

BAB 2

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Kondisi Stres

Stres merupakan suatu kondisi respons adaptif kompleks yang terjadi ketika individu menghadapi tuntutan internal maupun eksternal yang melebihi kapasitas coping atau kemampuan penyesuaian diri. Dalam kajian psikologi dan fisiologi, stres dipahami sebagai reaksi tubuh terhadap ancaman yang memicu perubahan pada sistem saraf dan hormonal. Respon ini melibatkan sistem saraf otonom yang menghasilkan pelepasan hormon stres seperti kortisol dan adrenalin. Aktivasi hormon-hormon tersebut meningkatkan kewaspadaan, denyut jantung, tekanan darah, serta kesiapan tubuh dalam merespons tekanan lingkungan (physiological stress response) sehingga tubuh berada dalam keadaan “siaga” untuk menghadapi tantangan. Jika paparan terhadap stres bersifat kronis atau berkepanjangan, perubahan fisiologis ini bisa berdampak negatif pada kesehatan fisik dan mental seperti hipertensi, gangguan kecemasan, maupun penurunan sistem imun (chronic stress effects). Penelitian dalam psikologi klinis menunjukkan bahwa stres tidak hanya sekadar ketegangan emosional, tetapi juga memengaruhi fungsi kognitif, suasana hati, dan pola perilaku seseorang selama dan setelah menghadapi stresor (Attar, 2022).

Lebih lanjut, stres ditandai oleh rasa tegang, kewaspadaan berlebihan, atau kecemasan ketika individu mengalami tekanan psikososial atau tuntutan hidup yang kuat, seperti beban pekerjaan, perubahan hidup mendadak, atau situasi tekanannya tinggi. Stress yang dirasakan dapat berupa emotional tension yang berhubungan dengan tantangan kehidupan sehari-hari, misalnya kekhawatiran berlebihan, rasa tertekan, hingga gangguan tidur yang memengaruhi kesejahteraan seseorang secara umum (Attar, 2022).

Dalam konteks neurofisiologis, respons stres tercermin pula dalam aktivitas otak, terutama pada area yang mempengaruhi fungsi kognitif dan emosi. Ketika seseorang mengalami stres, aktivitas neuron di otak berubah yang dapat diobservasi melalui sinyal EEG (Electroencephalography). Penelitian terdahulu telah

menunjukkan bahwa perubahan dalam daya spektral gelombang otak terjadi saat keadaan stres, khususnya pada gelombang Alpha dan Beta. Gelombang Alpha (8–13 Hz) umumnya berkaitan dengan keadaan rileks dan istirahat, sedangkan gelombang Beta (13–30 Hz) berkaitan dengan kewaspadaan, kecemasan, dan kondisi mental lebih aktif. Dalam kondisi stres, dominasi daya gelombang Alpha cenderung menurun sementara daya gelombang Beta meningkat, menggambarkan peningkatan kewaspadaan dan ketegangan mental. Studi EEG menunjukkan bahwa rasio antara gelombang Alpha dan Beta (Alpha/Beta rasio) merupakan indikator penting untuk menilai tingkat stres, di mana rasio ini biasanya menurun ketika stres meningkat. Metode ini telah diaplikasikan dalam penilaian stres yang objektif melalui analisis power spectral density dari sinyal EEG (Wen et al., 2020).

2.1.2 Elektroensefalografi (EEG)


Elektroensefalografi (EEG) adalah teknik pengukuran aktivitas listrik otak yang bersifat non-invasif, di mana tegangan yang muncul dari aktivitas neuron di korteks otak direkam melalui elektroda yang ditempelkan pada kulit kepala (Zhang et al., 2023). EEG merekam sinyal listrik yang muncul akibat aktivitas sel-sel saraf di otak, di mana sinyal tersebut dapat dideteksi melalui elektroda yang ditempelkan pada kulit kepala (Khakim & Kusrohmaniah, 2021). Teknik ini telah menjadi alat penting dalam penelitian neurosains dan klinis karena mampu menangkap dinamika aktivitas otak dengan resolusi temporal sangat tinggi (order milidetik), sehingga cocok untuk mempelajari proses kognitif secara real-time (Zhang et al., 2023).

