

# RANGKAIAN NEURAL KONVOLUTIONAL TEMPORAL UNTUK KLASIFIKASI ARITMIA ISYARAT ELEKTROKARDIOGRAM

## SIRI MASA

Ng Xin Yen & Salwani Abdullah

*Fakulti Teknologi & Sains Maklumat, Universiti Kebangsaan Malaysia, 43600 UKM Bangi,  
Selangor Darul Ehsan, Malaysia*

### ABSTRAK

Aritmia jantung adalah keadaan yang melibatkan degupan jantung tidak normal, sama ada ia berdegup terlalu perlahan atau laju. Penyakit ini membawa risiko kesihatan yang kritikal jika tidak dirawat, yang boleh membawa kepada serangan jantung dan kegagalan jantung. Elektrokardiogram (EKG) ialah alat asas untuk memantau degupan jantung. Oleh yang demikian, ia menjadi sangat penting untuk mengenalpasti dan mengklasifikasikan ketidakraturan dalam degupan jantung. Memandangkan kesukaran dalam menganalisis isyarat EKG secara manual, objektif projek ini adalah untuk memperkenalkan penggunaan Rangkaian Neural Konvolusi Temporal (TempCNN) untuk mengkategorikan lima aritmia berbeza dengan tepat berdasarkan Isyarat EKG Siri Masa, iaitu sama ada 'Rentak Normal', 'Rentak Tidak Diketahui', 'Rentak Ektopik Ventrikel', 'Rentak Ektopik Supraventricular' atau 'Denyut Fusi'. Dataset yang dipilih untuk projek ini diperoleh daripada laman web Kaggle yang mengandungi 48 rekod isyarat EKG siri masa yang berlabel. Projek ini akan menilai keberkesanan TempCNNs dalam pengelasan aritmia dengan membandingkannya dengan Rangkaian Neural Konvolusi (CNN), Memori Pendek Jangka Panjang (LSTM) dan Rangkaian Neural Berulang (RNN) berdasarkan metrik hasil seperti kejituan, kepersisanan, dapatan semula, dan skor F1. Bagi projek ini, hasil terakhir adalah model pengelasan berdasarkan TempCNN. Antara model yang dibandingkan, TempCNN muncul sebagai yang paling tepat, diikuti oleh CNN, manakala RNN dan LSTM mempamerkan prestasi yang sederhana.

Kata kunci: Aritmia, TempCNN, elektrokardiogram

### Pengenalan

Aritmia ialah masalah yang berkaitan dengan kadar atau irama degupan jantung anda. Ini bermaksud jantung anda berdegup terlalu cepat, terlalu perlahan, atau dengan denyutan yang tidak teratur. Jika tidak ditangani, aritmia akan meningkatkan risiko kematian jantung tiba-tiba (Brouillette et al., 2019), dan juga risiko strok serta kegagalan jantung (Bordignon et al., 2012). Elektrokardiogram (EKG) merupakan sebuah alat diagnostik untuk mengukur dan merekodkan aktiviti elektrik jantung (Miquel et al., 2019). Isyarat ini boleh digunakan untuk mengenal pasti irama jantung yang tidak normal dan keadaan lain berkaitan jantung, memberikan sumbangan yang ketara dalam meramalkan penyakit jantung. Oleh itu, perubahan dalam bentuk gelombang EKG berfungsi sebagai petunjuk masalah kardiovaskular yang mungkin, seperti aritmia. Pendeteksian awal jenis-jenis penyakit jantung berlaku memerlukan pemantauan jangka panjang aktiviti elektrik jantung. Oleh yang demikian, ia menjadi sangat penting untuk mengenalpasti dan mengklasifikasikan ketidakaturan dalam degupan jantung. Namun demikian, penganalisan isyarat EKG secara manual telah menyebabkan kesukaran dalam pengesanan pelbagai jenis penyakit jantung.

