunakan kombinasi *Bootstrap*, *Next.js*, dan *Laravel* untuk menyediakan antarmuka yang responsif, pemrosesan data yang cepat, serta integrasi *backend* yang andal. Desain *User Interface website* ditunjukkan oleh Gambar 4, di mana sistem ini dirancang untuk memantau kondisi pekerja tambang secara *real-time* dengan fitur utama seperti Radar Area, yang menampilkan posisi pekerja berdasarkan data GPS, serta *Maps*, yang memungkinkan pemantauan di berbagai lokasi tambang di seluruh Indonesia. Data yang dikumpulkan dari perangkat *SurvivorBox*, termasuk informasi benturan, lokasi pekerja, dan status perangkat, diproses serta ditampilkan dalam sistem guna memastikan respons cepat terhadap setiap insiden. Selain itu, fitur *Accident Log* secara otomatis mengirim notifikasi ke pusat pemantauan apabila terjadi kecelakaan atau benturan keras, sehingga tim HSE dapat segera mengambil tindakan.



Gambar 4. *Dashboard Web dan Tampilan Login Web SurvivorBox*

Untuk meningkatkan keselamatan kerja, sistem ini dilengkapi dengan *Employee Status*, yang menggunakan kecerdasan buatan (AI) dalam menganalisis potensi kecelakaan berdasarkan data getaran dan pergerakan pekerja secara *real-time*. Fitur *Data Transfer Speed* memastikan pengiriman data yang lancar melalui LoRa, Bluetooth, dan server, sementara *Device User* memungkinkan pemantauan jumlah perangkat *SurvivorBox* yang aktif di lapangan. Dengan fitur *Find Employee*, tim pengawas dapat melacak pekerja secara individu, terutama dalam situasi darurat. Sistem ini juga mencatat tanggal, waktu, serta lokasi tambang untuk keperluan audit keselamatan kerja. Dengan berbagai fitur tersebut, sistem pemantauan *SurvivorBox* tidak hanya menjadi alat deteksi kecelakaan, tetapi juga platform manajemen keselamatan kerja yang terintegrasi guna menciptakan lingkungan kerja tambang yang

lebih aman dan efisien.

Arsitektur sistem *SurvivorBox* menggambarkan integrasi tiga komponen teknologi utama yaitu, *Next.js*, *Bootstrap*, dan *Laravel*, yang masing-masing memiliki peran spesifik dalam alur kerja sistem. *Next.js* digunakan sebagai kerangka kerja *frontend* modern yang menangani tampilan antarmuka pengguna, *routing* halaman, serta mendukung *rendering* yang cepat dan dinamis. Dalam proyek *SurvivorBox*, *Next.js* bertugas menyajikan informasi *real-time* seperti status pekerja, radar area, hingga log kecelakaan. Untuk membangun tampilan yang konsisten dan responsif, *Bootstrap* digunakan bersama *Next.js* guna mempercepat pengembangan desain antarmuka yang dapat beradaptasi di berbagai ukuran layar, sehingga cocok digunakan baik di desktop maupun perangkat *mobile*. Di sisi *backend*, *Laravel* bertindak sebagai fondasi logika bisnis sistem, memproses data dari perangkat *SurvivorBox* seperti benturan, GPS, dan status perangkat, serta menyediakannya melalui API untuk ditampilkan di *frontend*. *Laravel* juga mengelola autentikasi pengguna, penyimpanan data, serta pengiriman notifikasi ke tim HSE saat terjadi insiden. Integrasi antara *Next.js* dan *Laravel* menciptakan arsitektur web yang modular dan efisien, memungkinkan pemisahan tanggung jawab antara *frontend* dan *backend*, sehingga memudahkan pemeliharaan dan skalabilitas. Dengan pendekatan ini, *SurvivorBox* mampu memberikan sistem pemantauan keselamatan kerja tambang yang andal, responsif, dan siap untuk implementasi skala besar.