Sinyal EEG yang direkam sangat kecil amplitudanya (biasanya dalam mikrovolt), dan rentan terhadap kontaminasi oleh artefak seperti gerakan otot, gerakan mata, dan interferensi listrik lingkungan. Oleh karena itu, perekaman dan analisis EEG harus dilakukan dengan teknik penguatan sinyal dan filtrasi yang tepat, serta pemrosesan data yang baik untuk mengisolasi komponen aktivitas otak yang relevan. EEG tidak hanya digunakan dalam diagnosis kondisi neurologis seperti epilepsi atau gangguan tidur, tetapi juga berkembang luas dalam aplikasi penelitian kognitif, pengembangan antarmuka otak-komputer (Brain-Computer Interface), serta studi psikofisiologi seperti deteksi stres dan beban mental.

Secara fungsional EEG memberikan gambaran tentang pola aktivitas otak melalui gelombang-gelombang listrik yang dapat dikategorikan menurut rentang

frekuensi tertentu seperti Delta, Theta, Alpha, Beta, dan Gamma. Setiap kategori frekuensi ini berkaitan dengan kondisi fisiologis dan keadaan mental tertentu, sehingga analisis frekuensi menjadi bagian penting dalam interpretasi EEG (Khakim & Kusrohmaniah, 2021), (Wen et al., 2020), dan (Purnamasari et al., 2018).

Sinyal EEG dapat digunakan untuk deteksi stres, perubahan pola gelombang EEG menunjukkan adanya korelasi dengan kondisi mental seseorang, di mana peningkatan aktivitas gelombang Beta umumnya dikaitkan dengan kondisi tegang, cemas, dan stres, sedangkan penurunan gelombang Alpha menunjukkan berkurangnya kondisi relaksasi. Selain itu, rasio antara gelombang Alpha dan Beta (alpha/beta ratio) sering digunakan sebagai parameter untuk mengidentifikasi tingkat stres, di mana nilai rasio yang lebih rendah mengindikasikan tingkat stres yang lebih tinggi.



Gambar 2. 1 Frekuensi Gelombang Otak¹

2.1.3 Pemrosesan Sinyal EEG

Pemrosesan sinyal EEG secara umum mencakup tahap-tahap seperti *pre-processing* (filtrasi, normalisasi), ekstraksi fitur, dan klasifikasi dengan algoritma

¹https://storage.googleapis.com/mv-prod-blog-en-assets/2018/01/fc6f13b9-brainwaves_bloggraphic_1200x800.webp

komputasi seperti *machine learning* untuk interpretasi data yang lebih canggih. Pendekatan ini memungkinkan sistem untuk mengenali pola kompleks yang tidak tampak melalui observasi manual saja, serta memberikan dasar kuat bagi aplikasi klinis maupun teknologi seperti deteksi stres berbasis EEG (Chaddad et al., 2023). Berikut adalah tahapan pemrosesan sinyal EEG:

- 1) Tahap pertama adalah *pre-processing*, yang bertujuan untuk meningkatkan kualitas sinyal EEG dengan mengurangi noise dan gangguan yang tidak diinginkan. Pada tahap ini menggunakan band-pass filter untuk menyaring sinyal pada rentang frekuensi tertentu yang relevan dengan analisis stres, yaitu gelombang Theta (4–8 Hz), Alpha (8–13 Hz), dan Beta (13–30 Hz). Filter ini berfungsi untuk menghilangkan komponen frekuensi rendah seperti drift sinyal serta frekuensi tinggi yang berasal dari noise lingkungan. Selain itu, dilakukan juga normalisasi untuk menyamakan skala amplitudo sinyal sehingga mengurangi pengaruh variasi antar jenis sinyal.

Pada penelitian ini digunakan metode *Z-score Normalization*, yaitu teknik normalisasi data dengan mengubah setiap nilai berdasarkan rata-rata (mean) dan simpangan baku (standard deviation) dari data, sehingga menghasilkan distribusi dengan rata-rata bernilai 0 dan simpangan baku bernilai 1. Teknik ini bertujuan untuk menyamakan skala data tanpa menghilangkan karakteristik atau pola dasar sinyal EEG, sehingga setiap fitur memiliki kontribusi yang lebih seimbang pada proses analisis dan klasifikasi.

- 2) Tahap berikutnya adalah ekstraksi fitur, yaitu proses pengambilan ciri-ciri penting dari sinyal EEG yang telah diproses sehingga dapat merepresentasikan kondisi mental pengguna. Pada penelitian ini, sinyal terlebih dahulu ditransformasikan ke domain frekuensi menggunakan metode Fast Fourier Transform (FFT) untuk memperoleh nilai Power Spectral Density (PSD).