Dengan kematangan teknologi Kecerdasan Buatan (AI), banyak kaedah pembelajaran mesin digunakan dalam penganalisan isyarat EKG. Deep learning merujuk kepada satu jenis teknik pembelajaran mesin (ML) yang menggunakan model neural network yang dalam dan kompleks. Model-model ini dilatih dengan menggunakan satu set data yang besar yang telah diberi label dan senibina neural network yang mengandungi banyak lapisan. Projek ini akan memfokuskan pada pembangunan dan pengoptimuman model pembelajaran dalam untuk pengklasifikasian aritmia. Kerja dalam projek ini akan melibatkan beberapa model pembelajaran dalam seperti Rangkaian Neural Konvolusi Temporal (TempCNN), Rangkaian Neural Konvolusi (CNN), Rangkaian Neural Berulang (RNN) dan Memori Jangka Pendek Panjang (LSTM). Mengenalpasti dan mengklasifikasikan ketidakaturan dalam degupan jantung adalah penting untuk mengesan aritmia sebelum parah.

Proses pembangunan untuk projek ini akan mengikut metodologi CRISP-DM (Cross-Industry Standard Process for Data Mining). Pendekatan yang diiktiraf secara meluas dan berstruktur ini akan membimbing peringkat penerokaan, penyediaan data, pembinaan model, penilaian dan penggunaan pengkaji. Dengan mematuhi rangka kerja yang ketat ini, pengkaji boleh memastikan kebolehulungan dan kebolehpercayaan hasil.


Terdapat beberapa kajian lepas yang telah dirujuk untuk mendapat gambaran tentang kajian dilakukan. Penyelidikan pertama bertajuk Kajian mengenai Aritmia melalui Klasifikasi Isyarat EKG menggunakan Rangkaian Neural Konvolusi dan diterbitkan pada 2021 (Wu et al. 2021). Keputusan prestasi pemodelan dinilai melalui kejitian. Ia boleh dilihat bahawa model CNN yang dihasilkan oleh penyelidikan ini mengatasi model-model lain, di mana kejitian untuk model CNN yang dicadangkan untuk mengklasifikasikan isyarat EKG aritmia siri masa ialah 97.41%, diikuti dengan model rangkaian Random Forest dengan kejitian sebanyak 95.72%, model CNN yang akan diperbandingkan dan model Rangkaian neural BP dengan kejitian sebanyak 94.07% dan 87.25%. Penyelidikan seterusnya bertajuk Klasifikasi Aritmia EKG Menggunakan Rangkaian Neural Berulang (Singh et al. 2018). Model pembelajaran mesin yang digunakan ialah Rangkaian Neural Berulang (RNN), Unit Berulang Bergetar (GRU), dan Jangka Pendek-Masa Panjang (LSTM). Perbandingan adalah berdasarkan metrik penilaian seperti kejitian, sensitiviti dan spesifisitas. Keputusan mendedahkan kedudukan prestasi pelbagai model, dengan LSTM mempamerkan kejitian yang lebih tinggi, sebanyak 88.1%, spesifisitas sebanyak 83.35% dan sensitiviti sebanyak 92.4%, mengatasi RNN, yang memperoleh kejitian sebanyak 85.4%, spesifisitas sebanyak 80.6% dan sensitiviti sebanyak 85.7% serta RNN GRU dengan kejitian sebanyak 82.5%, spesifisitas sebanyak 81.5% dan sensitiviti sebanyak 78.9%. Penyelidikan ketiga bertajuk Model Berasaskan CNN-LSTM Untuk Klasifikasi Arritmia EKG dan Serangan Jantung yang diterbitkan pada 2020 (Abdullah & Al-ani 2020). Model pembelajaran mesin yang digunakan ialah model CNN-LSTM telah mencapai 98.66% kejitian dengan pangkalan data MIT-BIH Arrhythmia dan kejitian 98.13% menggunakan pangkalan data ECG Diagnostik Physionet PTB manakala model CNN mencapai kejitian 94.7% dan 97.55%. Penyelidikan seterusnya yang akan dikaji adalah bertajuk Klasifikasi Jaringan Neural Konvolusional Hibrid Elektrokardiografi-Jangka Pendek Ingatan Panjang yang diterbitkan pada 2022 (Ramachandran et al. 2022). Model pembelajaran mesin yang telah dilaksanakan dalam penyelidikan ini ialah CNN-LSTM dan CNN. Prestasi akan dinilai dengan kejitian metrik, RMSE, MAE, Skor R2 dan masa jalan. CNN-LSTM mempunyai kejitian tertinggi (99.43%) dengan RMSE (0.18), Skor R2 (0.884) dan MAE(0.027), manakala CNN mempunyai kejitian (98.61%) dengan RMSE (0.08), Skor R2 (0.826) dan MAE(0.020). Dari segi masa latihan, CNN-LSTM mengambil masa 235.34s untuk menjalankan latihan yang lebih pantas berbanding CNN(255.62s).