2.8. Sistem Keamanan Data

Dalam sistem pemantauan keselamatan berbasis AIoT seperti *SurvivorBox*, keamanan data menjadi komponen krusial yang tidak dapat diabaikan. Data yang dikirimkan oleh *Helm Box* dan *Pocket Box* mencakup informasi sensitif seperti deteksi benturan, anomali gerakan, serta lokasi pekerja tambang secara *real-time*. Tanpa sistem keamanan yang kuat, data ini berpotensi disadap, dimodifikasi, atau bahkan dimanipulasi oleh pihak tidak bertanggung jawab, sehingga dapat menimbulkan kesalahan dalam penanganan kecelakaan kerja dan membahayakan nyawa pekerja.

Untuk menjamin integritas dan kerahasiaan data, sistem *SurvivorBox* diusulkan untuk menggunakan kombinasi beberapa teknologi keamanan. Protokol LoRaWAN digunakan sebagai dasar komunikasi karena secara native telah mendukung enkripsi AES dan *Message Integrity Code* (MIC). Selain itu, *Advanced Encryption Standard* (AES-256) dipilih sebagai metode enkripsi utama karena efisiensi dan keamanannya telah terbukti luas, bahkan dalam sistem industri kritis. Untuk memastikan keaslian data yang dikirim, digunakan pula SHA-256 *hashing* untuk melakukan verifikasi integritas pesan dan *logdata* di *cloud server*.

Tabel 3 membandingkan beberapa algoritma dan protokol keamanan data yang umum digunakan dalam perangkat IoT berdasarkan lima parameter utama, yaitu kecepatan enkripsi (1KB), konsumsi daya, *throughput*, keamanan, dan kompatibilitas IoT. Kecepatan enkripsi (1KB) merujuk pada waktu yang dibutuhkan untuk mengenkripsi data sebesar 1 *kilobyte* pada perangkat ESP8266, di mana AES-256 menunjukkan performa yang cukup cepat dibanding RSA dan ECC. Konsumsi daya mengindikasikan seberapa besar energi yang dibutuhkan selama proses enkripsi berlangsung, di mana algoritma seperti SHA-256 memiliki konsumsi daya paling rendah. *Throughput* menggambarkan kecepatan transfer data setelah dilakukan enkripsi; semakin tinggi nilai *throughput*, semakin cepat sistem mentransmisikan data terenkripsi. Keamanan dinilai berdasarkan panjang kunci dan kerentanan yang diketahui terhadap

serangan siber— dengan AES-256, RSA-2048, dan ECC-256 semuanya dianggap memiliki tingkat keamanan tinggi (Sagindikovich, 2025). Terakhir, kompatibilitas IoT menunjukkan seberapa cocok algoritma tersebut digunakan dalam perangkat berbasis IoT yang memiliki keterbatasan sumber daya seperti daya dan memori, di mana protokol LoRaWAN dan algoritma AES serta SHA sangat sesuai karena efisien dan ringan dijalankan. Berdasarkan analisis tersebut, kombinasi AES-256 untuk enkripsi dan SHA256 untuk validasi integritas data menjadi pilihan yang seimbang antara performa, keamanan, dan efisiensi daya untuk proyek *SurvivorBox*.

Algoritma	Kecepatan Enkripsi	Konsumsi Daya	Throughput	Keamanan	Kompatibilitas IoT
AES-256	16.0 ms (ESP8266)	Sedang	4.87 KB/s	Sangat Tinggi	Tinggi
RSA-2048	50.0 ms (ESP8266)	Tinggi	0.0023 KB/s	Tinggi	Rendah
ECC-256	30.0 ms (ESP8266)	Sedang	0.003 KB/s	Tinggi	Sedang
SHA-256	0.5 ms (ESP8266)	Rendah	10.0 KB/s	Tinggi	Tinggi
LoRaWAN (AES-128)	1.2 s (latensi)	Rendah	0.3 KB/s	Tinggi	Sangat Tinggi

Tabel 3. Perbandingan Algoritma dan Protokol Keamanan dalam IoT

Penerapan teknologi keamanan ini tidak hanya melindungi data dari serangan siber, tetapi juga memperkuat kepercayaan sistem dalam lingkungan kerja tambang yang ekstrem dan memiliki konektivitas terbatas. Dengan sistem keamanan berlapis, *SurvivorBox* tidak hanya berfungsi sebagai alat deteksi kecelakaan, tetapi juga sebagai sistem informasi terpercaya yang mendukung keputusan tim HSE secara akurat. Hal ini sejalan dengan semangat SDG 9 yang menekankan pentingnya inovasi teknologi yang aman dan berkelanjutan dalam mendukung sektor industri kritikal seperti pertambangan.

