



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 5 No. 1 (2026) pp: 5035-5042

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Implementasi Sistem Deteksi Detak Jantung Berbasis Long Short-Term Memory (LSTM) pada Perangkat Mobile

Akhmad Khaerudin¹, Bambang Irawan²

^{1,2}Jurusan Teknik Informatika, Fakultas Teknik, Universitas Muhadi Setiabudi

¹akhmadkhaer74@gmail.com, ²bambangumus@gmail.com

Abstrak

Penyakit kardiovaskular tetap menjadi penyebab utama kematian di dunia, sehingga mendorong pihak-pihak terkait untuk mengembangkan sistem pemantauan detak jantung yang menggunakan elektrokardiogram (ECG) dan bisa bekerja secara langsung dalam waktu nyata. Perkembangan perangkat mobile dan wearable membuat pendekatan inferensi di perangkat (on-device inference) semakin penting karena bisa mengurangi keterlambatan, meminimalkan ketergantungan pada jaringan, serta melindungi data pribadi. Namun, sebagian besar penelitian tentang klasifikasi detak jantung menggunakan machine learning masih lebih memperhatikan akurasi model, sedangkan penilaian mengenai kemampuan komputasi sistem inferensi ECG pada perangkat mobile masih kurang lengkap. Penelitian ini bertujuan membuat dan mengecek bagaimana sistem untuk mengira detak jantung secara langsung, berjalan di perangkat Android, menggunakan cara pemrosesan aliran data. Sistem ini menggunakan data ECG dari sensor Polar H10 dan memanfaatkan model LSTM yang sudah dilatih dari penelitian sebelumnya, yang telah diubah ke dalam format TensorFlow Lite. Pengembangan dilakukan dengan pendekatan prototyping berulang kali, meliputi penerimaan sinyal ECG, pembersihan sinyal, pencarian puncak R, pemotongan gelombang jantung, serta proses pengambilan kesimpulan. Evaluasi kinerja dilakukan dengan mempertimbangkan beberapa parameter seperti waktu yang dibutuhkan untuk menghasilkan hasil, penggunaan prosesor, penggunaan memori, serta kemampuan sistem dalam menangani data secara simultan. Hasil percobaan menunjukkan rata-rata waktu inferensi sebesar 34,79 milidetik, penggunaan memori RAM sebesar 13,04 megabyte, penggunaan CPU sebesar 17,05 persen, serta tingkat throughput mencapai 1,65 inferensi per detik. Temuan ini memberikan bukti nyata tentang kemampuan dan sifat-sifat kerja sistem inferensi detak jantung secara real-time yang menggunakan machine learning pada perangkat mobile.

Kata kunci: Elektrokardiogram, Inferensi, Stream Processing, Polar H10, Android

1. Latar Belakang

Penyakit kardiovaskular masih menjadi penyebab kematian tertinggi di dunia dan memberikan beban signifikan terhadap sistem layanan kesehatan global, terutama di negara dengan pendapatan menengah dan rendah (World Health Organization, 2025; Chong et al., 2025). Tingginya angka morbiditas dan mortalitas tersebut menunjukkan pentingnya deteksi dini serta pemantauan kondisi jantung secara berkelanjutan. Dalam praktik klinis, pemantauan aktivitas listrik jantung melalui sinyal elektrokardiogram (ECG) telah menjadi standar utama dalam mengidentifikasi gangguan irama jantung dan anomali kardiovaskular (Chicco et al., 2024). Namun, pendekatan konvensional yang bergantung pada fasilitas kesehatan memiliki keterbatasan dalam hal kontinuitas pemantauan dan aksesibilitas, khususnya bagi pasien dengan mobilitas tinggi atau keterbatasan akses layanan kesehatan.

Perkembangan teknologi *wearable* dan perangkat mobile membuka peluang baru dalam transformasi sistem pemantauan jantung. Sensor seperti Polar H10 mampu menghasilkan sinyal ECG dengan kualitas yang mendekati perangkat klinis (Gilgen-Ammann et al., 2019), sehingga memungkinkan akuisisi data fisiologis secara *real-time* dalam aktivitas sehari-hari. Integrasi sensor *wearable* dengan smartphone menghadirkan paradigma pemantauan berbasis *edge device*, di mana pemrosesan data dapat dilakukan langsung pada perangkat pengguna tanpa ketergantungan penuh terhadap infrastruktur rumah sakit atau server terpusat.