Laporan teknikal mengikut organisasi berstruktur, merangkumi empat bahagian utama. Pertama, bahagian Pengenalan memberikan gambaran keseluruhan mengenai latar belakang

projek, objektif, skop, justifikasi, dan metodologi yang digunakan, serta menggariskan kepentingan klasifikasi isyarat EKG menggunakan algoritma. Bahagian Metodologi menerangkan proses pembangunan model yang digunakan, kaedah pengumpulan dan analisis data, serta pengukuran dan alat yang digunakan untuk menilai keputusan kajian. Dalam bahagian Keputusan dan Perbincangan, prestasi model pembelajaran mesin dinilai secara menyeluruh melalui penilaian metrik seperti Kejituan, Kepersisan, Dapatan Semula dan Skor F1. Akhir sekali, bahagian Kesimpulan meringkaskan penemuan utama, implikasinya terhadap industri, dan memberikan cadangan untuk kajian masa hadapan..

### METODOLOGI KAJIAN

Metodologi yang digunakan untuk kajian projek ini adalah Cross Industry Standard Process for Data Mining (CRISP-DM). CRISP-DM merupakan satu metodologi yang kukuh dan terbukti berkesan dengan menyediakan pendekatan berstruktur untuk pembangunan model algoritma pengklasifikasian (Larissa, 2022) . Ia terdiri daripada enam fasa iaitu Pemahaman Perniagaan (Business Understanding), Pengetahuan Data (Data Understanding), Penyediaan Data (Data Preparation), Pemodelan (Modelling), Penilaian (Evaluation) dan Penggunaan (Deployment) seperti yang ditunjukkan pada Rajah 1:



Rajah 1 Fasa CRISP-DM. Sumber: (Hotz 2022)

Fasa pemahaman terhadap perniagaan ialah langkah pertama CRISP-DM. Fasa ini membantu memastikan projek perlombongan data difokuskan untuk memenuhi keperluan dan objektif perniagaan atau organisasi. Matlamat kajian ini adalah untuk membangunkan model pembelajaran mesin untuk klasifikasi isyarat EKG aritmia siri masa. Pihak berkepentingan projek ini mungkin melibatkan pelabur, institusi kewangan, dan peniaga di bidang kesehatan. Untuk menentukan kriteria kejayaan bagi projek ini, pengkaji perlu mempertimbangkan beberapa faktor yang khusus untuk klasifikasi isyarat EKG. Sebagai contoh, klasifikasi mungkin dianggap berjaya jika ia tepat dalam julat tertentu atau jika ia menilai sejauh mana model mematuhi standar klinis dan pedoman medis yang berlaku. Data yang berkaitan untuk projek ini termasuk data isyarat EKG aritmia siri masa.

Fasa pemahaman data ialah langkah kedua CRISP-DM, dan ia tertumpu pada penerokaan dan menganalisis data yang dikumpul untuk mendapatkan pemahaman yang lebih baik tentang kandungan, struktur dan kualitinya. Sumber data yang digunakan untuk penyelidikan ini adalah data isyarat EKG aritmia yang telah dipraproses secara minor diperoleh daripada laman web kaggle.com. Fail set data yang dikumpulkan datang dalam 1 jenis, isyarat dalam fail .csv. Data akan diproses untuk mengelakkan data yang tidak diformat dengan betul dan nilai kosong untuk menghasilkan data berkualiti tinggi. Atribut daripada set data mentah akan ditunjukkan dalam Jadual 1:

Jadual 1 Set Data Atribut

<b>Atribut</b>	<b>Format</b>	<b>Penerangan</b>
<i>Time</i>	Masa	Mewakili masa yang berlalu bagi anotasi dari permulaan rekod. Ia dinyatakan dalam minit, saat, dan milisaat.
<i>Sample #</i>	Angka/Nombor	Bilangan selang sample dari permulaan rekod.
<i>Type</i>	Teks	Label denyutan jantung.
<i>Sub</i>	Angka/Nombor	Laluan pengesanan (0 atau 1) semasa kompleks QRS dikesan.
<i>Chan</i>	Angka/Nombor	Nombor isyarat di mana kompleks QRS dikesan.
<i>Num</i>	Angka/Nombor	Amplitud puncak penapis padan penderia semasa kompleks QRS.