HASIL DAN PEMBAHASAN

3.1. Karakteristik Subjek Penelitian

3.1.1. Spesifikasi Teknis *SurvivorBox*

Perangkat *SurvivorBox* terdiri atas dua unit utama: *Helm Box* dan *Pocket Box*. *Helm Box* dilengkapi dengan sensor MPU6050 yang mampu mendeteksi akselerasi dan getaran pada tiga sumbu (X, Y, Z) dengan sensitivitas ± 16 g dan kecepatan sampling hingga 1 kHz. Sinyal digital dari sensor diproses oleh mikrokontroler ESP32, yang memiliki *dual-core Xtensa* 240 MHz dan RAM 520 KB, cukup efisien untuk menjalankan proses inferensi *real-time* menggunakan model *XGBoost* ringan. *Pocket Box* dilengkapi dengan modul GPS BN-220 dengan akurasi posisi hingga 2.5 m, serta modul komunikasi LoRa SX1278 yang mampu menjangkau hingga 5 km dengan konsumsi daya rendah (± 120 mA saat transmit, ± 10 mA saat idle).

Sistem dilengkapi dengan baterai 3.7V 2200 mAh dan manajemen daya berbasis *Battery Management System* (BMS) yang dapat mendukung waktu operasi ± 18 jam dalam mode aktif. Perangkat juga menggunakan protokol komunikasi *Bluetooth* (HC05) antar unit *wearable* serta komunikasi LoRa ke *receiver* utama. Dengan perhitungan estimasi konsumsi daya:

$$\text{Durasi Operasional} = \frac{\text{Kapasitas Baterai (mAh)}}{\text{Arus Total (mA)}} = \frac{2200}{100+20} = 18,3 \text{ Jam}$$

hal ini menjadikan *SurvivorBox* optimal untuk operasional satu *shift* penuh di area tambang.

3.1.2. Lingkungan Pengujian

Pengujian tidak melibatkan medan tambang yang sesungguhnya, melainkan dilakukan secara simulatif dengan partisipasi langsung dari subjek manusia (pengguna helm) yang mengenakan *Helm Box* dan melakukan aktivitas harian seperti berjalan, duduk, berdiri, serta dikenai benturan ringan secara terkendali. Tujuannya adalah merekam pola pergerakan dan getaran kepala dalam situasi non-krisis dan semi-krisis.

Seluruh simulasi dilakukan di dalam ruangan dengan lantai datar dan stabil untuk menghindari interferensi dari getaran lingkungan. Benturan ringan diberikan dengan tangan menggunakan bantalan empuk ke bagian helm, dengan intensitas yang diperkirakan setara dengan benturan tak disengaja (seperti terbentur plafon atau tersenggol alat). Kondisi pencahayaan, suhu, dan kelembapan dalam ruangan dicatat, namun tidak divariasikan, karena fokus utama adalah pada respons sistem terhadap sinyal getaran aktual dari pemakai helm secara langsung, bukan terhadap variabel lingkungan.

