

REWS-GAMA (Radiation Early Warning System) : Modul EWS dengan Sistem Evakuasi Cerdas berbasis Algoritma Dijkstra-Modifikasi untuk Mendukung Sistem Proteksi Fisik

Jalalludin Mukhtafi¹⁾, Moehammad Alridz Al Farabi Pasha²⁾, dan Nazrul Effendy³⁾

^{1,2)}Program Sarjana Teknik Nuklir, Fakultas Teknik, Universitas Gadjah Mada, Yogyakarta

³⁾Dosen Departemen Teknik Nuklir dan Teknik Fisika, Fakultas Teknik, Universitas Gadjah Mada, Yogyakarta

Corresponding Author: Nazrul Effendy (Email: nazrul@ugm.ac.id)

Abstract

In the past few years, nuclear security advancements have been aggressively pursued. In addition to Indonesia's efforts with the establishment of the Hypothetical Nuclear Safety Facility (HNPRF), nuclear global organizations such as the IAEA and ICRP have been actively evaluating evacuation safety using current technology. One of these technological implementations is the REWS module, which has been adopted by many countries, including Lebanon. However, conventional REWS tends to rely on manual procedures, requiring experts to conduct separate analysis and validation, which cannot be performed in real-time. This study aims to develop an AIoT-integrated REWS module to enhance evacuation route response and predictive radiation systems. This research consists of two assessments: a hypothetical study (conducted at the HNPRF) and a pilot study (conducted on the 2nd floor at DTNTF). The proposed solution architecture includes two conditions—"normal" and "hazardous"—by inserting a reference location or initial worker position along with the final evacuation destination. This system provides an evacuation route using a modified Dijkstra algorithm (without weight). Finally, the data visualization is transmitted to Pekerja Proteksi Radiasi (PPR) and local workers, allowing them to follow the recommended evacuation path. The pilot simulation results indicate the most effective exit route, leading to the nearest evacuation point, with an accumulated dose of $1.355 \times 10^{-3} \mu\text{Sv}$, a travel distance of 19.49 meters, and an evacuation time of 8.77 seconds when running. The hypothetical simulation at HNPRF involved two start-point scenarios. In the first scenario (start point-1: front door), the optimal route to end point-1 had an accumulated dose of $4.853 \times 10^{-3} \mu\text{Sv}$, a travel distance of 66.38 meters, and an evacuation time of 29.8 seconds while running. Meanwhile, in the second scenario (start point-2: emergency door), the best route led to end-point-3 (emergency gate), with an accumulated dose of $1.236 \times 10^{-2} \mu\text{Sv}$, a travel distance of 161.21 meters, and an evacuation time of 72.55 seconds while running.

Keywords: Artificial intelligence, dijkstra algorithm, early warning system, IoT, radiation

1. Pendahuluan

1.1. Latar Belakang

Tempo hari, BATAN berencana membangun Reaktor Daya Experimental (RDE) dan iradiator Gamma di Area Nuklir, Serpong, Banten. RDE ini akan menjadi basis demonstrasi tentang kemampuan aspek

keselamatan radiasi nuklir di Indonesia dalam mewujudkan pembangunan PLTN kedepannya. Adanya segala instalasi nuklir tersebut memunculkan potensi peningkatan risiko paparan radiasi dari fasilitas nuklir ke lingkungan dan masyarakat. Pelepasan radionuklida yang tidak terkendali ke

lingkungan atmosfer, perairan, hingga darat dapat terjadi akibat kecelakaan nuklir atau radiologi (Farid et al., 2017).

Disisi lain, regulasi dan rekomendasi kebijakan dalam bencana nuklir telah diatur oleh IAEA and International Commission on Radiological Protection (ICRP). Rekomendasi tersebut mencakup sarana & prasarana, yakni *sheltering*, evakuasi, dan relokasi. Namun, beberapa penelitian menunjukkan bahwa evakuasi dan relokasi menyebabkan dampak kesehatan yang serius. Misalnya di bencana Fukushima, dimana evakuasi warga yang terpapar radiasi menuju rumah sakit terdekat menyebabkan banyak pasien renta yang dirawat ikut terpapar dan berakhir meninggal dunia (Tanigawa et al., 2012). Tak hanya itu, (Ohba et al., 2021) menemukan fakta dari kajian literatur sebanyak 634 artikel, ditemukan bahwa sebagian dampak bencana nuklir diperparah kala rencana evakuasi tidak jelas atau tidak disosialisasikan dengan baik ke pekerja maupun warga sekitar. Misalnya yang terjadi di TMI Nuclear Power Plant, Amerika Serikat pada tahun 1979, dimana warga sekitar tidak memiliki rencana evakuasi. Kemudian terdapat Chernobyl, Uni Soviet pada tahun 1986, dimana rencana evakuasi mereka memiliki kecacatan dan ketidaksiagapan dalam skala yang besar. Lebih lanjut ada Fukushima Daiichi di Jepang pada tahun 2011, dimana warga sekitar yang berlokasi di 10 km dari lokasi tidak diberitahu rencana evakuasi dari pemerintah setempat. Dalam kejadian bencana nuklir, ketidakpastian lokasi PLTN setelah terjadinya bencana membuat publik cemas dan ketidaktersediaan informasi akan memperburuk situasi.

Secara keseluruhan, aspek keselamatan fasilitas nuklir baik sekadar instalasi hingga PLTN memerlukan transparansi informasi berupa dosis radiasi di lokasi hingga strategi monitoring keseluruhan untuk keadaan darurat, dengan mempertimbangkan potensi jalur paparan guna meminimalkan dosis radiasi bagi pekerja dan warga yang terpapar.

Tak hanya itu, solusi lain yang ditawarkan adalah monitoring radiasi secara teratur pada area pelepasan bahan radioaktif sebagai langkah penting dalam melindungi

masyarakat dan lingkungan terhadap radiasi (Farid et al., 2017).

Solusi tersebut ditegaskan kembali pada dokumen International Atomic Energy Agency (IAEA) RS-G-1.8, dimana dalam situasi intervensi, fasilitas nuklir diharuskan melakukan tindakan untuk mengurangi atau menghentikan penyebaran radiasi, baik dalam kondisi darurat maupun kronis. Keputusan mengenai tindakan ini diambil oleh pemangku kepentingan berdasarkan data hasil monitoring (IAEA, 2005).