<i>Aux</i>	Teks	Huruf mengenai perubahan dalam ritma jantung yang dominan, biasanya kosong.
<i>MLII</i>	Angka/Nombor	Isyarat EKG yang diperoleh menggunakan elektroda yang terletak di modified position atau multiple positions dan melibatkan left arm.
<i>V5</i>	Angka/Nombor	Isyarat EKG yang diperoleh dari elektroda ke-5 yang ditempatkan di posisi dada kiri anterior.

Terdapat 15 label yang digunakan dalam dataset MIT-BIH Arrhythmia Database. Untuk mempermudah klasifikasi anotasi dalam dataset MIT-BIH Arrhythmia Database, anotasi denyutan jantung telah dikategorikan mengikut piawaian AAMI (Association for the Advancement of Medical Instrumentation), iaitu lima kategori utama iaitu N (Normal Beat), VEB (Ventricular Ectopic Beat), SVEB (Supraventricular Ectopic Beat), F (Fusion Beat), dan Q (Unknown Beat). Setiap kategori denyutan jantung dikaitkan dengan anotasi tertentu yang menggambarkan jenis denyutan tersebut. Berikut adalah penjelasan bagi setiap kategori denyutan jantung dan anotasi yang berkaitan:

Jadual 2 Anotasi Set Data Mengikut Piawaian AAMI

Kelas Denyutan Jantung	Anotasi Denyutan Jantung	Penerangan
<i>N (Normal)</i>	NOR (Normal)	Denyutan normal serta beberapa jenis denyutan jantung yang normal.
	LBBB (Left bundle branch block beat)	
	RBBB (Right bundle branch block beat)	
	AE (Atrial escape beat)	
	NE (Nodal (junctional) escape beat)	
<i>VEB (Ventricular Ectopic Beat)</i>	PVC (Premature ventricular contraction)	Denyutan ektopik yang berasal dari ventrikel.
	VE (Ventricular escape beat)	
<i>SVEB (Supraventricular Ectopic Beat)</i>	AP (Atrial premature beat)	Merujuk kepada denyutan ektopik yang berasal dari atrium atau persimpangan atrioventrikular.
	aAP (Aberrated atrial premature beat)	
	NP (Nodal (junctional) premature beat)	

	SP (Supraventricular premature beat)	
<i>F (Fusion Beat)</i>	fVN (Fusion of ventricular and normal beats)	Denyutan yang merupakan gabungan antara denyutan ventrikel dan denyutan normal.
<i>Q (Unknown Beat)</i>	U (Unclassifiable beat) P (Paced beat) f (Fusion of paced and normal beat)	Denyutan yang tidak sesuai dengan mana-mana kategori di atas atau denyutan yang dipacu.

Fasa penyediaan data ialah fasa yang melibatkan pemrosesan data untuk menghasilkan set data bersih yang sesuai untuk penyepaduan ke dalam pembelajaran mesin model. Langkah pemrosesan data seperti penerokaan data, pembersihan, korelasi atribut, penskalaan data, dan teknik tinkap gelongsor akan diterangkan dalam bahagian ini (Abdallah et al. 2017). Set data yang bersih bebas daripada nilai yang hilang dan ralat yang berlaku pada set data. Ringkasnya, Penyediaan Data ialah langkah penting dalam proses pembelajaran mesin, kerana ia membantu memastikan data bersih dan konsisten, yang diperlukan untuk membina model yang tepat. Antara proses penyediaan data yang dijalankan termasuk penerokaan data, penyingkiran gangguan bunyi dan penyelarasan semula data.