Seiring dengan kemajuan kecerdasan buatan, pendekatan *deep learning* semakin dominan dalam analisis sinyal ECG. Model berbasis deret waktu seperti *Long Short-Term Memory (LSTM)* terbukti efektif dalam menangkap dependensi temporal pada sinyal jantung, sehingga mampu meningkatkan performa klasifikasi detak jantung dibandingkan metode konvensional (Foresta et al., 2023; Pramukantoro et al., 2025a). Keunggulan LSTM

terletak pada kemampuannya mempertahankan informasi jangka panjang dalam rangkaian sinyal, yang relevan untuk mendeteksi pola abnormal yang tidak selalu muncul dalam satu siklus jantung tunggal.

Berbagai penelitian telah menunjukkan keberhasilan penerapan model *deep learning* untuk klasifikasi irama jantung di perangkat mobile. De Melo Ribeiro et al. (2022) mengembangkan sistem klasifikasi irama jantung berbasis jaringan saraf terkuantisasi menggunakan TensorFlow Lite pada smartphone dan melaporkan latensi inferensi yang rendah serta konsumsi energi yang relatif efisien. Tan et al. (2022) menggunakan pendekatan Neural Architecture Search (NAS) untuk merancang model Convolutional Neural Network (CNN) ringan yang dioptimalkan untuk perangkat *mobile*, dengan fokus pada efisiensi komputasi dan respons *real-time*. Penelitian lain oleh Spicher et al. (2021) memanfaatkan arsitektur *edge computing* berbasis 5G, di mana smartphone berfungsi sebagai pengumpul data sementara proses inferensi dilakukan pada server *edge* untuk menjaga performa waktu nyata.

Meskipun hasil-hasil tersebut menunjukkan bahwa inferensi ECG pada perangkat *mobile* memungkinkan secara teknis, sebagian besar penelitian masih menitikberatkan pada akurasi model atau optimasi arsitektur jaringan saraf. Evaluasi komprehensif terhadap kinerja komputasi sistem saat dijalankan secara langsung pada perangkat pengguna nyata masih relatif terbatas. Parameter seperti penggunaan CPU, konsumsi memori, latensi inferensi aktual, serta stabilitas sistem dalam skenario *streaming* data berkelanjutan jarang dibahas secara mendalam. Padahal, dalam konteks implementasi nyata, keberhasilan sistem tidak hanya ditentukan oleh akurasi klasifikasi, tetapi juga oleh efisiensi dan keberlanjutan operasionalnya pada perangkat dengan sumber daya terbatas.

Penelitian oleh Pramukantoro et al. (2025a) dan Pramukantoro et al. (2025b) mulai mengarah pada evaluasi performa komputasi model LSTM dan CNN pada perangkat *edge* dengan spesifikasi relatif tinggi seperti Raspberry Pi dan Intel NUC. Studi tersebut menunjukkan bahwa terdapat *trade-off* antara kompleksitas model, akurasi, dan efisiensi komputasi saat inferensi dilakukan secara *real-time*. Namun, perangkat seperti Raspberry Pi dan Intel NUC masih memiliki kapasitas komputasi yang lebih besar dibandingkan sebagian besar smartphone kelas menengah. Dengan demikian, hasil penelitian tersebut belum sepenuhnya merepresentasikan kondisi operasional pada perangkat mobile Android yang umum digunakan masyarakat.

Di sisi lain, Zhang (2023) menyoroti potensi peningkatan performa melalui penerapan *multi-threading* pada perangkat mobile, sementara Li et al. (2024) menekankan bahwa inferensi di perangkat dapat mengurangi latensi jaringan dan meningkatkan privasi data, tetapi tetap membutuhkan pengelolaan sumber daya CPU dan memori yang efisien agar sistem tetap stabil saat beroperasi secara *real-time*. Temuan-temuan ini memperlihatkan bahwa persoalan utama dalam implementasi sistem deteksi detak jantung berbasis *deep learning* di perangkat mobile bukan semata pada kemampuan model mengenali pola, melainkan pada bagaimana model tersebut beroperasi secara efisien dan stabil dalam keterbatasan lingkungan komputasi nyata.

Berdasarkan telaah tersebut, terdapat kesenjangan penelitian yang jelas. Pertama, masih terbatas penelitian yang secara khusus mengevaluasi kinerja inferensi model LSTM berbasis *streaming* ECG pada perangkat Android nyata dengan pengukuran terperinci terhadap penggunaan CPU, memori, dan latensi waktu nyata. Kedua, sebagian studi melakukan pengujian pada emulator atau perangkat *edge* dengan spesifikasi tinggi, sehingga kurang merepresentasikan kondisi implementasi pada smartphone pengguna umum. Ketiga, integrasi antara sensor *wearable* komersial seperti Polar H10 dengan sistem inferensi LSTM berbasis TensorFlow Lite pada Android dalam skenario *real-time* belum banyak dianalisis secara menyeluruh dari sisi performa komputasi.