Berkaca dari hal tersebut, sudah banyak beberapa negara yang melakukan inovasi di bidang monitoring tingkat radiasi lingkungan untuk mendeteksi kejadian tidak normal. Salah satunya adalah Lebanon, dimana mereka mengembangkan program monitoring radiasi nasional untuk menjaga laju dosis berada di level baseline dan menganalisis tren radiasi di negara mereka. Program yang dimaksud adalah Radiation Early Warning System (REWS) yang digunakan oleh Lebanon sejak 2013 (Saleh et al., 2019).

REWS terdiri dari sensor deteksi radiasi yang tersebar di beberapa wilayah potensial dan bereaksi terhadap anomali yang melebihi nilai *threshold* dengan meningkatkan level kewaspadaan atau membunyikan peringatan. Nilai *threshold* ini bervariasi tergantung pada radiasi latar serta faktor lingkungan seperti ketinggian, suhu, dan kelembapan. Untuk mencegah *false alarm*, tenaga ahli harus mengkalibrasi data sensor dengan mempertimbangkan kondisi cuaca dan kualitas sensor yang menurun seiring waktu. Namun, REWS konvensional masih bergantung pada prosedur manual, sehingga tenaga ahli harus melakukan analisis dan validasi secara terpisah. Proses ini memperlambat respons karena setiap alarm harus diklasifikasikan secara manual sebagai *false alarm* atau *true alarm*, sehingga sistem tidak dapat bekerja secara *real-time* (Saleh et al., 2019).

Disisi lain, dalam beberapa tahun terakhir, perkembangan Artificial Intelligence (AI), *Big Data*, Internet of Things (IoT), dan teknologi lainnya sangat mengubah proses inovasi (Cai et al., 2023). IoT telah diterapkan dalam beberapa aplikasi, seperti Wi-Fi,

Bluetooth, perangkat inframerah, tempat penyortiran sampah pintar, hingga monitoring lingkungan. Sedangkan AI dapat membantu sebuah program untuk memproses dan mempelajari dataset agar memperoleh informasi, mengidentifikasi variabilitas objek, dan ikut membantu membuat keputusan yang sesuai (Azzimani et al., 2022).

Dalam penelitian ini, penulis merumuskan permasalahan tentang bagaimana cara mengatasi keterbatasan Radiation Early Warning System (REWS) konvensional dalam mendeteksi dan merespons anomali radiasi serta mengoptimalkan jalur evakuasi menggunakan teknologi AIoT sehingga mitigasi risiko bencana nuklir dapat terpetakan dengan jelas.

Dimana, tujuannya penelitian ini akan menghasilkan sebuah modul monitoring radiasi yang bekerja dengan cara mencacah radiasi serta mencatat data suhu, kelembapan, dan kualitas udara. Dengan demikian, terdapat empat luaran dalam pengembangannya, yaitu: (1) Menghasilkan model pendeteksi radiasi yang akurat dan andal menggunakan sistem benam IoT; (2) Mengembangkan jalur evakuasi berbasis paparan radiasi untuk digunakan dalam situasi bencana nuklir menggunakan algoritma *shortest-path*; (3) Menghasilkan prediksi dispersi radiasi secara *real-time* guna meningkatkan efektivitas mitigasi menggunakan *predictive learning*, serta (4) Menilai kelayakan implementasi modul ini dalam fasilitas nuklir untuk meningkatkan keselamatan dan kesiapsiagaan terhadap potensi insiden radiasi.

2. Tinjauan Pustaka

Dalam beberapa tahun ini, REWS telah dikembangkan oleh beberapa peneliti, diantaranya oleh (Szumega et al., 2021) yang mengembangkan alat monitoring radiasi bernama CROME (CERN RadiatiOn Monitoring Electronics). Alat ini dipasang dengan kemampuan komputasi sehingga mampu menjalankan algoritma, seperti arus listrik sebenarnya dari detektor radiasi elektromagnetik atau EMR (Electro-Magnetic Radiation). Lalu terdapat (Li et al., 2021) yang mengembangkan sistem monitoring EMR untuk deteksi dan monitoring radiasi di

sekitar reaktor riset di China. Sedangkan di Indonesia telah ada sistem monitoring radiasi konvensional yang digunakan untuk mencatat dan merekam paparan radiasi di fasilitas Reaktor Kartini, Daerah Istimewa Yogyakarta. Berbekal dari hal tersebut, (Saifullah et al., 2022) merancang sistem kecerdasan untuk monitoring radiasi. Tak hanya itu, ia juga mengimplementasikan sistem prediktif untuk melakukan *forecasting* output menggunakan distribusi probabilitas. Hasilnya menunjukkan bahwa klasifikasi intensitas radiasi dapat dilakukan setelah menentukan keputusan dari dataset dengan algoritma terbaik adalah adaptive boosting classifier sebesar 82,9% (akurasi testing) dan 81,7% (akurasi validasi),

Dalam hal analisis jalur, terdapat istilah *pathfinding*. *Pathfinding* adalah proses mencari jalur terbaik atau tercepat antara dua titik, dengan *shortest path* sebagai optimasinya. Dengan memanfaatkan algoritma *shortest-path*, jalur evakuasi yang dirancang dapat menghasilkan jalur tercepat sekaligus jalur dengan dosis radiasi seminimal mungkin bagi pekerja. Beberapa penelitian telah membahas hal ini, salah satunya adalah (Karova et al., 2016), yang membandingkan ketiga jenis algoritma, yakni A-Star (A*), Backtracking Algorithm (BA), dan Genetic Algorithm Path Planning (GAPP). Hasil penelitian menunjukkan panjang rute yang dihasilkan oleh A* lebih pendek daripada BA, dengan aturan (20% & 30% *obstacle*), algoritma A* menunjukkan hasil yang terbaik. Berdasarkan penelitian (Andiwijayakusuma et al., 2019), perbandingan algoritma Dijkstra dengan A* menghasilkan rerata panjang jalur yang hampir sama, dengan perbedaan hanya 1%. Namun, rerata operasi Dijkstra's lebih besar daripada A*. Dengan demikian, algoritma A* lebih efektif dalam mencari jalur terpendek daripada Dijkstra's (Andiwijayakusuma et al., 2019). Walaupun berbagai penelitian mengatakan algoritma A* lebih baik daripada Dijkstra. Penulis memutuskan untuk menggunakan algoritma Dijkstra-Modifikasi, bukan A* maupun Dijkstra, melainkan kombinasi antar keduanya. Disebut "modifikasi" karena perhitungan bobot

(*weight*) tidak hanya bergantung pada *time-consuming*, seperti yang diterapkan dalam Algoritma A*, tetapi juga mempertimbangkan dosis radiasi dalam proses evakuasi.