Dalam fasa pemodelan, model pembelajaran mesin dibangunkan dan diuji untuk mengenal pasti corak dan perhubungan dalam data. Ini biasanya dilakukan menggunakan subset data yang dikenali sebagai set latihan. Model tersebut kemudiannya diuji pada subset berasingan data yang dikenali sebagai set ujian untuk menilai keberkesannya. Model yang akan digunakan dalam penyelidikan ini ialah Rangkaian Neural Konvolusi Temporal (TempCNN), Rangkaian Neural Konvolusi (CNN), Rangkaian Neural Berulang (RNN) dan Memori Jangka Pendek Panjang (LSTM). Rangkaian Neural Konvolusi Temporal (TempCNN) adalah model jaringan saraf tiruan yang digunakan untuk memproses data sekuensial dalam domain waktu. Rangkaian Neural Konvolusi (CNN) secara umumnya dibahagikan kepada 2 bahagian, iaitu Feature Extraction dan Classification. Feature extraction terdiri daripada Lapisan Konvolusional (Convolution Layer) dan Lapisan Penurunan (Pooling Layer) manakala Classification terdiri daripada Fully-Connected Layer. Contoh penggunaan CNN dalam penggunaan klasifikasi EKG didapati dalam kajian (Chourasia et al. 2020). Jaringan neural berulang (RNN) adalah model pembelajaran mendalam (deep learning) yang dilatih untuk memproses dan mengubah data input berurutan menjadi data output berurutan tertentu. Contoh penggunaan RNN dalam penggunaan klasifikasi EKG didapati dalam kajian

(Shraddha et al. 2018). Long Short-Term Memory (LSTM) merupakan jenis rangkaian neural berulang (RNN) yang telah mendapat populariti dalam pelbagai bidang, termasuk bidang kesihatan dan analisis EKG. Komponen utama LSTM ialah sel memori, get lupa dan get input. Sel memori bertanggungjawab untuk menyimpan maklumat untuk jangka masa yang lama, dan get lupa dan input menentukan maklumat yang patut atau tidak boleh disimpan dalam sel. Contoh penggunaan LSTM dalam penggunaan klasifikasi EKG didapati dalam kajian (Gao et al. 2019).

Fasa penilaian ialah di mana prestasi model terlatih diukur pada set data ujian. Set data ujian ialah set data berasingan daripada set data latihan dan pengesahan yang tidak digunakan semasa latihan model. Tujuan fasa penilaian adalah untuk menilai keupayaan generalisasi model, iaitu keupayaannya untuk membuat ramalan yang tepat ke atas data baharu yang tidak kelihatan. Metrik penilaian yang akan digunakan untuk mengukur prestasi model klasifikasi isyarat EKG siri masa ialah kepersisan, dapatan semula, skor F1 dan kejytuan. Nilai kejytuan, kepersisan dan dapatan semula boleh diperolehi daripada nilai True Negative (TN), False Positive (FP), False Negative (FN), dan True Positive (TP).

Fasa penggunaan ialah langkah terakhir dalam proses CRISP-DM. Fasa penggunaan ialah langkah terakhir dalam proses CRISP-DM. Dalam kajian ini, model klasifikasi isyarat EKG aritmia jantung siri masa yang merupakan hasil kajian ini tidak digunakan dalam Fasa Penggunaan kerana kajian ini merupakan kajian awal untuk menilai kegunaan TempCNN untuk mengklasifikasi isyarat EKG secara lebih tepat. Penambahan model ini diharap dapat digunakan dalam bidang perubatan.

## **KEPUTUSAN DAN PERBINCANGAN**

Bahagian ini membentangkan hasil penilaian metrik untuk model klasifikasi, membandingkan keputusan penilaian metrik model TempCNN, CNN, RNN dan LSTM, dipaparkan dalam bentuk jadual dan rajah.