Atas dasar kesenjangan tersebut, penelitian ini dilakukan untuk mengimplementasikan sistem deteksi detak jantung berbasis LSTM yang berjalan langsung pada perangkat Android dengan memanfaatkan data ECG dari sensor Polar H10. Model LSTM yang telah dilatih sebelumnya dikonversi ke format *TensorFlow Lite* agar kompatibel dengan lingkungan mobile, kemudian diintegrasikan ke dalam sistem pemrosesan aliran data (*stream processing*) sehingga inferensi dapat dilakukan secara *real-time* tanpa ketergantungan pada server eksternal. Fokus utama penelitian ini bukan pada pengembangan arsitektur model baru atau peningkatan akurasi klasifikasi, melainkan pada evaluasi kemampuan komputasi sistem saat beroperasi dalam kondisi nyata.

Kebaruan penelitian ini terletak pada pendekatan evaluasi performa inferensi LSTM secara langsung di perangkat Android nyata dalam konteks pemrosesan *streaming* ECG, dengan pengukuran terstruktur terhadap latensi inferensi, penggunaan CPU, penggunaan memori, dan kapasitas pemrosesan data per satuan waktu. Pendekatan ini memberikan gambaran praktis mengenai kelayakan implementasi sistem deteksi detak jantung berbasis *deep learning* pada perangkat mobile kelas umum, sekaligus memperkaya literatur yang selama ini lebih berorientasi pada akurasi model atau pengujian di lingkungan terkontrol.

Dengan demikian, pertanyaan penelitian yang ingin dijawab dalam studi ini adalah: (1) sejauh mana sistem inferensi detak jantung berbasis LSTM yang dijalankan menggunakan *TensorFlow Lite* pada perangkat Android mampu memenuhi kebutuhan pemrosesan *real-time* dalam skenario *streaming* ECG; (2) bagaimana karakteristik penggunaan sumber daya komputasi, khususnya CPU dan memori, selama sistem beroperasi secara kontinu; dan (3) apakah performa komputasi yang dihasilkan cukup efisien untuk mendukung implementasi sistem pemantauan jantung berbasis mobile secara praktis dan berkelanjutan.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan implementatif dan eksperimental untuk merancang serta mengevaluasi sistem deteksi detak jantung berbasis *Long Short-Term Memory (LSTM)* yang dijalankan secara langsung pada perangkat Android. Pendekatan implementatif dipilih karena penelitian berfokus pada pembangunan sistem nyata yang beroperasi dalam lingkungan perangkat bergerak dengan keterbatasan sumber daya komputasi. Sementara itu, pendekatan eksperimental diterapkan untuk mengukur performa komputasi sistem secara objektif dalam kondisi operasional sebenarnya. Evaluasi performa pada perangkat *edge* menjadi aspek penting dalam penelitian sistem kecerdasan buatan modern, karena keberhasilan implementasi tidak hanya ditentukan oleh akurasi model, tetapi juga oleh efisiensi latensi dan konsumsi sumber daya (Li et al., 2024).

Pengembangan sistem dilakukan menggunakan metode *prototyping* secara iteratif. Pendekatan ini memungkinkan proses perancangan, implementasi, pengujian, dan penyempurnaan dilakukan secara bertahap hingga sistem mencapai kondisi stabil dan siap untuk eksperimen performa. Metode *prototyping* dinilai sesuai untuk penelitian yang melibatkan integrasi perangkat keras dan perangkat lunak, khususnya dalam pengembangan aplikasi berbasis kecerdasan buatan pada perangkat bergerak (Zahrah & Suranto, 2025). Dalam penelitian ini, sistem yang dikembangkan mengintegrasikan sensor *wearable* Polar H10, aplikasi Android, serta model *deep learning* dalam format TensorFlow Lite.

Tahap awal penelitian adalah analisis kebutuhan sistem untuk memastikan seluruh komponen berjalan sesuai tujuan penelitian. Sistem dirancang agar mampu melakukan akuisisi sinyal elektrokardiogram (ECG) secara kontinu melalui koneksi *Bluetooth Low Energy (BLE)*, melakukan pemrosesan awal sinyal secara *real-time*, mendeteksi puncak R (*R-peak*), melakukan segmentasi siklus detak jantung, menjalankan inferensi model *LSTM*, serta mencatat parameter performa komputasi seperti latensi, penggunaan CPU, penggunaan memori, dan *throughput*. Pemilihan protokol *BLE* didasarkan pada efisiensinya dalam konsumsi energi dan kemampuannya mendukung transmisi data fisiologis secara *real-time* pada perangkat bergerak (Gufon & Ardiwinata, 2025).