Disisi lain, dispersi radiasi bergantung pada model prediksi kecepatan angin. Beberapa penelitian membahas model prediksi kecepatan angin menggunakan model statistik, seperti Auto Regressive Integrated Moving Average (ARIMA) dengan menghubungkannya pada kecepatan angin aktual yang dilakukan oleh Kavasseri dan Seetharaman (Kavasseri & Seetharaman, 2009). Tak hanya itu, metode lain dengan menggunakan Artificial Neural Network (ANN), Logika Fuzzy dan *Wavelet Decomposition* juga telah diteliti. Aplikasi ANN dalam prediksi kecepatan angin telah diteliti oleh (Mabel & Fernandez, 2008) di PLTB Muppandal, India. Ia memanfaatkan data rerata kecepatan angin, kelembapan relatif, dan waktu di setiap pembangkit. Hasil menunjukkan Root Mean Square Error (RMSE) model miliknya sebesar 0.0065. Lebih lanjut, (Ayodele & Ogunjuyigbe, 2015) melakukan penelitian di Western Cape di Afrika Selatan. Ia memanfaatkan data cuaca dan mengombinasikannya dengan *Feed Forward* ANN, lalu diujikan kembali ke data cuaca. Hasil penelitian menunjukkan beberapa parameter penting, seperti R; RMSE; MPAE; dan MAE yang masing-masing sebesar 0,96; 0,56; 6,64%; dan 0,44. Kemudian terdapat Ahmed et al. (Ahmed et al., 2022) yang menggunakan *Back Propagation Feed Forward* ANN untuk memprediksi kecepatan angin di Sujawal, Pakistan, dengan input berupa suhu harian (T), tekanan atmosferik (P), kelembapan relatif (RH%), dan waktu (D). Hasil terbaik diperoleh dengan 4 input neuron (RH, P, T, D), 50 neuron di *hidden layer* pertama, 45 di *hidden layer* kedua, dan 1 output neuron, menghasilkan RMSE 0,541; MAPE 6,023; MBE 0,067; dan R 0,951. Sementara itu, model dengan 3 input neuron (D, T, RH) optimal dengan 10 neuron di *hidden layer* pertama, 40 di *hidden layer* kedua, dan 1 output neuron, menghasilkan RMSE 0,747; MAPE 8,12; MBE -0,012; dan R 0,898.

3. Metode Penelitian


3.1. Area Penelitian dan Kajian Hipotesis

3.1.1. Studi Kasus di Area Hipotesis

Pada penelitian ini, modul REWS-GAMA akan diletakkan pada fasilitas nuklir hipotesis yang dirancang oleh Badan Pengawas Tenaga Nuklir Nasional (BATAN) pada tahun 2015 dari artikel “*Physical protection system effectiveness calculation in nuclear reactor facility using EASI code: case study sabotage scenario*”, dengan nama Hypothetical Nuclear Power Reactor Facility (HNPRF) (Andiwijayakusuma et al., 2019). HNPRF merupakan bagian dari skenario Experimental Power Reactor (RDE) yang dirancang untuk mewujudkan fasilitas nuklir yang aman. Dalam perkembangannya, HNPRF merupakan representasi dari RDE yang dilengkapi oleh sistem deteksi, tunda, dan respon. HNPRF sendiri terdiri dari area terbatas, area terkontrol, area vital, dan area proteksi. Gambar 3.1 dibawah mengilustrasikan area HNPRF dalam tampilan 2D dengan diagram jalur hipotesis evakuasi. Pada area ini, telah dipasang beberapa elemen Sistem Proteksi Fisik yang dilengkapi dengan sensor untuk melakukan fungsi deteksi-tunda-respons. Kemudian terdapat Balance Magnetic Switch (BMS) sebagai sensor pintu berbasis magnetik di depan *front door* dan *emergency door*, dengan *front door* hanya aktif diluar jam kerja, sedangkan *emergency door* aktif selama 24 jam. Jika pintu dengan sensor BMS dipaksa terbuka (misal: serangan *cybersecurity*), maka sensor BMS akan mengirimkan sinyal alarm ke Central Alarm Station (CAS). Untuk simulasi, penulis memasang 22 modul REWS-GAMA dan sumber radiasi *random* di beberapa lokasi.



Gambar 3.1. Layout 2D area hipotesis di HNPRF



Gambar 3.2. Layout 2D area pilot di Lantai 2 DTNTF

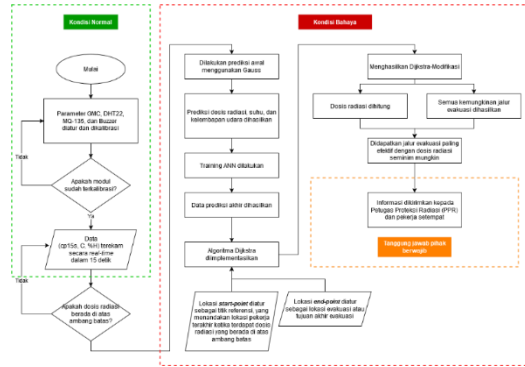
3.1.2. Studi Kasus Pilot

Untuk menguji validasi solusi, penulis melakukan dua pendekatan, yakni pendekatan studi kasus pilot dan pendekatan hipotesis (seperti yang dibahas sebelumnya). Oleh karena itu, kajian penelitian ini dapat dibagi menjadi dua segmen, yakni segmen studi kasus pilot sebagai validasi solusi dan segmen hipotesis (dibahas sub-bab sebelumnya) sebagai tujuan akhir solusi. Sebelum melangkah ke segmen hipotesis, penulis melakukan validasi solusi berupa pengujian performa REWS-GAMA di lapangan secara nyata. Dalam hal ini, penulis mengujikan langsung di Departemen Teknik Nuklir dan Teknik Fisika, Lantai 2. Denah studi kasus dapat dilihat pada Gambar 3.2 diatas, dimana warna kuning di depan setiap ruangan adalah sebuah pintu, sedangkan warna kuning di area hijau (area jalan) adalah *obstacle* (berupa meja, kursi, *hydrant*, tempat sampah, dsb), warna merah adalah sumber radiasi (*hipotesis*), biru adalah lokasi pekerja terakhir, serta warna ungu adalah tempat dimana modul REWS-GAMA dipasang. Secara keseluruhan, penulis memasang 9 modul REWS-GAMA dan 1 sumber radiasi (*hipotesis*).