### Penilaian Rangkaian Neural Konvolusi Temporal (TempCNN)

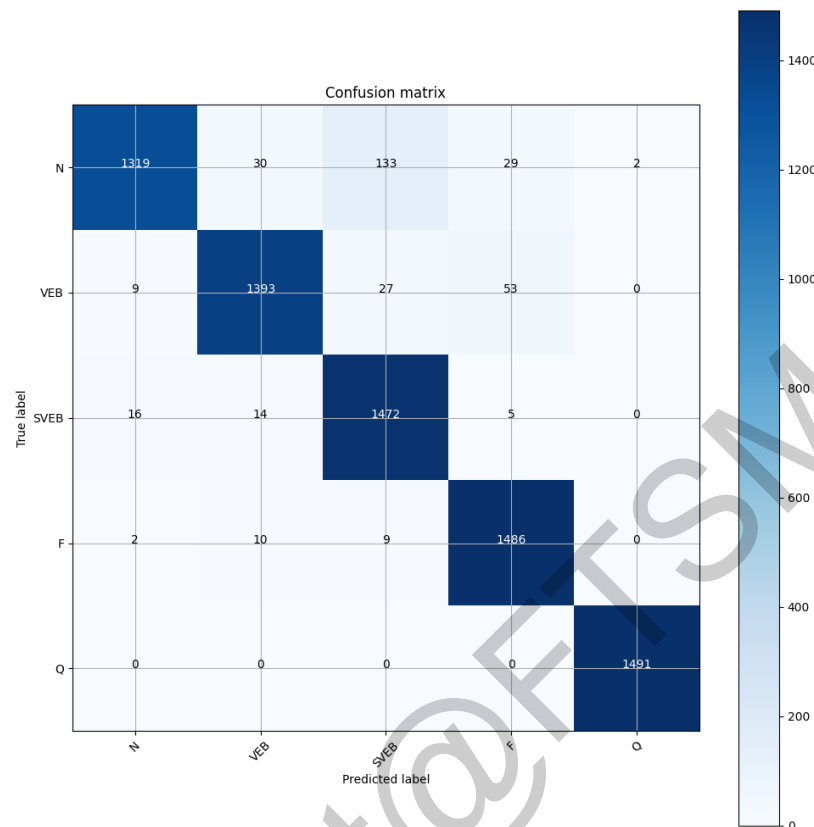
Jadual 3 menunjukkan keputusan penilaian metrik bagi model TempCNN, termasuk kepersisan, dapatan semula, skor F1 dan juga sokongan keputusan klasifikasi model. Rajah 2 mempersempahkan matriks konfusi model TempCNN. Jadual 4 menunjukkan prestasi model dalam kejitian dan kehilangan latihan dan ujian, manakala Rajah 3 menunjukkan graf kejitian latihan dan ujian Model TempCNN dan Rajah 4 menunjukkan graf kehilangan latihan dan ujian Model TempCNN.

Jadual 3 Keputusan penilaian metrik model TempCNN

Label	Penilaian Metriks			
	Kepersisan	Dapatan Semula	Skor F1	Sokongan
N	0.98	0.87	0.92	1513
VEB	0.96	0.94	0.95	1482
SVEB	0.90	0.98	0.94	1507
F	0.94	0.99	0.96	1507
Q	1.00	1.00	1.00	1491

Kejitian: 0.95

Berdasarkan metrik-metrik yang dilampirkan dalam Jadual 3, model ini memiliki prestasi yang baik (kejitian 95%) dalam mengklasifikasikan label N dan Skor F1 yang seimbang (92%) menunjukkan bahawa model dapat secara baik membedakan label N dari kelas lainnya, dengan jumlah sampel yang cukup (1513). Selain itu, model juga menunjukkan prestasi yang baik untuk label VEB, dengan kepersisan(96%), dan skor F1(95%). Ini menunjukkan bahawa model sangat efektif dalam mengidentifikasi label VEB, dengan jumlah sampel yang cukup (1482). Bukan itu sahaja, model ini turut menunjukkan kinerja yang sangat baik untuk label SVEB, F dan Q, dengan kepersisan(90%;94%;100%), dapatan semula(98%;99%;100%), dan skor F1(94%;96%;100%) masing-masing. Secara keseluruhannya, model TempCNN telah mencapai keputusan yang sangat baik dalam mengklasifikasikan semua label, terutamanya label Q.