Arsitektur sistem dirancang secara modular untuk memisahkan setiap tahapan pemrosesan agar meningkatkan keterbacaan, pemeliharaan sistem, serta stabilitas eksekusi. Proses dimulai dari penerimaan sinyal ECG mentah dari sensor Polar H10 melalui koneksi *BLE*. Data yang diterima disimpan sementara dalam mekanisme *buffer streaming* untuk mencegah kehilangan data ketika proses inferensi berlangsung. Skema *stream processing* digunakan karena sistem harus memproses data secara berkelanjutan tanpa menunggu keseluruhan sinyal terkumpul. Pendekatan ini umum digunakan dalam sistem analitik *real-time* berbasis *edge computing* (Arifin, 2025).

Tahap berikutnya adalah *preprocessing* sinyal ECG yang meliputi proses *noise filtering*, stabilisasi baseline, dan normalisasi amplitudo. Penyaringan sinyal dilakukan untuk mengurangi gangguan seperti *baseline wander* dan *high-frequency noise* yang dapat memengaruhi akurasi segmentasi. Normalisasi diterapkan agar data sesuai dengan format masukan model yang telah dilatih sebelumnya. Proses ini dilakukan secara langsung pada perangkat Android untuk memastikan keseluruhan pipeline tetap berada dalam skema *on-device inference*. Praktik pemrosesan sinyal sebelum inferensi model telah terbukti meningkatkan stabilitas sistem klasifikasi ECG berbasis *deep learning* (Mi`roj et al., 2026).

Deteksi *R-peak* dilakukan sebagai dasar segmentasi siklus detak jantung. Titik *R-peak* merupakan referensi utama dalam analisis ritme jantung karena merepresentasikan aktivitas depolarisasi ventrikel yang paling dominan dalam sinyal ECG. Setelah *R-peak* teridentifikasi, sistem mengekstraksi sejumlah sampel sebelum dan sesudah titik tersebut untuk membentuk satu segmen detak jantung. Segmentasi berbasis *beat-to-beat* ini penting karena model *LSTM* yang digunakan dilatih menggunakan potongan sinyal per siklus detak, bukan sinyal kontinu panjang. Pendekatan segmentasi berbasis detak telah banyak digunakan dalam sistem klasifikasi aritmia modern berbasis *deep learning*.

Model *LSTM* yang digunakan dalam penelitian ini merupakan model terlatih yang kemudian dikonversi ke format TensorFlow Lite agar kompatibel dengan lingkungan Android. TensorFlow Lite dirancang untuk mendukung inferensi model *deep learning* pada perangkat dengan keterbatasan memori dan daya komputasi

melalui optimasi ukuran model dan efisiensi eksekusi. Proses inferensi dilakukan setiap kali satu segmen detak jantung siap diproses, tanpa memerlukan koneksi internet atau server eksternal. Dengan demikian, sistem sepenuhnya berjalan dalam skema *on-device inference*, yang diketahui mampu mengurangi latensi jaringan sekaligus meningkatkan privasi data pengguna (Li et al., 2024).

Setelah sistem berada dalam kondisi stabil, dilakukan pengujian fungsional menggunakan pendekatan *black-box testing*. Pengujian difokuskan pada kesesuaian keluaran sistem terhadap masukan tanpa memeriksa struktur internal kode program. Setiap modul, mulai dari koneksi sensor, *streaming data*, *preprocessing*, deteksi *R-peak*, segmentasi, hingga inferensi model, diuji secara berulang untuk memastikan tidak terjadi kegagalan proses sebelum masuk ke tahap evaluasi performa komputasi.

Eksperimen kinerja komputasi dilakukan dalam satu sesi *streaming* ECG berkelanjutan untuk merepresentasikan skenario penggunaan nyata. Parameter yang diukur meliputi waktu inferensi per segmen (milidetik), penggunaan CPU (persentase), penggunaan memori RAM (megabyte), serta *throughput* dalam satuan inferensi per detik. Pengukuran latensi dilakukan dengan mencatat selisih waktu sebelum dan sesudah eksekusi interpreter TensorFlow Lite. Penggunaan CPU dan memori dipantau menggunakan alat profil bawaan Android. Pendekatan pengukuran langsung pada perangkat nyata dianggap lebih representatif dibandingkan pengujian berbasis emulator karena mampu menggambarkan dinamika sistem operasi dan beban proses latar belakang yang sesungguhnya (Tolle et al., 2017).