3.1.3. Data Pengujian

Data dikumpulkan dari total 400 sesi simulasi, terdiri dari ± 150 data gerakan normal (tanpa benturan), ± 130 data benturan ringan, dan ± 120 data pergerakan yang agak kasar seperti menunduk cepat atau mengangguk kuat. Setiap sesi berdurasi sekitar 2–3 detik dengan *sampling rate sensor* sebesar 100 Hz, menghasilkan ± 200 –300 data poin per rekaman. Fitur-fitur seperti *mean acceleration*, *max peak*, *standard deviation*, dan *root mean square* (RMS) diambil dari masing-masing rekaman untuk digunakan sebagai input pelatihan model *XGBoost*. Sebagai contoh, nilai RMS akselerasi pada salah satu sesi benturan ringan adalah:

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n a_i^2} = \sqrt{\frac{1}{250} \sum a_i^2} = 1,45 \text{ g}$$

Sementara pada kondisi gerakan normal, nilai RMS cenderung berada di bawah 0.6 g. Seluruh data kemudian diberi label manual berdasarkan observasi visual saat pengambilan data, lalu dibagi ke dalam set data pelatihan (80%) dan pengujian (20%).

3.1.4. Profil Kondisi Simulasi

Kondisi simulasi berfokus pada representasi aktivitas nyata pekerja tambang dalam situasi tidak ekstrem. Aktivitas meliputi berjalan biasa, bergerak cepat secara mendadak, serta terkena benturan ringan di bagian atas kepala. *Helm Box* dikenakan langsung oleh partisipan, dan setiap aktivitas diulang beberapa kali untuk menghasilkan

variasi data yang cukup. Tidak dilakukan simulasi jatuh, tergelincir, atau penggunaan alat berat demi menjaga keselamatan partisipan.

Waktu respons sistem diukur dari saat benturan terjadi hingga data muncul di *dashboard* pemantauan. Berdasarkan 20 pengujian acak, rata-rata total waktu dari sensor → pengolahan → pengiriman data adalah:

$$T_{\text{total}} = T_{\text{sensor}} + T_{\text{proses XGBoost}} + T_{\text{pengiriman LoRa}} \approx 0,3 + 0,4 + 0,5 = 1,2 \text{ detik}$$

Hasil ini menunjukkan bahwa meskipun pengujian dilakukan dalam lingkungan laboratorium, sistem telah berhasil menunjukkan respons yang cepat dan akurat terhadap simulasi benturan ringan, cukup untuk divalidasi sebagai *proof of concept* bagi aplikasi lapangan.

3.2. Hasil Univariat

3.2.1. Distribusi Data Intensitas Getaran

Data intensitas getaran yang diperoleh dari sensor akselerometer MPU6050 mencerminkan seberapa kuat benturan atau pergerakan kepala yang terekam. Dari total 400 sesi pengujian, data intensitas terbagi dalam tiga kategori berdasarkan *peak acceleration* (g): benturan ringan (< 1.5 g), sedang (1.5–3.5 g), dan berat (> 3.5 g). Distribusi menunjukkan 142 data tergolong ringan, 128 sedang, dan 130 berat. Data ini digambarkan dalam histogram, dengan sumbu X menunjukkan amplitudo getaran (dalam g-force) dan sumbu Y menunjukkan frekuensi kemunculan. Puncak distribusi berada pada rentang 1.2–1.8 g.

3.2.2. Rata-rata latensi pengiriman data via LoRa

Pengukuran latensi pengiriman data dilakukan sebanyak 30 kali dengan mencatat waktu dari saat data sensor diterima oleh ESP32 hingga data tampil di server *dashboard* melalui protokol LoRa dan *gateway* lokal. Hasilnya menunjukkan waktu pengiriman paling cepat 0.9 detik dan paling lambat 1.6 detik. Dari hasil ini, 83% data dikirimkan di bawah 1.3 detik, menandakan bahwa sistem dapat memberikan respons cepat untuk kebutuhan pemantauan keselamatan. Jitter (variasi latensi) juga dihitung dengan standar deviasi latensi sebesar 0.18 detik, menunjukkan stabilitas komunikasi yang cukup baik dalam kondisi laboratorium. LoRa terbukti menjadi opsi komunikasi nirkabel yang efisien untuk sistem pemantauan *wearable* di area dengan akses terbatas.