Melalui PSD, diperoleh nilai daya spektral dari masing-masing pita frekuensi EEG, khususnya gelombang Theta (4–8 Hz), Alpha (8–13 Hz), dan Beta (13–30 Hz) yang memiliki keterkaitan kuat dengan kondisi stres. Selain itu, dilakukan perhitungan rasio antar gelombang, seperti rasio Alpha/Beta, yang sering digunakan sebagai indikator tingkat stres. Selanjutnya, fitur-fitur yang


telah diperoleh digunakan sebagai input dalam proses klasifikasi menggunakan algoritma Random Forest.

Pada tahap ini dilakukan penentuan parameter dan hyperparameter untuk memperoleh performa model yang optimal. Parameter yang digunakan meliputi jumlah pohon (*n_estimators*), kedalaman maksimum pohon (*max_depth*), jumlah fitur yang dipertimbangkan pada setiap split (*max_features*), serta jumlah minimum sampel untuk melakukan pemisahan node (*min_samples_split*). Untuk mendapatkan kombinasi hyperparameter terbaik, digunakan metode Grid Search yang menguji berbagai kombinasi nilai parameter secara sistematis. Proses evaluasi setiap kombinasi dilakukan menggunakan Cross Validation, sehingga model yang dihasilkan memiliki kemampuan generalisasi yang baik dan tidak mengalami overfitting.

- 3) Tahap terakhir adalah proses klasifikasi menggunakan algoritma Random Forest untuk mengelompokkan kondisi mental pengguna berdasarkan fitur yang telah diekstraksi. Fitur yang digunakan sebagai input model meliputi nilai Power Spectral Density (PSD) dari masing-masing pita frekuensi EEG, yaitu Theta, Alpha, dan Beta, serta fitur turunan berupa rasio antar gelombang yakni rasio Alpha/Beta yang merepresentasikan tingkat stres. Fitur-fitur tersebut dipilih karena memiliki keterkaitan fisiologis dengan aktivitas otak yang berhubungan dengan kondisi relaksasi maupun tekanan mental.

Algoritma Random Forest bekerja dengan membangun sejumlah pohon keputusan dari subset data dan fitur yang dipilih secara acak, kemudian menggabungkan hasil prediksi dari setiap pohon melalui mekanisme *majority voting* untuk menghasilkan keputusan akhir. Pendekatan ini mampu meningkatkan akurasi serta mengurangi risiko overfitting dibandingkan dengan satu pohon keputusan tunggal. Model yang digunakan merupakan hasil optimasi hyperparameter sebelumnya menggunakan metode Grid Search yang dikombinasikan dengan Cross Validation, sehingga parameter seperti jumlah pohon (*n_estimators*), kedalaman pohon (*max_depth*), serta jumlah fitur (*max_features*) telah berada pada kondisi optimal. Output dari proses klasifikasi ini berupa label kondisi mental pengguna, yaitu kategori stres dan normal, yang

ditentukan berdasarkan pola distribusi fitur EEG yang telah dipelajari oleh model selama proses pelatihan.




Gambar 2. 2 Proses Sinyal EEG²

2.1.4 NeuroSky MindWave Mobile

NeuroSky MindWave merupakan headset EEG (Electroencephalography) portable dan nirkabel yang dirancang untuk merekam aktivitas gelombang otak secara aman, real-time, dan praktis di luar lingkungan laboratorium klinis. Perangkat ini menggunakan teknologi biosensor yang dapat mendeteksi sinyal listrik otak pada frekuensi rendah dari posisi FP1 (prefrontal cortex) di dahi, kemudian mengirimkan data tersebut secara nirkabel melalui koneksi Bluetooth untuk diproses lebih lanjut oleh komputer atau perangkat tertanam.

²https://media.springernature.com/lw685/springer-static/image/chp%3A10.1007%2F978-981-16-5540-1_78/MediaObjects/471638_1_En_78_Fig9_HTML.png



Gambar 2. 3 Posisi Sensor Neurosky Mindwave³

Secara komponen fisik, MindWave terdiri dari tiga bagian utama: headset, sensor arm, dan ear-clip. Elektroda referensi dan ground terletak pada ear-clip yang menjepit telinga, sedangkan elektroda pengukur EEG berada pada sensor arm yang menyentuh area dahi di atas mata. Perangkat ini bekerja dengan mengambil sinyal EEG mentah (raw EEG) dalam rentang frekuensi 3–100 Hz dengan sampling rate 512 Hz, kemudian memprosesnya menjadi beberapa output seperti spektrum gelombang otak (Alpha, Beta, dll).