Melalui rangkaian tahapan tersebut, metodologi penelitian ini dirancang untuk memastikan bahwa sistem tidak hanya berfungsi secara teknis, tetapi juga dapat dievaluasi secara kuantitatif dari sisi efisiensi komputasi dalam konteks implementasi real-time pada perangkat mobile.

3. Hasil dan Diskusi

3.1 Hasil Implementasi Sistem

Sistem deteksi detak jantung berbasis LSTM berhasil diimplementasikan dalam bentuk aplikasi Android yang terintegrasi dengan sensor Polar H10. Implementasi dilakukan dengan pendekatan modular yang terdiri atas beberapa komponen utama, yaitu modul akuisisi sinyal ECG, modul *preprocessing* sinyal (noise filtering dan normalisasi), modul deteksi R-peak, modul segmentasi beat, serta modul inferensi menggunakan model LSTM yang telah dikonversi ke format TensorFlow Lite.

Akuisisi data dilakukan melalui koneksi *Bluetooth Low Energy (BLE)* antara perangkat Android dan sensor Polar H10. Data ECG diterima secara kontinu dalam skema *streaming*, kemudian diproses dalam buffer untuk memastikan tidak terjadi kehilangan data saat proses inferensi berlangsung. Mekanisme ini memungkinkan sistem berjalan secara *real-time* dengan memproses setiap segmen detak jantung segera setelah terdeteksi.

Tahap *preprocessing* meliputi proses penyaringan noise untuk mengurangi gangguan sinyal serta normalisasi fitur agar sesuai dengan format input model LSTM. Deteksi R-peak dilakukan sebagai dasar segmentasi siklus detak jantung, sehingga setiap segmen yang masuk ke model inferensi merepresentasikan satu siklus detak.

Antarmuka aplikasi dirancang dalam dua halaman utama. Halaman pertama berfungsi untuk koneksi sensor dan inisialisasi sistem, sedangkan halaman kedua digunakan untuk pemantauan sinyal ECG dan parameter kinerja sistem.



Gambar 1. Implementasi Antarmuka Utama

Halaman pemantauan menampilkan sinyal ECG dalam bentuk grafik dinamis yang diperbarui secara *real-time*. Selain itu, ditampilkan hasil klasifikasi detak jantung serta parameter kinerja seperti waktu inferensi per segmen, penggunaan CPU, penggunaan RAM, dan durasi pengujian. Informasi ini diperbarui secara berkala selama proses berlangsung.



Gambar 2. Implementasi Antarmuka Streaming ECG

Seluruh proses inferensi dijalankan secara *on-device*, tanpa memerlukan koneksi internet. Hal ini menunjukkan bahwa sistem mampu beroperasi secara mandiri dalam lingkungan perangkat mobile.

3.2 Hasil Pengujian Fungsional

Pengujian fungsional dilakukan untuk memastikan bahwa setiap komponen sistem berjalan sesuai dengan rancangan sebelum dilakukan evaluasi kinerja komputasi. Metode yang digunakan adalah *black-box testing*, dengan fokus pada kesesuaian keluaran sistem terhadap masukan yang diberikan.

Tabel 1. Hasil Pengujian Fungsional

Kode	Fitur yang Diuji	Hasil Pengujian
F-01	Noise Filtering Sinyal	Sistem mampu melakukan proses <i>filtering</i> pada sinyal ECG yang diterima dari sensor secara berkelanjutan sebelum tahap analisis lanjutan.
F-02	Deteksi R-peak	Sistem berhasil mendeteksi puncak R (<i>R-peak</i>) pada sinyal ECG sebagai dasar segmentasi detak jantung.
F-03	Segmentasi Beat	Sistem mampu mengekstraksi segmen detak jantung berdasarkan hasil deteksi R-peak untuk setiap siklus detak.
F-04	Normalisasi Fitur	Sistem berhasil melakukan normalisasi data sinyal ECG sehingga sesuai dengan format masukan model inferensi.
F-05	Inferensi Model TFLite	Sistem dapat menjalankan model TensorFlow Lite untuk melakukan inferensi terhadap setiap segmen detak jantung secara real-time.
F-06	Koneksi Sensor	Aplikasi berhasil terhubung dengan sensor Polar H10.
F-07	Pencatatan Data	Sistem mampu mencatat parameter kinerja inferensi, termasuk waktu inferensi, penggunaan CPU, penggunaan memori, dan <i>throughput</i> , serta menyimpannya ke dalam berkas lokal.
F-08	Penghentian Streaming	Proses <i>streaming</i> berhasil dihentikan tanpa menyebabkan kesalahan sistem.
NF-01	Offline Support	Sistem tetap dapat menjalankan proses inferensi dan menampilkan hasil tanpa memerlukan koneksi internet.
NF-02	Reliability	Aplikasi dapat mempertahankan eksekusi proses <i>streaming</i> dan inferensi selama sesi pengujian tanpa mengalami terminasi atau <i>crash</i> .