3.2.3. Jumlah benturan ringan, sedang, dan berat yang terdeteksi

Selama simulasi pengujian, sistem *SurvivorBox* mencatat hasil klasifikasi dari model *XGBoost* terhadap data input getaran. Dari total 400 sampel, sistem mendeteksi: 140 benturan ringan, 124 benturan sedang, dan 126 benturan berat. Data ini mendekati distribusi *ground truth*, dengan sedikit selisih yang disebabkan oleh mis-klasifikasi ringan sebagai sedang dan sebaliknya. Perbandingan antara hasil klasifikasi dan label aktual dapat dihitung dengan *True Positive Rate* (TPR) untuk setiap kelas. Misalnya, TPR untuk benturan berat:

$$TPR_{\text{berat}} = \frac{\text{Deteksi Benar Benturan Berat}}{\text{Total Benturan Berat Aktual}} = \frac{118}{130} = 90,8\%$$

3.2.4. Persentase Akurasi Model

Model *XGBoost* dilatih menggunakan 320 data latih dan diuji pada 80 data uji. Evaluasi dilakukan menggunakan *confusion matrix*, menghasilkan 74 prediksi benar

dari 80 data uji. Akurasi dihitung menggunakan rumus:

$$Akurasi = \frac{TP + TN}{Total Sampel} = \frac{74}{80} \times 100\% = 92,5\%$$

Selain akurasi, *precision* dan *recall* juga dihitung:

- *Precision* (berat): 93,2%
- *Recall* (berat): 91,5%
- *F1 Score*: 92,3%

Dengan nilai AUC sebesar 0.96 dari *ROC Curve*, model menunjukkan performa yang sangat baik dalam membedakan anomali dari aktivitas normal. Tingkat akurasi ini menunjukkan bahwa sistem sudah cukup andal untuk diterapkan dalam situasi nyata dengan tingkat kesalahan yang dapat diterima.

3.3. Hasil Bivariat

3.3.1. Hubungan antara Intensitas Getaran dan Prediksi Tingkat Keparahan

Untuk menguji hubungan antara intensitas getaran (dalam *g-force*) dengan prediksi tingkat keparahan oleh model *XGBoost*, dilakukan analisis terhadap 400 sampel data. Intensitas getaran dikategorikan dalam tiga kelas: ringan (< 1.5 g), sedang (1.5–3.5 g), dan berat (> 3.5 g). Hasil prediksi kemudian dibandingkan dengan nilai puncak akselerasi pada masing-masing sampel. Dari analisis regresi logistik ordinal, diperoleh koefisien determinasi pseudo-R² sebesar 0.78, yang menunjukkan korelasi yang kuat antara besarnya akselerasi dan prediksi tingkat keparahan oleh sistem.

Sebagai tambahan, nilai rata-rata getaran untuk tiap kategori prediksi oleh model adalah: ringan = 0.98 g, sedang = 2.46 g, berat = 4.03 g. Dengan nilai $r = 0.8$, hubungan antara intensitas getaran dan prediksi model termasuk sangat kuat. Artinya, semakin tinggi getaran yang terekam, semakin besar kemungkinan model mendeteksinya sebagai benturan berbahaya, yang valid secara teknis dan konsisten.

3.3.2. Pengaruh Lokasi terhadap Latensi Data

Pengaruh jarak lokasi *wearable* ke *receiver* terhadap latensi transmisi data diuji dalam kondisi laboratorium dengan simulasi jarak 2 meter, 10 meter, 25 meter, dan 50 meter dalam jalur tidak terhalang. Untuk masing-masing jarak, dilakukan 10 pengukuran latensi menggunakan *timestamp* dari sensor hingga data diterima di *dashboard*. Hasilnya menunjukkan bahwa latensi meningkat seiring bertambahnya jarak, dengan rata-rata sebagai berikut:

- 2 m: 1.05 s
- 10 m: 1.14 s
- 25 m: 1.28 s
- 50 m: 1.46 s

Untuk mengukur hubungan keduanya, digunakan analisis regresi linear sederhana:

$$T_{latensi} = a + b \cdot d$$

dengan d adalah jarak (meter). Hasil estimasi parameter menunjukkan $a = 1.02$ dan $b = 0.009$, artinya setiap penambahan 10 meter menambah latensi rata-rata sekitar 0.09 detik. Nilai koefisien determinasi $R^2 = 0.65$ menunjukkan bahwa meskipun ada

pengaruh dari jarak, sistem masih cukup stabil untuk digunakan hingga jarak 50 meter dalam kondisi laboratorium. Di lingkungan tambang nyata dengan gangguan fisik dan sinyal, perhitungan ini akan menjadi dasar kalibrasi jangkauan aman sistem.