Karena bobot headset yang ringan (sekitar 90g) dan konsumsi daya yang rendah, MindWave sangat cocok untuk aplikasi yang membutuhkan mobilitas dan kenyamanan pengguna, termasuk penelitian serta aplikasi dalam bidang pendidikan, kesehatan, relaksasi, dan pengembangan antarmuka otak-komputer (Brain–Computer Interface/BCI).

2.1.5 Embedded System

Embedded system merupakan sistem komputasi khusus yang dirancang untuk menjalankan fungsi tertentu di dalam suatu perangkat atau produk. Sistem ini umumnya terdiri dari perangkat keras seperti mikrokontroler atau mikroprosesor, memori, sensor, aktuator, serta perangkat lunak tertanam (*firmware*) yang bekerja

³https://www.researchgate.net/figure/Neurosky-mindwave-electrode-Location-at-FP115_fig2_357832429

secara terintegrasi. Berbeda dengan komputer umum, embedded system dirancang untuk bekerja secara spesifik, real-time, dan sering kali dengan keterbatasan sumber daya seperti daya, memori, dan kapasitas pemrosesan. Embedded system banyak digunakan pada berbagai aplikasi, mulai dari peralatan elektronik, sistem otomasi industri, perangkat medis, hingga perangkat wearable, karena kemampuannya dalam melakukan pengolahan data dan pengendalian sistem secara langsung dan efisien (Jaya et al., 2017).

Secara arsitektur, embedded system umumnya terdiri dari beberapa komponen utama, yaitu unit pemrosesan (mikrokontroler atau mikroprosesor), modul input berupa sensor untuk membaca kondisi lingkungan atau sinyal fisik, modul output berupa aktuator atau tampilan, serta perangkat lunak tertanam yang mengatur alur kerja sistem. Dalam banyak aplikasi, embedded system juga harus mampu bekerja secara *real-time*, artinya sistem harus merespons input dalam batas waktu tertentu sesuai kebutuhan aplikasi.

2.1.6 Waveshare ESP32-S3 Touch AMOLED 2.06

Waveshare ESP32-S3 Touch AMOLED 2.06 merupakan modul pengembangan berbasis mikrokontroler ESP32-S3 yang dilengkapi layar sentuh AMOLED berukuran 2,06 inci dengan resolusi tinggi, sehingga cocok digunakan untuk aplikasi yang membutuhkan antarmuka visual interaktif seperti perangkat wearable. Modul ini mengintegrasikan chip ESP32-S3 yang memiliki prosesor dual-core serta mendukung konektivitas nirkabel Wi-Fi dan Bluetooth, dengan kapasitas memori dan kecepatan pemrosesan yang memadai untuk menjalankan inferensi model machine learning secara langsung pada perangkat (on-device). Khusus untuk komunikasi Bluetooth, chip ESP32-S3 hanya mendukung mode Bluetooth Low Energy (BLE) dan tidak mendukung Bluetooth Classic beserta profil SPP di dalamnya.



Gambar 2. 4 Waveshare ESP32-S3 unit

2.1.7 ESP32

ESP32 merupakan mikrokontroler berbasis System-on-Chip (SoC) yang dikembangkan oleh Espressif Systems dan banyak digunakan pada sistem embedded maupun Internet of Things (IoT) karena mengintegrasikan prosesor, memori, antarmuka perifer, serta modul komunikasi nirkabel dalam satu chip. ESP32 mendukung berbagai antarmuka komunikasi seperti UART, SPI, I²C, PWM, ADC, dan GPIO, sehingga mudah diintegrasikan dengan berbagai sensor dan perangkat eksternal. Salah satu keunggulan utama ESP32 adalah dukungannya terhadap Bluetooth Classic dan Bluetooth Low Energy (BLE). Pada Bluetooth Classic, ESP32 mendukung Serial Port Profile (SPP) yang memungkinkan komunikasi data secara serial melalui Bluetooth, sedangkan BLE dirancang untuk komunikasi dengan konsumsi daya yang lebih rendah dan kompatibel dengan berbagai perangkat modern. Kemampuan mendukung komunikasi SPP dan BLE tersebut menjadikan ESP32 sesuai digunakan pada sistem yang memerlukan pertukaran data nirkabel antara perangkat dengan teknologi Bluetooth yang berbeda.