3.2. Arsitektur Solusi

Dalam penelitian ini, arsitektur solusi mencakup dua kondisi, yaitu kondisi normal dan kondisi bahaya seperti pada Gambar 3.3. Ketika REWS-GAMA mengumpulkan data radiasi dan mendeteksi anomali dosis radiasi yang melebihi ambang batas, misalnya 10 μSv /jam, perangkat akan beralih ke mode darurat. Dalam mode ini, data yang terkumpul

akan terintegrasi satu sama lain, mencakup dosis radiasi, suhu ($^{\circ}\text{C}$), dan kelembapan ($\%H$). Sementara itu, indeks kualitas udara (PPM) digunakan sebagai evaluator eksternal untuk mengidentifikasi penyebab bencana di akhir proses.



Gambar 3.3. Bagan arsitektur solusi

Prediksi awal dibuat menggunakan perhitungan Gauss, yang kemudian ditingkatkan dengan pelatihan ANN untuk menghasilkan data prediksi akhir. Selanjutnya, dengan memasukkan lokasi referensi atau posisi awal pekerja serta lokasi tujuan akhir evakuasi, sistem akan menghasilkan jalur evakuasi menggunakan algoritma Dijkstra yang telah dimodifikasi (tanpa bobot/weight). Algoritma ini akan menghasilkan semua kemungkinan jalur evakuasi. Dengan mempertimbangkan dosis radiasi, jalur evakuasi yang tersedia akan diseleksi secara otomatis untuk memastikan rute dengan dosis radiasi seminimal mungkin. Terakhir, visualisasi data ini dapat dikirimkan kepada Petugas Proteksi Radiasi (PPR) dan pekerja setempat, sehingga mereka dapat mengikuti jalur evakuasi yang telah direkomendasikan.

3.3. Set-up Prototipe

3.3.1. Perangkat Keras (*Hardware*)


Modul REWS-GAMA dilengkapi oleh beberapa komponen utama, yaitu Assembled DIY Geiger Counter Kit (20 mR/h ~ 120 mR/h) sebagai sensor deteksi radiasi, ESP8266Mod *NodeMCU* sebagai mikrokontroler dengan konektivitas WiFi, DHT22 untuk mengukur suhu dan kelembapan, MQ-135 sebagai sensor gas

(NH₃, S, C₆H₆, CO₂, dan lainnya), serta buzzer 5V yang berfungsi sebagai alarm peringatan.


NodeMCU yang penulis gunakan dilengkapi oleh ESP-12E, yang didalamnya berisi chip ESP8266 dengan Tensilica Xtensa 32-bit LX106 RISC sebagai mikroprosesor. Selain itu, *NodeMCU* juga memiliki RAM sebesar 128 kB dan memori Flash 4 MB untuk menyimpan data dan program. Selain itu, komponen penting lainnya adalah detektor radiasi. Beberapa detektor komersial di dunia didominasi oleh produk dari ORTEC yang meliputi High Purity Germanium (HPGe) *Detectors*, Silicon Charged Particle *Detectors*, dan *Scintillation Detectors*. Namun, karena keterbatasan biaya dan faktor ergonomis dari modul REWS-GAMA, penulis menggunakan J305 Geiger-Muller Counter (GMC).

J305 GMC menggunakan bahan dasar logam dan dirancang dengan parameter tabung yang mampu mendeteksi radiasi beta dan gamma. Untuk kalibrasi, perangkat ini menggunakan sumber Cobalt-60 (⁶⁰Co). Dari segi sensitivitas, alat ini memiliki respons sebesar 44 cps dalam 1 mR/jam saat dikalibrasi dengan ⁶⁰Co. Rentang deteksi radiasi gamma berada pada 20–120 mR/jam, sementara untuk radiasi beta, alat ini dapat mengukur dalam kisaran 100–1800 berdasarkan variabel dan titik dari sinar beta lunak. Perangkat ini dirancang untuk beroperasi dalam rentang suhu lingkungan antara 40–55°C. Dari segi daya input, alat ini dapat dioperasikan dengan tegangan 5 V, atau menggunakan tiga baterai 1.5 V, maupun empat baterai 1.2 V, dengan konsumsi arus berkisar antara 30–120 mA.

Sementara itu, modul REWS-GAMA nantinya akan terintegrasi antar sensor sehingga dapat bekerja secara paralel dengan suplai daya berasal dari baterai 3 x 1,5 V tipe AAA seperti yang terlihat pada Gambar 3.4.



Gambar 3.4. Skematik hardware



Gambar 3.5. Skematik software

3.3.2. Perangkat Lunak (Software)


Visualisasi data akan memanfaatkan ThingSpeak. Proses dimulai ketika sensor mengambil data, kemudian data akan dikirimkan ke *NodeMCU* seperti yang terlihat pada Gambar 3.5. Data yang telah diolah selanjutnya akan teruskan dikirim ke laptop untuk mengalami *post processing*. Terakhir, data yang sudah melewati *post-processing* dapat di-*publish* ke *website* agar dapat dilihat secara publik.

4. Hasil dan Pembahasan

4.1. Pengujian Studi Kasus Pilot

4.1.1. Pengujian Sistem Benam IoT

Prototipe yang telah dirancang dapat dilihat pada Gambar 4.1.. Terlihat bahwa indikator GMC, DHT22, dan MQ-135 menyala, menandakan sensor berfungsi dengan baik. Bagian terpenting pada sensor J305 GMC adalah tabung J305. Tabung ini diisi dengan gas inert yang tidak menghantarkan listrik, seperti neon, argon, helium, atau kripton, dalam tekanan rendah.



Gambar 4.1. Prototipe REWS-GAMA

```
19:45:00.107 -> === Data Sensor ===
19:45:00.107 -> Suhu: 24.30
19:45:00.107 -> Kelembapan: 57.00
19:45:00.107 -> Kualitas Udara (PPM): 15.05
19:45:00.107 -> Pulsa Geiger Counter: 2
19:45:01.337 -> Data berhasil dikirim ke ThingSpeak!
```

Kondisi Normal

```

19:43:45.053 -> === Data Sensor ===
19:43:45.053 -> Suhu: 24.30
19:43:45.053 -> Kelembapan: 57.10
19:43:45.089 -> Kualitas Udara (PM2.5): 35.39
19:43:45.089 -> Pulsa Geiger Counter: 19
19:43:45.955 -> Data berhasil dikirim ke ThingSpeak!
19:43:45.955 -> !!! ALARM: Radiasi tinggi terdeteksi !!!