Berdasarkan hasil pengujian, seluruh fitur utama sistem berfungsi sesuai harapan. Modul *noise filtering* mampu memproses sinyal ECG secara kontinu tanpa menyebabkan gangguan pada alur data. Modul deteksi R-peak berhasil mengidentifikasi puncak R sebagai dasar segmentasi detak jantung. Segmentasi beat berjalan konsisten untuk setiap siklus detak yang terdeteksi.

Modul normalisasi fitur menghasilkan data dengan format yang sesuai untuk input model LSTM. Proses inferensi menggunakan *TensorFlow Lite* berjalan dengan stabil pada setiap segmen detak yang masuk. Selain itu,

sistem mampu mencatat parameter kinerja seperti waktu inferensi, penggunaan CPU, penggunaan RAM, dan *throughput* ke dalam berkas lokal secara otomatis.

Sistem juga berhasil mempertahankan koneksi dengan sensor Polar H10 selama sesi pengujian berlangsung. Proses *streaming* dapat dihentikan secara normal tanpa menyebabkan kesalahan sistem. Pengujian nonfungsional menunjukkan bahwa aplikasi tetap berjalan tanpa koneksi internet dan tidak mengalami terminasi atau *crash* selama pengujian berlangsung.

Hasil ini menunjukkan bahwa sistem berada dalam kondisi stabil dan layak untuk dilakukan eksperimen kinerja komputasi.

3.3 Hasil Eksperimen Kinerja Komputasi

Eksperimen dilakukan untuk mengevaluasi karakteristik performa komputasi sistem inferensi saat dijalankan dalam kondisi *real-time* dan *on-device*. Pengujian dilakukan dengan satu sesi *streaming* ECG berkelanjutan, di mana setiap segmen detak jantung diproses melalui tahapan *preprocessing* hingga inferensi LSTM.

Parameter yang diamati meliputi waktu inferensi (ms), penggunaan RAM (MB), penggunaan CPU (%), dan *throughput* pemrosesan detak jantung.

Tabel 2. Hasil Eksperimen Kinerja Sistem

Parameter	Waktu Inferensi (ms)	RAM (MB)	CPU (%)	Throughput
Avg	34.79	13.04	17.05	1.65
Max	96.04	21.14	100	1.72
Min	8.27	7.13	0	1.00

Data menunjukkan bahwa sistem mampu memproses seluruh segmen detak jantung selama sesi pengujian tanpa kehilangan data. Waktu inferensi berada dalam rentang yang bervariasi, mencerminkan fluktuasi beban komputasi selama proses berlangsung. Penggunaan RAM menunjukkan variasi yang relatif stabil, sedangkan penggunaan CPU mengalami lonjakan pada kondisi tertentu.

Nilai *throughput* menunjukkan bahwa sistem mampu mempertahankan kapasitas pemrosesan detak jantung secara kontinu selama proses *streaming* berlangsung.

3.4 Diskusi

Hasil penelitian menunjukkan bahwa sistem inferensi berbasis LSTM yang dijalankan menggunakan TensorFlow Lite pada perangkat Android mampu memenuhi kebutuhan pemrosesan *real-time*. Rata-rata waktu inferensi sebesar 34,79 ms menunjukkan bahwa sistem memiliki respons yang cukup cepat untuk mengikuti aliran sinyal ECG secara kontinu. Nilai ini berada dalam rentang yang memungkinkan pemrosesan detak jantung secara praktis tanpa menimbulkan keterlambatan yang signifikan.

Meskipun terdapat nilai maksimum waktu inferensi yang lebih tinggi, sistem tetap mampu mempertahankan kontinuitas pemrosesan. Hal ini menunjukkan bahwa fluktuasi beban komputasi tidak berdampak pada kegagalan sistem. Variasi ini kemungkinan dipengaruhi oleh aktivitas sistem operasi Android atau proses internal lain yang berjalan bersamaan.

Dari sisi penggunaan memori, kestabilan konsumsi RAM menunjukkan bahwa sistem memiliki manajemen memori yang baik. Tidak ditemukan pola peningkatan penggunaan memori secara progresif selama pengujian, sehingga dapat diasumsikan bahwa tidak terjadi kebocoran memori. Stabilitas ini penting dalam konteks implementasi *on-device*, karena perangkat mobile memiliki kapasitas memori yang terbatas dibandingkan perangkat komputasi kelas tinggi.