Gambar 2. 5 ESP32

2.1.8 Bluetooth

Bluetooth merupakan teknologi komunikasi nirkabel jarak pendek yang bekerja pada frekuensi radio 2,4 GHz dan umum digunakan untuk pertukaran data antar perangkat elektronik tanpa memerlukan kabel. Dalam standar Bluetooth, terdapat dua jenis mode komunikasi utama, yaitu Bluetooth Classic dengan profil Serial Port Profile (SPP) dan Bluetooth Low Energy (BLE). SPP merupakan profil pada Bluetooth Classic yang mengemulasikan komunikasi serial (seperti RS-232) sehingga cocok untuk transfer data dengan throughput lebih tinggi secara terus-menerus, namun mengonsumsi daya yang relatif besar. Sementara itu, BLE dirancang khusus untuk efisiensi energi dengan mekanisme pengiriman data secara singkat dan berkala (burst), sehingga lebih hemat daya dan cocok digunakan pada perangkat wearable atau IoT yang mengandalkan baterai kecil, meskipun throughput datanya lebih rendah dibandingkan SPP.




Gambar 2. 6 Logo Bluetooth

2.1.9 Random Forest

Sinyal EEG bersifat non-stasioner, memiliki variasi antar individu, serta rentan terhadap noise dan artefak. Kondisi tersebut menyebabkan metode analisis tradisional sering menghasilkan akurasi yang tidak konsisten. *Machine learning* menawarkan solusi dengan memanfaatkan kemampuan pembelajaran pola statistik dan non-linear dari data EEG, sehingga mampu meningkatkan akurasi dan robustitas sistem klasifikasi (Phadikar et al., 2022).

Dalam sistem klasifikasi stres menggunakan sinyal EEG, *machine learning* umumnya digunakan setelah tahap ekstraksi fitur. Fitur-fitur seperti nilai Power Spectral Density (PSD) rasio alpha/beta, dan rasio theta/beta digunakan sebagai input model pembelajaran. Model kemudian dilatih untuk memetakan fitur-fitur tersebut ke dalam kelas tertentu, misalnya kondisi stres dan tidak stres. Pendekatan ini memungkinkan sistem untuk bekerja secara adaptif terhadap variasi sinyal EEG

antar individu dan kondisi lingkungan. Model algoritma yang biasanya digunakan dalam melakukan klasifikasi stres menggunakan sinyal EEG adalah random forest.



Gambar 2. 7 Algoritma Random Forest⁴

Random Forest (RF) merupakan algoritma *machine learning* berbasis *ensemble learning* yang bekerja dengan membangun sejumlah pohon keputusan (*decision tree*) secara acak dan menggabungkan hasil prediksinya untuk menghasilkan keputusan akhir. Setiap pohon keputusan dibangun dari subset data dan fitur yang dipilih secara acak, sehingga mampu mengurangi bias dan varians model. Proses klasifikasi atau prediksi pada Random Forest dilakukan melalui evaluasi aturan sederhana berbasis *if-else* pada setiap pohon, kemudian hasilnya ditentukan berdasarkan mekanisme pemungutan suara (*majority voting*) atau rata-rata keluaran (Kamau et al., 2023). Pendekatan ini memungkinkan Random Forest untuk menangani data berdimensi tinggi, hubungan non-linear, serta meningkatkan ketahanan terhadap noise dan overfitting, terutama pada dataset berukuran kecil hingga menengah.

Pada tahap pelatihan, Random Forest membangun setiap pohon keputusan menggunakan teknik *bootstrap sampling*, yaitu pengambilan data secara acak dengan pengembalian dari dataset pelatihan. Selain itu, pada setiap node pohon keputusan hanya dipilih sejumlah fitur secara acak untuk menentukan pemisahan data terbaik. Kriteria pemisahan yang umum digunakan adalah Gini Impurity, yang dirumuskan sebagai:

⁴ <https://www.scaler.com/topics/machine-learning/random-forest-algorithm/>

$$Gini = 1 - \sum_{k=1}^c p_k^2 \quad (1)$$

Dimana:

- C = jumlah kelas
- p_k = proporsi data yang termasuk kelas ke- k
- k = penomoran kelas

Selanjutnya pada tahap prediksi, setiap pohon keputusan menghasilkan satu hasil klasifikasi berdasarkan aturan logika berbasis *if-else*. Prediksi akhir diperoleh dengan menggabungkan seluruh hasil pohon menggunakan pemungutan suara mayoritas. Pendekatan ini membuat Random Forest lebih tahan terhadap fluktuasi sinyal EEG dan gangguan (*noise*) yang bersifat non-linear.