```

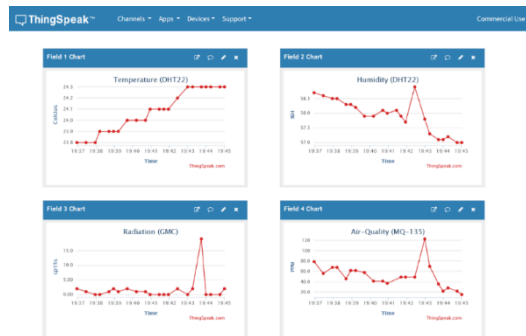
Kondisi Bahaya

Gambar 4.2. Set logika alarm pada modul

Namun, tidak adanya sumber membuat sensor GMC membaca cacah radiasi background yang berkisar di angka 0 hingga 1 cp15s, mengakibatkan sistem tidak bisa membedakan kondisi normal dan bahaya. Oleh karena itu, penulis menggunakan kaos petromaks sebagai *dummy source* atau pengganti sumber radiasi. Kaos petromaks merupakan kaos lampu yang dibuat dari kain katun yang lembut dan dirajut secara khusus dalam skala industri yang dilapisi dengan Thorium. Thorium yang digunakan dalam kaos lampu petromaks adalah Thorium alam (Th-232) yang diperoleh dari ekstraksi batuan Thorium. Ketika kaos petromaks berada di dekat tabung, radiasi dari Thorium melintasi tabung dan berinteraksi dengan gas di dalamnya. Tabung J305 menggunakan gas quenching, yang menyerap energi ion melalui transfer ke molekulnya, sehingga ion mampu mencapai katoda tanpa memancarkan foton. Hal ini menjaga kestabilan operasi dan memperpanjang umur tabung J305.

Sementara itu, algoritma deteksi kemudian diatur pada skala yang sederhana dan mengikuti *delay-time* dari ThingSpeak, yakni 15 detik atau cp15s. Kemudian untuk mendemonstrasikan cara kerja secara sederhana, sinyal kondisi bahaya akan aktif apabila sensor membaca deteksi radiasi diatas 5 cp15s, yang diikuti dengan bunyinya buzzer yang keras sebanyak tiga kali. Dalam hal ini, penulis meniru contoh (Farid et al., 2017), terkait cara kerja OLM ketika mode “Peringatan Dini” aktif yang ditandai dengan menyalanya alarm sebanyak tiga. Lebih jelas, visualisasi kondisi tersebut dapat dilihat pada Gambar 4.2.

Data yang sudah terekam juga dapat dilihat pada ThingSpeak seperti pada Gambar 4.3. Terlihat bahwa ketika kaos petromaks didekatkan, otomatis cacah radiasi langsung berubah secara signifikan.



Gambar 4.3. Tampilan di ThingSpeak

4.1.2. Implementasi Algoritma Dijkstra-Modifikasi untuk Jalur Evakuasi

Implementasi algoritma Dijkstra-Modifikasi dimulai melalui pengintegrasian data IoT, yakni data dosis radiasi ($\mu\text{Sv}/\text{hour}$), temperature ($^{\circ}\text{C}$) dan humiditas relatif (%) dari sensor J305 Geiger-Muller Counter dan DHT22. Data yang didapat dari *mapping* Departemen akan diutilisasi lebih lanjut untuk memprediksi dosis radiasi pada setiap titik di sekitar modul REWS-GAMA diletakkan, maupun titik yang tidak terjangkau.

Proses prediksi terbagi menjadi dua, yakni prediksi awal dan prediksi akhir. Prediksi awal bertujuan untuk mendapatkan data kasar terkait parameter dosis radiasi, suhu, dan humiditas pada lokasi tersebut. Prediksi ini dapat dilakukan menggunakan algoritma Gauss, yakni algoritma yang akan memberikan data kasar dari beberapa titik yang diketahui dengan melakukan konvolusi atau pemerataan/distribusi pada tiap *node* atau *grid* pada iterasi tertentu hingga tercapai kondisi konvergen. Semakin banyak dilakukan proses iterasi, hasil yang didapat semakin akurat dengan *cost* berupa *grid* yang semakin besar, mengakibatkan waktu komputasi lebih lama.

Langkah selanjutnya adalah proses *training data* dengan menggunakan Artificial Neural Network (ANN). ANN adalah salah satu model ML yang terinspirasi dari struktur jaringan sistem syaraf manusia yang kompleks. Sebelum masuk ke proses *training*, diperlukan *preprocessing* berupa normalisasi data karena data yang didapatkan sebelumnya masih belum ternormalisasi pada range tertentu. *Preprocessing* dimulai dengan

mentransformasikan data pada *range* -1 hingga 1. Dengan demikian, *preprocessing* dilakukan untuk mendapatkan parameter *loss* yang kecil pada proses *training data* sehingga hasilnya lebih akurat.

Setelah *preprocessing* selesai, langkah selanjutnya adalah prediksi akhir dengan melakukan *training data* menggunakan ANN. Terdapat beberapa parameter ANN yang perlu diperhatikan karena membentuk arsitektur model, yakni menggunakan 4 layer dengan masing-masing layer input bersikan 3 *node*, *hidden layer* 1 dengan 10 *node*, *hidden layer* 2 berisikan 12 *node* dan output hanya dengan 1 *node*.

Data output yang akan dilatih merupakan hasil pencacahan radiasi secara *real-time* menggunakan detektor GMC pada modul REWS-GAMA di setiap *node*. Selain itu, terdapat parameter lain pada ANN seperti *optimizer* dan *loss function*. *Optimizer* yang digunakan pada penelitian ini adalah Stochastic Gradient Descent (SGD), hal ini dikarenakan *optimizer* SGD menghasilkan data generalisasi yang lebih baik dibandingkan dengan *optimizer* lainnya. Tak hanya itu, SGD memiliki parameter momentum yang berfungsi untuk menghindari kondisi osilasi pada *local minima* (Tian et al., 2023). *Loss function* yang digunakan pada model ini adalah *smoothL1Loss* atau biasa juga disebut dengan *Huber-loss*, hal ini dikarenakan *loss function* ini memiliki kemampuan yang adaptif yang menyerupai *loss function* MSE (Mean Square Error) dan MAE (Mean Absolute Error) (Iliev & Anand, 2023). *Huber-loss* ini akan bertindak seperti MSE pada kondisi *loss* yang kecil untuk menghindari osilasi lebih lanjut dan mencapai konvergensi, kemudian bertindak seperti MAE pada kondisi *loss* yang tinggi, hal ini yang menyebabkan *huber loss* dapat lebih efisien dibandingkan dengan *loss function* lainnya (Wang et al., 2019).