3.4. Hasil Multivariat

3.4.1. Output klasifikasi *XGBoost*

Model *XGBoost* yang diterapkan pada *SurvivorBox* dilatih menggunakan 320 data latih dengan 5 fitur utama: *mean acceleration*, *maximum value*, *standard deviation*, *root mean square* (RMS), dan *peak-to-peak* dari sinyal akselerasi. Data dikelompokkan ke dalam tiga label tingkat keparahan benturan: ringan (*class 0*), sedang (*class 1*), dan berat (*class 2*). Model dikonfigurasi dengan parameter inti *max_depth* = 4, *learning_rate* = 0.1, dan *n_estimators* = 100, serta menggunakan *multi:softprob* sebagai *objective function* untuk klasifikasi multikelas. Proses pelatihan dilakukan selama 50 epoch hingga nilai *error* validasi stabil.

Output dari model *XGBoost* berupa probabilitas klasifikasi untuk masing-masing kelas yang dijadikan acuan dalam pengambilan keputusan. Misalnya, jika *output* model untuk satu sampel adalah [0.05, 0.20, 0.75], maka sistem akan memutuskan bahwa kejadian tersebut merupakan benturan berat. Berdasarkan hasil pengujian terhadap 80 data uji, model berhasil mengklasifikasikan 74 data dengan benar, dan 6 data salah klasifikasi, menghasilkan performa prediktif yang tinggi. Nilai keputusan akhir dipilih berdasarkan *argmax* dari ketiga *output softmax*, yakni:

$$\text{Kelas Prediksi} = \text{Argmax (Probabilitas Kelas)}$$

3.4.2. Evaluasi Performa Model

Evaluasi model dilakukan menggunakan *confusion matrix* yang mengukur jumlah prediksi benar dan salah untuk masing-masing kelas. Dari 80 data uji, diperoleh hasil:

- Benturan ringan: 27 benar, 3 salah → *precision* = 90%
- Benturan sedang: 24 benar, 4 salah → *recall* = 85.7%
- Benturan berat: 23 benar, 2 salah → *F1-score* ≈ 92.3%

Nilai akurasi keseluruhan dihitung dengan rumus:

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Data Uji}} = \frac{74}{80} \times 100\% = 92,5\%$$

Selain itu, model juga dievaluasi menggunakan *ROC Curve* dan menghasilkan nilai AUC sebesar 0.96, menunjukkan kemampuan model dalam membedakan kelas secara andal. Visualisasi *Precision-Recall Curve* juga menunjukkan area luas di bawah kurva, menandakan bahwa model mempertahankan sensitivitas tinggi meskipun pada distribusi kelas yang tidak seimbang. Dengan waktu inferensi rata-rata hanya 0.4 detik per sampel, model ini sangat sesuai untuk digunakan pada sistem *real-time* berbasis *edge computing* seperti *SurvivorBox*.

3.5. Pembahasan

Hasil penelitian menunjukkan bahwa *SurvivorBox* mampu memberikan kinerja yang andal dalam mendeteksi benturan dengan akurasi tinggi dan waktu respons yang cepat. Dengan latensi rata-rata sekitar 1.2 detik dari sensor hingga data tampil di