Untuk menilai kinerja model yang telah dibuat, maka dilakukan dengan menghitung tingkat akurasi, yang dirumuskan sebagai:

Akurasi

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

Akurasi menunjukkan proporsi seluruh prediksi yang diklasifikasikan dengan benar terhadap seluruh data pengujian

Presisi

$$Presisi = \frac{TP}{TP + FP} \quad (3)$$

Presisi mengukur kemampuan model dalam menghasilkan prediksi positif yang benar. Nilai presisi yang tinggi menunjukkan bahwa sebagian besar prediksi positif merupakan prediksi yang benar.

Recall

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

Recall mengukur kemampuan model dalam mendeteksi seluruh data positif yang sebenarnya. Semakin tinggi nilai recall, semakin sedikit data positif yang terlewatkan.

F1-Score

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

F1-score merupakan rata-rata harmonik antara presisi dan recall. Metrik ini digunakan ketika diperlukan keseimbangan antara kemampuan mendeteksi kelas positif dan ketepatan prediksi positif


Dimana:

- TP = True Positive
- TN = True Negative
- FP = False Positive
- FN = False Negative

Dengan memanfaatkan teknik bootstrap sampling, pemilihan fitur acak, dan mekanisme penggabungan prediksi berbasis majority voting, Random Forest mampu menghasilkan model klasifikasi yang stabil, tahan terhadap noise, dan efektif untuk dataset EEG berukuran kecil hingga menengah dengan beban komputasi yang relatif ringan.

2.1.10 Visual Studio Code

Visual Studio Code (VSCode) merupakan sebuah *source code editor* yang dikembangkan oleh Microsoft dan telah banyak dimanfaatkan dalam pengembangan perangkat lunak modern karena kemampuannya dalam mendukung penulisan kode dengan berbagai bahasa pemrograman. Dalam konteks akademik dan pengembangan aplikasi, VSCode mendukung berbagai bahasa pemrograman, antara lain HTML, CSS, JavaScript, Python, dan C/C++ dan mendukung fitur seperti *syntax highlighting*, *auto-completion*, serta *error detection* untuk meminimalkan kesalahan penulisan kode. Selain itu, VSCode menyediakan fitur *integrated terminal* dan *debugging* yang memungkinkan pengguna menjalankan serta menguji program secara langsung di dalam editor (Agung et al., 2025).



Gambar 2. 8 Ikon VSCode⁵

2.1.11 Python

Python merupakan bahasa tingkat tinggi yang dirancang untuk memudahkan proses penulisan program karena sintaksnya yang sederhana dan intuitif, sehingga cocok bagi pemula maupun pengembang profesional. Python mendukung berbagai paradigma pemrograman seperti prosedural, berorientasi objek, dan fungsional, serta memiliki pustaka standar yang luas yang dapat digunakan pada beragam aplikasi seperti pengembangan web, *data science*, kecerdasan buatan, hingga *automation* (Maulana, 2024).

Salah satu fitur yang tersedia pada python adalah sebagai bahasa pemrograman dinamis yang dilengkapi dengan manajemen memori otomatis. Seperti halnya pada bahasa pemrograman dinamis lainnya, python umumnya digunakan sebagai bahasa script meski pada praktiknya penggunaan bahasa ini lebih luas mencakup konteks pemanfaatan yang umumnya tidak dilakukan dengan menggunakan bahasa script. Python dapat digunakan untuk berbagai keperluan pengembangan perangkat lunak dan dapat berjalan di berbagai platform sistem operasi seperti:

1. Linux/Unix
2. Windows
3. Mac OS X
4. Java Virtual Machine
5. Amiga
6. Palm

⁵ https://backend.global-inovasi.com/storage/tb_news/01J55GV1M5GAM8BQ3JVZ2N128C.png

Pada dasarnya, Python tersedia untuk diunduh dan digunakan secara bebas, termasuk untuk tujuan komersial. Lisensi yang diterapkan pada Python juga tidak bertentangan dengan prinsip *Open Source*.