Kemudian dilakukan proses *training* untuk menghasilkan hasil yang akurat dengan *loss* sebesar 0,00677 pada epoch ke-980 dan *loss* untuk test atau validasi sebesar 0,009494. Hasil dari *training* model ANN tersebut berisikan *weight* dan *bias* pada tiap *node*-nya yang dapat langsung digunakan untuk

memprediksi penyebaran radiasi. Kemudian, model ini akan digunakan sebagai sebuah fungsi yang akan dikomputasikan secara *real time* dengan sensor yang terpasang sehingga didapatkan hasil heatmap di setiap *grid*. Keseluruhan tahapan mulai dari prediksi awal, normalisasi, hingga model ANN dapat dilihat pada Tabal 4.1.

Selanjutnya, hasil *mapping* tersebut di-*coupling* dengan algoritma Dijkstra. Hal ini dilakukan untuk mendapatkan jalur evakuasi paling efektif jika suatu saat terjadi *radiation breakout* pada lokasi tersebut. Dikatakan paling efektif jika jalur dari titik mulai hingga titik keluar memiliki serapan dosis radiasi yang paling rendah. Metode Dijkstra yang digunakan pada penelitian ini adalah algoritma dijsktra termodifikasi untuk menghitung jarak, waktu dan dosis radiasi yang terserap pada jalur tersebut. Simulasi dimulai dengan *set-point* berada di depan pintu ruang referensi dan berakhir diantara jalur evakuasi tercepat atau terjauh.

Hasil simulasi dapat dilihat pada Gambar 4.4a dan Gambar 4.4b. Gambar 4.4a memvisualisasikan *set-point* mulai pada *start point-1* di depan ruang referensi, menghasilkan rute keluaran pada *end-point* di rute evakuasi terjauh dengan dosis akumulatif yang diterima oleh pekerja tersebut sebesar $5,798 \times 10^{-3} \mu\text{Sv}$, jarak yang ditempuh sebesar 116,38 meter, serta waktu yang diperlukan sebesar 52,38 detik dalam keadaan berlari. Sedangkan Gambar 4.4b adalah simulasi jika menggunakan algoritma Dijkstra-Modifikasi, didapatkan rute keluaran paling efektif pada *end-point* di rute evakuasi terdekat dengan dosis akumulatif yang diterima sebesar $1,355 \times 10^{-3} \mu\text{Sv}$, jarak tempuh sebesar 19,49 meter, serta waktu yang diperlukan selama 8,77 sekon dalam keadaan berlari.

Tabel 4.1. Tahapan mendapatkan visualisasi dispersi radiasi

Proses	Suhu	Kelembapan	Dosis radiasi
Prediksi awal			
Normalisasi			
	Dosis radiasi		
Hasil akhir			



(a)



(b)

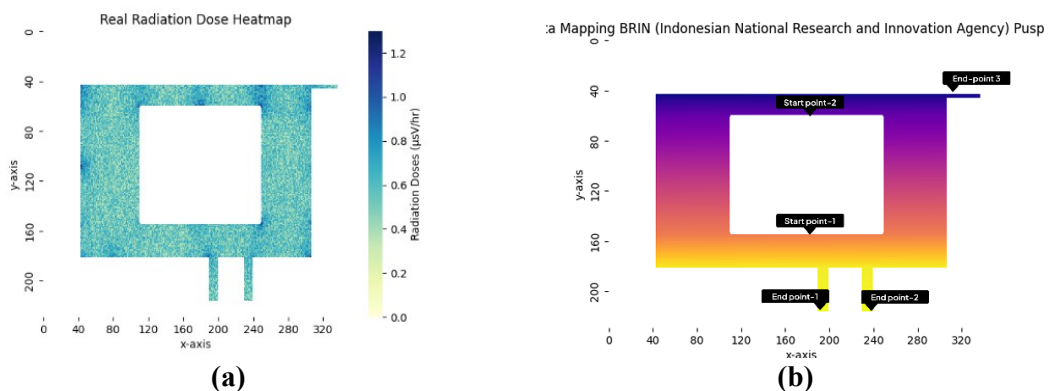
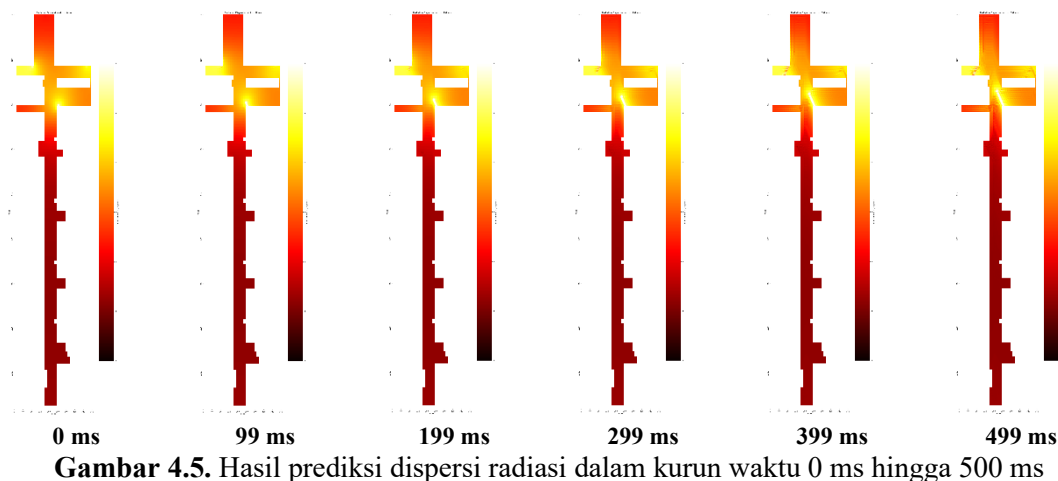
Gambar 4.4. Hasil simulasi jalur evakuasi di Lantai 2 DTNTF. (a) Tanpa algoritma Dijkstra-Modifikasi; (b) Menggunakan algoritma Dijkstra-Modifikasi