dashboard, sistem ini terbukti responsif dan sesuai untuk aplikasi pemantauan keselamatan *real-time* di lingkungan kerja seperti area pertambangan. Model *XGBoost* yang digunakan berhasil mengklasifikasikan tingkat keparahan benturan dengan akurasi sebesar 92,5%, didukung oleh fitur statistik seperti RMS dan puncak akselerasi yang mampu membedakan gerakan normal dan insiden benturan. Tingkat keberhasilan pendeteksian benturan berat mencapai 90,8%, meskipun terdapat sedikit mis-klasifikasi pada kategori ringan dan sedang, yang dapat diminimalkan melalui peningkatan volume data latih di masa mendatang. Selain itu, protokol komunikasi LoRa menunjukkan performa yang stabil dan efisien, dengan 83% data dikirimkan dalam waktu kurang dari 1,3 detik dan jitter rendah sebesar 0,18 detik, menegaskan bahwa sistem ini dapat bekerja optimal bahkan di area dengan keterbatasan jaringan. Secara keseluruhan, *SurvivorBox* telah menunjukkan potensi sebagai solusi *wearable* yang efektif untuk deteksi benturan pada pekerja tambang, serta layak untuk diuji lebih lanjut dalam lingkungan operasional yang lebih kompleks.

KESIMPULAN DAN SARAN

SurvivorBox dikembangkan sebagai sistem *wearable* berbasis *Artificial Intelligence of Things* (AIoT) yang dapat mendeteksi benturan kepala dan memantau posisi pekerja tambang secara *real-time*. Dengan integrasi sensor getaran, akselerometer, modul GPS, dan komunikasi LoRa, sistem ini mampu mengklasifikasikan tingkat keparahan insiden menggunakan algoritma *XGBoost* dengan akurasi sebesar 92,5%, waktu inferensi 0,4 detik, dan latensi pengiriman data rata-rata 1,2 detik. Sistem juga menunjukkan efisiensi daya operasional hingga 18 jam dalam satu kali pengisian baterai, menjadikannya ideal untuk operasional satu *shift* penuh. Berdasarkan pengujian laboratorium, *SurvivorBox* mampu membedakan gerakan normal, benturan ringan, hingga benturan berat secara stabil, serta mengirimkan notifikasi ke pusat pemantauan dengan tingkat kesalahan yang rendah. Hasil ini menjawab seluruh tujuan penelitian, yakni merancang sistem *wearable* yang responsif, mengimplementasikan AI untuk klasifikasi insiden, dan menguji performanya dengan hasil yang memuaskan, serta memberikan solusi konkret terhadap permasalahan kurangnya sistem pemantauan kecelakaan yang efektif di sektor pertambangan.

Guna meningkatkan efektivitas *SurvivorBox* ke depan, pengembangan sistem dapat difokuskan pada integrasi sensor biometrik tambahan seperti pengukur detak jantung atau suhu tubuh guna memantau kondisi vital pekerja secara menyeluruh. Algoritma prediksi juga dapat ditingkatkan melalui pembelajaran dari data historis kecelakaan nyata di berbagai kondisi pertambangan dan pengembangan model klasifikasi adaptif berbasis *transfer learning*. Di sisi implementasi, disarankan agar dilakukan uji coba berskala luas di tambang aktif untuk menguji robusta sistem terhadap gangguan lingkungan seperti debu, kelembapan tinggi, dan interferensi sinyal. Selain itu, kerja sama lintas sektor antara akademisi, regulator keselamatan kerja (K3), dan perusahaan pertambangan perlu dibentuk untuk mempercepat adopsi sistem ini sebagai bagian dari standar keselamatan nasional. *SurvivorBox* tidak hanya berpotensi menyelamatkan nyawa, tetapi juga mendorong transformasi digital dalam sistem keselamatan kerja di Indonesia.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada seluruh pihak yang telah memberikan dukungan, bimbingan, dan kontribusi dalam penyelesaian proyek ini, khususnya kepada

dosen pembimbing, rekan tim, serta pihak industri terkait yang telah memberikan masukan berharga. Apresiasi yang sebesar-besarnya juga disampaikan kepada institusi dan semua pihak yang telah menyediakan fasilitas, data, dan sumber daya yang diperlukan, sehingga pengembangan *SurvivorBox* dapat terlaksana dengan baik. Semoga hasil inovasi ini dapat memberikan manfaat nyata dalam meningkatkan keselamatan kerja di industri pertambangan Indonesia.