Gambar 2. 9 Ikon Python⁶

2.1.12 Arduino Integrated Development Environment (IDE)

Arduino IDE merupakan salah satu *development environment* yang paling banyak digunakan untuk pemrograman mikrokontroler pada platform Arduino. Menurut (Holovatsky, 2025), Arduino IDE berfungsi sebagai lingkungan pengembangan yang menyediakan proses penulisan, kompilasi, dan pengunggahan kode program ke mikrokontroler, serta menghasilkan *firmware* yang akan dieksekusi langsung oleh perangkat keras. Kualitas kode yang dihasilkan oleh Arduino IDE berpengaruh terhadap kinerja sistem tertanam, terutama dalam hal kecepatan eksekusi, penggunaan memori, dan efisiensi sumber daya mikrokontroler.

Selain melakukan kompilasi dan unggah program, Arduino IDE juga menyediakan lapisan abstraksi perangkat keras melalui pustaka (*libraries*) yang memungkinkan pemrogram untuk mengakses fitur mikrokontroler seperti GPIO, komunikasi serial, I²C, dan SPI tanpa perlu menulis secara langsung register tingkat rendah. Hal ini sangat relevan dalam pengembangan sistem berbasis sensor dan aktuator, terutama pada aplikasi Internet of Things (IoT) dan pengendalian otomatis.

⁶https://upload.wikimedia.org/wikipedia/commons/thumb/f/f8/Python_logo_and_wordmark.svg/1280px-Python_logo_and_wordmark.svg.png



Gambar 2. 10 Ikon Arduino IDE⁷

2.1.13 Liquid Crystal Display (LCD)

Liquid Crystal Display (LCD) merupakan perangkat tampilan (*display*) yang menggunakan sifat optik kristal cair untuk menampilkan informasi dalam bentuk teks, angka, atau grafis. LCD bekerja dengan mengatur orientasi molekul kristal cair di antara dua lapisan polarisator sehingga cahaya latar (*backlight*) dapat dikontrol untuk membentuk tampilan visual sesuai dengan sinyal listrik yang diberikan. Dalam sistem elektronika dan sistem tertanam (*embedded system*), LCD banyak digunakan sebagai media antarmuka antara sistem dan pengguna karena kemampuannya menampilkan data hasil pengukuran, status sistem, maupun informasi lainnya secara real-time dengan konsumsi daya yang relatif rendah.



Gambar 2. 11 Liquid Crystal Display (LCD)⁸

⁷https://upload.wikimedia.org/wikipedia/commons/thumb/7/73/Arduino_IDE_logo.svg/960px-Arduino_IDE_logo.svg.png

⁸ <https://toughthware.com/wp-content/uploads/2023/03/Screenshot-2023-03-08-124622.png>

2.2 Penelitian Terdahulu

Penelitian terkait deteksi stres menggunakan *machine learning* telah dilakukan oleh beberapa peneliti, di antaranya oleh.

Berdasarkan penelitian yang dilakukan oleh (Pan, 2021), mereka mengembangkan sistem klasifikasi tingkat stres berbasis sinyal electroencephalography (EEG) dengan memanfaatkan headset EEG multi-channel (14 channel) sebagai perangkat akuisisi data. Sinyal EEG ditampilkan dalam bentuk fitur statistik domain waktu yang mencerminkan karakteristik temporal sinyal, seperti nilai rata-rata, standar deviasi, varians, *root mean square*, serta ukuran kompleksitas sinyal seperti *entropy* dan *Hjorth parameters*. Fitur-fitur tersebut digunakan sebagai masukan ke dalam model Jaringan Saraf Tiruan (JST) untuk mengklasifikasikan kondisi stres dan non-stres. Hasil pengujian menunjukkan bahwa model JST mampu mencapai akurasi sebesar 93,8%, dan meningkat hingga 95,4% setelah diterapkan proses seleksi fitur menggunakan *genetic algorithm*. Kelebihan sistem ini terletak pada akurasi dan kemampuannya memodelkan data yang non-linier. Namun demikian, dari hasil penelitian disebutkan bahwa keterbatasan JST adalah sistem ini memerlukan dataset yang sangat besar dan beragam, jika dataset yang dimiliki terbatas maka JST akan cenderung mengalami overfitting, di mana model terlalu menyesuaikan dengan data latihan namun gagal melakukan generalisasi pada data baru dan hal ini sejalan dengan pernyataan (Narasingarao et al., 2018). Tak hanya itu, berdasarkan (Kamau et al., 2023), JST memerlukan operasi perkalian matriks yang intensif dan penggunaan memori (RAM) yang besar untuk menyimpan bobot neuron, sehingga kurang efisien jika diimplementasikan pada perangkat berbasis low-power mikroprosesor.