4.1.3. Implementasi *Predictive Learning* untuk Prediksi Dispersi Radiasi

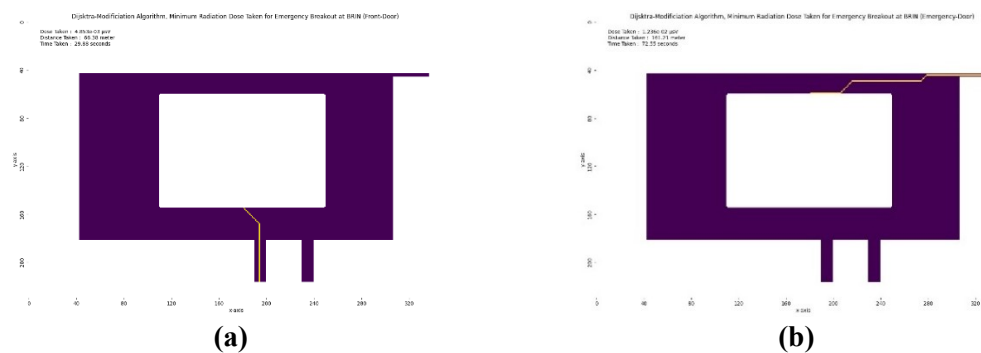
Untuk membuat model isotropik, penulis mengaplikasikan persamaan diferensial difusivitas radionuklida yang memanfaatkan data angin yang terdiri dari kecepatan angin dan sudut relatif terhadap *mapping* untuk memprediksi penyebaran radionuklida dalam kurun waktu tertentu. Persamaan tersebut merepresentasikan perubahan konsentrasi radionuklida akibat difusi, adveksi, dan sumber radiasi. Dimana, v melambangkan kecepatan angin (m/s), ϕ adalah dosis radiasi ($\mu\text{Sv}/\text{jam}$), dan D adalah koefisien difusivitas (m^2/s).

$$\frac{\partial \phi}{\partial t} + v \cdot \nabla \phi = D \nabla^2 \phi$$

Penulis melakukan simulasi prediksi dispersi radiasi dalam kurun waktu 0-500 ms dan *time step* sebesar 1 ms. Hasil simulasi dapat dilihat pada Gambar 4.5, dengan penyebaran masih didominasi oleh difusi isotropik (0-100 ms). Sementara pada 100-300 ms, kecepatan angin yang diprediksi dari suhu dan kelembapan mulai mengarahkan pergerakan radionuklida sesuai dengan gradien temperatur dan tekanan atmosfer. Pada 300-500 ms, turbulensi atmosfer sangat berpengaruh pada pola penyebaran radiasi, hal ini dapat diestimasi menggunakan model *Artificial Neural Network* (ANN) berdasarkan data *real-time* yang mencakup faktor suhu dan kelembapan udara. Data hasil prediksi ini memiliki fungsi penting dalam proses mitigasi bencana serta optimasi jalur evakuasi dalam situasi darurat radiasi.



Gambar 4.6. (a) Hasil prediksi akhir dosis radiasi di HNPRF; (b) Pemosisian start-point dan end-point di HNPRF



Gambar 4.7. Jalur evakuasi efektif di HNPRF. (a) Dimulai pada *start point-1* (pintu depan); (b) Dimulai pada *start point-2* (pintu emergency).

Kemudian hasil simulasi dapat dikirim dan diterima oleh *Bot Telegram* sebagai representasi *receiver* selanjutnya di fasilitas nuklir pada umumnya. Proses pengolahan, simulasi dan pengiriman data dapat dilakukan secara berkala menyesuaikan dengan *settings* yang telah ditentukan di awal. Kedepannya, model *predictive learning* ini dapat diintegrasikan dengan data cuaca dari API

BMKG jika sensor DHT22 di modul REWS-GAMA tidak berfungsi kembali karena fasilitas nuklir tersebut sudah terkena bencana nuklir kronik.

4.2. Pengujian Studi Kasus di HNPRF

Dengan model dan metode yang sama, penulis kemudian mengimplementasikan model pada area HNPRF dan melakukan

simulasi pada dua start-point. Dimana *start point-1* adalah front door dan *start point-2* adalah *emergency door*. Hasil prediksi akhir dapat dilihat pada Gambar 4.6a, dan Gambar 4.6b.

Hasil simulasi pada Gambar 4.7 menunjukkan dua hasil yang berbeda. Dimana, pada *start point-1* menghasilkan jalur evakuasi efektif di *end point-1*, dengan dosis akumulatif yang diterima oleh pekerja sebesar $4,854 \times 10^{-3}$ μSv , jarak tempuh sebesar 66,38 meter, dan waktu selama 29,8 detik dalam kondisi berlari. Sedangkan dengan *start point-2*, jalur evakuasi efektif berada di *end point-2*, dengan dosis akumulatif yang diterima oleh pekerja sebesar $1,236 \times 10^{-2}$ μSv , jarak tempuh sebesar 161,21 meter, dan waktu selama 72,55 detik dalam kondisi berlari.

5. Kesimpulan

Modul REWS-GAMA (Gajah Mada Monitoring Early Warning System) adalah sistem deteksi radiasi berbasis *Artificial Intelligence of Things* (AIoT). Dengan aplikasi sistem benam, ANN, dan *predictive learning*, REWS-GAMA memiliki tujuan untuk mengatasi keterbatasan Radiation Early Warning System (REWS) konvensional dalam mendeteksi dan merespons anomali radiasi serta mengoptimalkan jalur evakuasi dengan memanfaatkan teknologi AIoT, sehingga mitigasi risiko bencana nuklir dapat dipetakan dengan lebih jelas dan efektif. Simulasi dilakukan dalam dua segmen, yakni segmen studi kasus pilot sebagai validasi solusi dan segmen hipotesis di HNPRF sebagai tujuan akhir solusi. Hasil simulasi pilot menunjukkan rute keluaran paling efektif pada end-point di rute evakuasi terdekat dengan dosis akumulatif yang diterima sebesar $1,355 \times 10^{-3}$ μSv , jarak tempuh sebesar 19,49 meter, serta waktu evakuasi selama 8,77 sekon dalam keadaan berlari. Sedangkan simulasi hipotesis di HNPRF dilakukan dalam dua skenario *start-point*, dimana pada *start point-1* (front door) menuju end point-1 adalah rute paling efektif dengan dosis akumulatif sebesar $4,853 \times 10^{-3}$ μSv , jarak tempuh 66,38 meter dan waktu evakuasi selama 29,8 detik dalam kondisi

berlari. Sementara untuk skenario dari *start point-2* (*emergency door*), rute terbaik mengarah ke end-point-3 atau *emergency gate*, dengan dosis akumulatif $1,236 \times 10^{-2}$ μSv , jarak tempuh 161,21 meter, dan waktu evakuasi selama 72,55 detik dalam kondisi berlari.