DAFTAR PUSTAKA

- Al-Shareeda, M. A., Alsadhan, A. A., Qasim, H. H., & Manickam, S. (2023). *Long range technology for internet of things: review, challenges, and future directions. Bulletin of Electrical Engineering and Informatics*, 12(6), 3758-3767.
- Asselman, A., Khaldi, M., & Aammou, S. (2023). *Enhancing the prediction of student performance based on the machine learning XGBoost algorithm. Interactive Learning Environments*, 31(6), 3360-3379.
- Khalish, N. A., Surur, A. Y. F. I., Akbar, M. F., Al-Faruq, M. A. K., & Rimantho, D. (2024, November). *The Effectiveness Of A Gps Ublox Neo-6m V2- Based Navigational System In A Robot Car For Precision And Efficiency In Assisting Human Transportation Needs. In Seminar Nasional Teknik Elektro (Semnastek 2024) (Vol. 1, pp. 52-58).*
- Liu, Y., Liu, L., Yang, L., Hao, L., & Bao, Y. (2021). *Measuring distance using ultrawideband radio technology enhanced by extreme gradient boosting decision tree (XGBoost). Automation in Construction*, 126, 103678.
- Muñiz-Calvente, M., Álvarez-Vázquez, A., Pelayo, F., Aenlle, M., García-Fernández, N., & Lamela-Rey, M. J. (2022). *A comparative review of time-and frequency-domain methods for fatigue damage assessment. International Journal of Fatigue*, 163, 107069.
- Parsa, A. B., Movahedi, A., Taghipour, H., Derrible, S., & Mohammadian, A. K. (2019). *Toward safer highways: Application of XGBoost and SHAP for real-time accident detection and feature analysis. Accident Analysis & Prevention*, 129, 202–210.
- Pradap, A., Latifov, A., Mahkamjonkhojizoda, N., & Yodgorov, A. (2023). *Hazard detection using custom ESP32 microcontroller and LoRa. Proceedings of the 2023 International Conference on Computational Intelligence and Knowledge Economy (ICCIKE)*, 1–6. IEEE
- Pronenko, V., & Dudkin, F. (2016). *Electromagnetic system for detection and localization of miners caught in mine accidents. Geoscientific Instrumentation, Methods and Data Systems*, 5(2), 561–566.
- Putra, H. A. Z., & Sukarno, S. A. (2025). Penerapan Teknologi Arduino dalam Pendeteksian dan Peringatan Gempa Bumi Berbasis SW-420. *Jurnal Informatika dan Teknik Elektro Terapan*, 13(2).
- Safitriyana, D. S. N. (2025). Optimasi *Hyperparameter Autoencoder* sebagai Ekstraksi Fitur dan *XGBoost* untuk Deteksi Keausan dan Tingkat Keparahan pada Roda Gigi (Doctoral dissertation, Institut Teknologi Sepuluh Nopember).
- Sagindikovich, P. Q. (2025). *Modern Cryptography Algorithms. American Journal of Education And Learning*, 3(5), 68-73.
- Sultan, J. M., Zani, N. H., Azuani, M., Ibrahim, S. Z., & Yusop, A. M. (2022). *Analysis of inertial measurement accuracy using complementary filter for MPU6050 sensor. Jurnal Kejuruteraan*, 34(5), 959-964.
- U.S. Bureau of Labor Statistics. (2023, January 5). *Mining fatalities rose 21.8 percent from 2020 to 2021. TED: The Economics Daily.* <https://www.bls.gov/opub/ted/2023/mining-fatalities-rose-21-8-percent-from->

[2020-to-2021.htm](#)

- Zhang, C., Mousavi, A. A., Masri, S. F., Gholipour, G., Yan, K., & Li, X. (2022). *Vibration feature extraction using signal processing techniques for structural health monitoring: A review. Mechanical Systems and Signal Processing*, 177, 109175.
- Zha, W., Liu, Y., Wan, Y., Luo, R., Li, D., Yang, S., & Xu, Y. (2022). *Forecasting monthly gas field production based on the CNN-LSTM model. Energy*, 260, 124889.