(Juliantino & Widasari, 2025) mengusulkan sistem deteksi dini stres berbasis sinyal EEG dengan menerapkan metode K-Nearest Neighbor (K-NN). Data EEG diperoleh menggunakan perangkat Neurosky Mindwave Mobile 2, kemudian diekstraksi menjadi fitur Mean Absolute Value (MAV) serta rasio MAV pada pita frekuensi beta dan alpha. Berdasarkan hasil pengujian, metode K-NN mampu mencapai akurasi sebesar 84% dengan waktu komputasi rata-rata 0,12622 detik. Kelebihan sistem ini terletak pada kecepatan pemrosesannya, sehingga berpotensi diterapkan pada sistem real-time. Namun demikian, metode K-NN menggunakan

memori RAM yang sangat besar karena model harus menyimpan seluruh dataset latihan sebagai referensi sehingga kurang cocok jika diterapkan pada embedded system dengan sumber daya yang terbatas (Jain & Srihari, 2024).

(Sifaunnufus et al., 2024) mengembangkan sistem deteksi stres berbasis sinyal EEG dengan menggunakan algoritma Random Forest sebagai metode klasifikasi. Pada penelitian ini, sinyal EEG terlebih dahulu melalui tahapan pra-pemrosesan dan ekstraksi fitur menggunakan Power Spectral Density (PSD) sebelum diklasifikasikan. Hasil pengujian menunjukkan bahwa model Random Forest mampu mengklasifikasikan tingkat stres dengan akurasi sebesar 100%, serta waktu klasifikasi yang relatif cepat, yaitu sekitar 1,03 detik. Temuan ini menunjukkan bahwa Random Forest memiliki kemampuan yang baik dalam menangani karakteristik sinyal EEG yang kompleks dan berdimensi tinggi. Kelebihan pendekatan ini terletak pada kestabilan performa dan ketahanannya terhadap noise.

Tabel 2. 1 Penelitian Terdahulu

No	Peneliti	Metode	Dataset & Fitur EEG	Perangkat yang digunakan	Kelebihan	Hasil Penelitian
1	Pan (2021)	Jaringan Saraf Tiruan (JST)	Dataset EEG 14 channel, time-domain features (TDF)	Headband 14 Channel	Akurasi tinggi	Akurasi sebesar 93,8 % - 95,4%
2	Juliantino & Widasari (2025)	K-Nearest Neighbor (K-NN)	Dataset primer, fitur Mean Absolute Value (MAV)	NeuroSky Mindwave mobile 2, laptop (MATLAB)	Waktu komputasi cepat	Akurasi sebesar 84%, waktu komputasi rata-rata 0,12622 detik
3	Sifaunnufus et al. (2024)	Random Forest	Dataset primer, Power Spectral Density (PSD)	Muse 2, laptop dan Raspberry Pi 4 Model B	Tahan terhadap noise, akurasi tinggi	Akurasi 100%, waktu komputasi sekitar 1,03 detik

Berdasarkan peneltian-penelitian terdahulu maka, penggunaan Random Forest (RF) dalam penelitian ini didasarkan pada pertimbangan efisiensi komputasi serta keterbatasan jumlah data yang tersedia. Random Forest sendiri adalah metode *ensemble learning* berbasis pohon keputusan yang melakukan proses klasifikasi dengan menggunakan aturan sederhana *if-else*, sehingga memiliki kompleksitas komputasi yang relatif rendah pada tahap inferensi. Sehingga lebih stabil terhadap noise dan memiliki risiko overfitting yang lebih rendah pada dataset skala menengah dibandingkan metode pembelajaran mendalam seperti jst yang umumnya memerlukan jumlah data yang besar untuk mencapai performa optimal (Jain & Srihari, 2024).