Penggunaan CPU rata-rata sebesar 17,05% menunjukkan bahwa sistem tidak memberikan beban berlebih pada prosesor dalam kondisi normal. Walaupun terdapat lonjakan penggunaan CPU hingga 100% pada kondisi tertentu, tidak ditemukan indikasi gangguan terhadap kestabilan aplikasi. Hal ini menunjukkan adanya *trade-off* antara efisiensi komputasi dan respons cepat pada momen tertentu saat pemrosesan berlangsung lebih intensif.

Nilai *throughput* rata-rata menunjukkan bahwa sistem mampu memproses detak jantung secara berkelanjutan selama sesi *streaming*. Kemampuan ini menegaskan bahwa pendekatan inferensi *on-device* dapat

menjadi alternatif yang layak dibandingkan pendekatan berbasis *edge server*, terutama dalam hal independensi jaringan dan latensi yang lebih rendah.

Jika dikaitkan dengan pertanyaan penelitian, hasil ini menunjukkan bahwa: (1) Sistem mampu menjalankan inferensi detak jantung secara *real-time* pada perangkat Android; (2) Penggunaan CPU dan RAM berada dalam batas yang masih dapat diterima untuk perangkat mobile; (3) Implementasi inferensi berbasis LSTM secara *on-device* layak diterapkan dalam sistem pemantauan jantung berbasis mobile.

Namun demikian, penelitian ini memiliki keterbatasan. Pengujian dilakukan pada satu perangkat dengan spesifikasi tertentu, sehingga variasi performa pada perangkat dengan kelas yang berbeda belum dievaluasi. Selain itu, penelitian ini lebih berfokus pada aspek kinerja komputasi dan belum membandingkan secara kuantitatif tingkat akurasi model dalam berbagai kondisi penggunaan yang lebih kompleks.

Secara keseluruhan, hasil dan diskusi menunjukkan bahwa sistem deteksi detak jantung berbasis LSTM menggunakan *TensorFlow Lite* dapat berjalan secara stabil, efisien, dan mendukung pemrosesan *real-time* pada perangkat Android. Temuan ini memperkuat potensi penerapan kecerdasan buatan dalam sistem pemantauan kesehatan berbasis mobile yang mandiri dan berkelanjutan.

4. Kesimpulan

Penelitian ini berhasil mengimplementasikan sistem deteksi detak jantung berbasis *Long Short-Term Memory (LSTM)* yang dijalankan secara langsung pada perangkat Android dengan memanfaatkan sensor Polar H10 sebagai sumber data elektrokardiogram (ECG). Sistem dikembangkan dalam bentuk aplikasi *mobile* yang mampu melakukan akuisisi sinyal, pemrosesan awal, segmentasi detak, serta inferensi menggunakan *TensorFlow Lite* secara berkelanjutan dalam skema *streaming*. Berdasarkan hasil eksperimen, sistem mampu melakukan inferensi dengan waktu rata-rata 34,79 ms per segmen detak jantung, penggunaan memori rata-rata 13,04 MB, dan penggunaan CPU rata-rata 17,05% selama sesi pengujian. Nilai tersebut menunjukkan bahwa proses inferensi dapat berjalan secara *real-time* dengan penggunaan sumber daya komputasi yang masih dalam batas wajar untuk perangkat mobile. Hasil ini menjawab tujuan penelitian bahwa sistem inferensi detak jantung berbasis LSTM dapat diimplementasikan dan dijalankan secara *on-device* dengan performa komputasi yang stabil. Sistem mampu mempertahankan kontinuitas pemrosesan data tanpa ketergantungan pada koneksi internet, sehingga memiliki potensi untuk diterapkan dalam sistem pemantauan jantung berbasis mobile yang mandiri dan portabel. Implementasi ini membuka peluang penggunaan teknologi kecerdasan buatan dalam pemantauan kesehatan personal, khususnya untuk deteksi dini gangguan irama jantung dalam aktivitas sehari-hari. Meskipun demikian, pengujian dilakukan pada konfigurasi perangkat tertentu sehingga variasi performa pada perangkat dengan spesifikasi berbeda masih perlu dievaluasi lebih lanjut. Penelitian selanjutnya dapat menguji sistem pada berbagai kelas perangkat Android serta membandingkan beberapa variasi arsitektur model, baik dengan mengubah konfigurasi LSTM maupun membandingkannya dengan model lain yang sesuai untuk analisis sinyal ECG. Pendekatan tersebut diharapkan dapat memberikan pemahaman yang lebih komprehensif mengenai hubungan antara kompleksitas model, efisiensi komputasi, dan kinerja inferensi pada perangkat *mobile*.