Ucapan Terimakasih

Penulis berterima kasih kepada dukungan dari dosen pembimbing, Prof. Ir. Nazrul Effendy, S.T., M.T., Ph.D., IPM atas, serta rekan sejawat dari kantor PSIT.

Daftar Pustaka

- Ahmed, K. M., Khan, M. A., Siddiqui, I., Khan, S., Shoaib, M., & Zia, I. (2022). Wind Speed Prediction from Site Meteorological Data Using Artificial Neural Network. *2022 Global Conference on Wireless and Optical Technologies (GCWOT)*, 1–8. <https://doi.org/10.1109/GCWOT53057.2022.9772879>
- Andiwijayakusuma, D., Mardhi, A., Savitri, I., & Asmoro, T. (2019). A Comparative Study of the Algorithms for Path finding to Determine the Adversary Path in Physical Protection System of Nuclear Facilities. *Journal of Physics: Conference Series*, *1198*(9), 092002. <https://doi.org/10.1088/1742-6596/1198/9/092002>
- Ayodele, T. R., & Ogunjuyigbe, A. S. O. (2015). Prediction of wind speed for the estimation of wind turbine power output from site climatological data using artificial neural network. *International Journal of Ambient Energy*. <https://doi.org/10.1080/01430750.2015.1023845>
- Azzimani, K., Bihri, H., Dahmi, A., Azzouzi, S., & Charaf, M. E. H. (2022). An AI Based Approach for Personalized Nutrition and Food Menu Planning. *2022 IEEE 3rd International Conference on Electronics, Control, Optimization and Computer Science (ICECOCS)*, 1–5.

- <https://doi.org/10.1109/ICECOCS55.148.2022.9983099>
- Cai, Y., Lin, J., & Zhang, R. (2023). When and how to implement design thinking in the innovation process: A longitudinal case study. *Technovation*, *126*, 102816. <https://doi.org/10.1016/j.technovation.2023.102816>
- Farid, M. M., Prawito, Susila, I. P., & Yuniarto, A. (2017). *Design of early warning system for nuclear preparedness case study at Serpong*. 030067. <https://doi.org/10.1063/1.4991171>
- IAEA. (2005). *Environmental and Source Monitoring for Purposes of Radiation Protection* (Safety Guide RS-G-1.8).
- Iliev, A. I., & Anand, A. (2023). Huber Loss and Neural Networks Application in Property Price Prediction. *Future of Information and Communication Conference*, 242–256.
- Karova, M., Penev, I., & Kalcheva, N. (2016). Comparative analysis of algorithms to search for the shortest path in a maze. *2016 IEEE International Black Sea Conference on Communications and Networking (BlackSeaCom)*, 1–4. <https://doi.org/10.1109/BlackSeaCom.2016.7901597>
- Kavasseri, R., & Seetharaman, K. (2009). Day-ahead wind speed forecasting using f-ARIMA models. *Renew Energy*, *34*(5), 1388–1393.
- Li, S., Wang, H., & Zhang, Y. (2021). Assessment of supervision monitoring for radiation environment around the typical research reactors in China. *Nuclear Engineering and Technology*, *53*(12), 4150–4157. <https://doi.org/10.1016/j.net.2021.06.032>
- Mabel, M., & Fernandez, E. (2008). Analysis of wind power generation and prediction using ANN: a case study. *Renew Energy*, *33*, 986–992.
- Ohba, T., Tanigawa, K., & Liutsko, L. (2021). Evacuation after a nuclear accident: Critical reviews of past nuclear accidents and proposal for future planning. *Environment International*, *148*, 106379. <https://doi.org/10.1016/j.envint.2021.106379>
- Saifullah, M., Bajwa, I. S., Ibrahim, M., & Asghar, M. (2022). IoT-Enabled Intelligent System for the Radiation Monitoring and Warning Approach. *Mobile Information Systems*, *2022*, 1–12. <https://doi.org/10.1155/2022/2769958>
- Saleh, M. A., Finance, B., Taher, Y., & Haque, R. (2019). Towards An Autonomous Radiation Early Warning System. *CEUR Workshop Proceedings*.
- Szumeaga, J. M., Boukabache, H., & Perrin, D. (2021). Neural network approach for efficient calculation of the current correction value in the femtoampere range for a new generation of ionizing radiation monitors at CERN. *Radiation Physics and Chemistry*, *188*, 109539. <https://doi.org/10.1016/j.radphyschem.2021.109539>
- Tang, Z., Xie, X., Cai, J., & Li, Q. (2022). An optimization method of multi-objective evacuation path for off-site emergency under severe nuclear accidents. *Annals of Nuclear Energy*, *174*, 109170. <https://doi.org/10.1016/j.anucene.2022.109170>
- Tanigawa, K., Hosoi, Y., Hirohashi, N., Iwasaki, Y., & Kamiya, K. (2012). Loss of life after evacuation: Lessons learned from the Fukushima accident. *The Lancet*, *379*(9819), 889–891. [https://doi.org/10.1016/S0140-6736\(12\)60384-5](https://doi.org/10.1016/S0140-6736(12)60384-5)
- Tian, Y., Zhang, Y., & Zhang, H. (2023). Recent Advances in Stochastic Gradient Descent in Deep Learning. *Mathematics*, *11*(3). <https://doi.org/10.3390/math11030682>
- Wang, Y., Hu, S., & Wu, S. (2019). Object tracking based on Huber loss function. *The Visual Computer*, *35*(11), 1641–1654. <https://doi.org/10.1007/s00371-018-1563-1>

Xiao, D., Li, J., Zhang, Z., Gu, Z., Fu, Y., & Niu, J. (2024). Optimization of personnel evacuation routes for sudden nuclear accidents based on hybrid genetic-grey wolf optimizer algorithm. *Nuclear Engineering and Technology*, 103223. <https://doi.org/10.1016/j.net.2024.09.026>