Referensi

1. Anbalagan, T., Nath, M. K., Vijayalakshmi, D., & Anbalagan, A. (2023). Analysis of various ECG signal usage techniques in healthcare: Past, present, and future. *Biomedical Engineering Advances*, 6, 100089.
2. Arifin, S. A. S. (2025). Perancangan sistem monitoring kualitas udara real-time berbasis wireless sensor network dan edge computing untuk optimasi latensi data. *Karapan Network Journal: Journal Computer Technology and Mobile Ad Hoc Network*, 1(01).
3. Chong, B., Jayabaskaran, J., Jauhari, S. M., Chan, S. P., Goh, R., Kueh, M. T. W., Li, H., Chin, Y. H., Kong, G., Anand, V. V., Wang, J. W., Muthiah, M., Jain, V., Mehta, A., Lim, S. L., Foo, R., Figtree, G. A., Nicholls, S. J., Mamas, A. M., Januzzi, J. L., Chew, N. W. S., Richards, A. M., & Chan, M. Y. (2025). Global burden of cardiovascular disease: Projections from 2025 to 2050. *European Journal of Preventive Cardiology*, 32(11), 1001–1015.
4. Gufron, F. M., & Ardiwinata, F. (2025). Perancangan arsitektur sistem informasi kesehatan terintegrasi berbasis Internet of Things untuk pemantauan kesehatan harian (Doctoral dissertation, Universitas Islam Indonesia).
5. Li, Y., Zhang, Q., & Chen, M. (2024). On-device deep learning inference: Performance, latency, and privacy trade-offs in edge AI systems. *IEEE Access*, 12, 24567–24580. <https://doi.org/10.1109/ACCESS.2024.3367890>
6. Mi'roj, M. F., Pramukantoro, E. S., & Kurnianingtyas, D. (2026). Implementasi sistem inferensi detak jantung berbasis long short-term memory (LSTM) pada perangkat mobile. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 10(3).
7. Pramukantoro, E. S., & Gofuku, A. (2022). Heartbeat classifier for continuous prediction using wearable devices. *Sensors*, 22(14), 5080.
8. Pramukantoro, E. S., Amron, K., Kamila, P. A., & Wardhani, V. (2025a). Real-time heartbeat classification on distributed edge devices: A study of performance and resource utilization. *Sensors*, 25(19), 6116.

9. Pramukantoro, E. S., Amron, K., Wardhani, V., & Kamila, P. A. (2025b). Study on inference-based heartbeat classification using CNN and LSTM on edge devices. *International Journal of Computing and Digital Systems*, 18(1), 1–12.
10. Rahman, M., & Morshed, B. I. (2024). Smart wearable device for real-time heart disease detection through beat-wise ECG analysis using edge-based AI classification. In *Proceedings of the IEEE International Conference on Body Sensor Networks (BSN)* (ISBN 979-8-3315-3014-3).
11. Ribeiro, H. D. M., Arnold, A., Howard, J. P., Shun-Shin, M. J., Zhang, Y., Francis, D. P., Lim, P. B., Whinnett, Z., & Zolgharni, M. (2022). Real-time ECG-based arrhythmia monitoring using quantized deep neural networks: A feasibility study. *Biomedical Signal Processing and Control*, 74, 103495.
12. Spicher, N., Klingenberg, A. S., Purrucker, V., & Deserno, T. M. (2021). Edge processing in 5G cellular networks for real-time analysis of electrocardiograms recorded with textile sensors. In *Proceedings of the IEEE Engineering in Medicine and Biology Conference*.
13. Tan, H., Lai, J., Liu, Y., Song, Y., Wang, J., Chen, M., Yan, Y., Zhong, L., Feng, Q., & Yang, W. (2022). Neural architecture search for real-time quality assessment of wearable multi-lead ECG on mobile devices. *Biomedical Signal Processing and Control*, 74, 103495.
14. Tolle, H., Pinandito, A., Kharisma, A. P., & Dewi, R. K. (2017). *Pengembangan aplikasi perangkat bergerak*. Universitas Brawijaya Press.
15. Zahrah, N., & Suranto, B. (2025). Pengembangan antarmuka aplikasi bergerak dengan perangkat prototyping berbasis AI. *Idealis: Indonesia Journal Information System*, 8(2), 210–219.
16. Zen, A. F. A., Pramukantoro, E. S., Amron, K., Wardhani, V., & Kamila, P. A. (2023). Prediksi detak jantung menggunakan LSTM yang dijalankan di Raspberry Pi untuk memantau kesehatan secara portabel. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 10(7), 1555–1562.