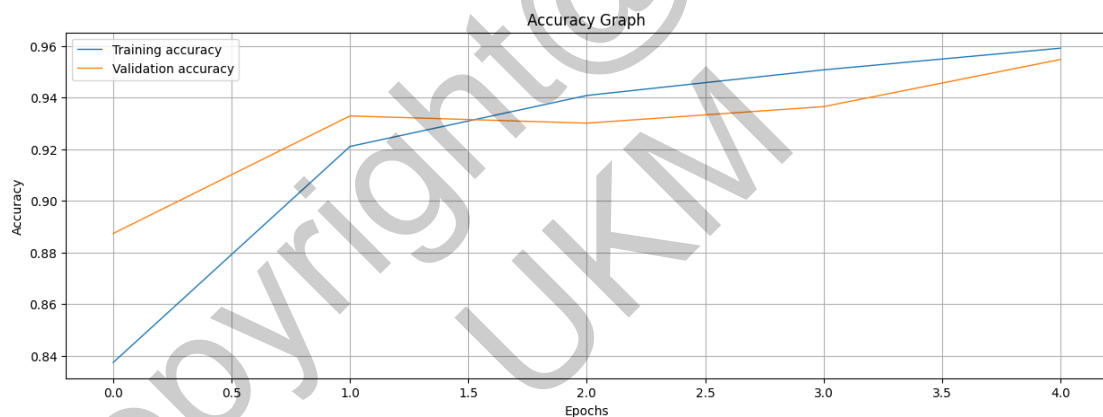
Rajah 2 Matriks Konfusi model TempCNN

Berdasarkan matriks konfusi di atas, model TempCNN berjaya mengenalpasti 1319 sampel sebagai label N dengan betul. Terdapat beberapa kes kekeliruan dengan 30 sampel salah diklasifikasikan sebagai label VEB, 133 sebagai label SVEB, 29 sebagai label F dan 2 sebagai label Q. Jumlah kesalahan adalah kecil berbanding jumlah benar positif. Bukan itu sahaja, model juga sangat cekap dalam mengenalpasti label F dengan 1478 benar positif dan 21 negatif palsu untuk label ini. Model juga menunjukkan prestasi yang baik dalam mengenalpasti label VEB dengan 1393 sampel diklasifikasikan dengan betul. Terdapat sedikit kes kekeliruan dengan 9 disalhsampelkan sebagai label N, 27 disalhsampelkan sebagai label SVEB dan 53 disalhsampelkan sebagai label F. Seterusnya, label SVEB dikenalpasti dengan baik oleh model dengan 1472 benar positif dan 16 label disalhsampelkan kepada label N dan 14 salah disampelkan kepada label VEB serta 5 disalhsampelkan sebagai label F. Akhir sekali, model menunjukkan prestasi yang cemerlang dalam mengenalpasti 1491 label Q dengan betul, menunjukkan prestasi yang kukuh dalam mengklasifikasikan label ini.

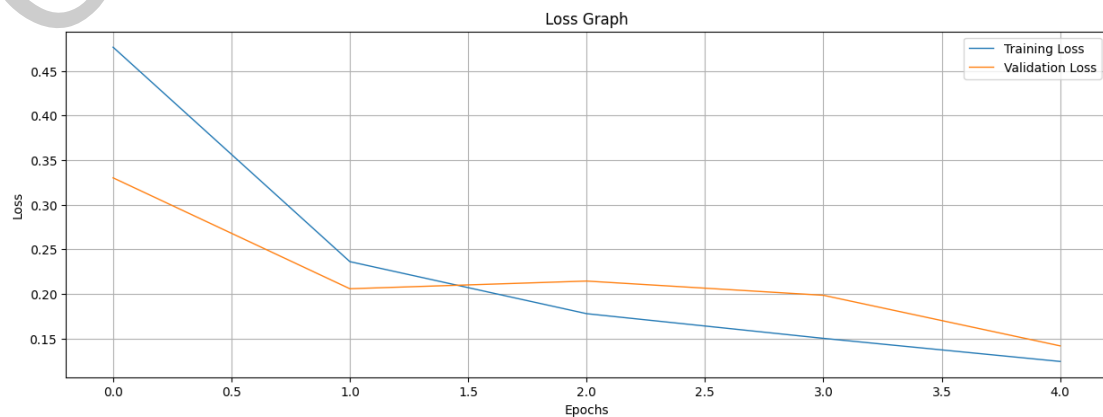
Secara keseluruhan, model TempCNN menunjukkan prestasi yang sangat baik secara keseluruhan dalam mengklasifikasikan kelima-lima label. Label Q dan F menunjukkan prestasi yang cemerlang dengan kekeliruan yang sangat sedikit. Prestasi model untuk label N, VEB, dan SVEB juga adalah baik, walaupun terdapat sedikit kekeliruan antara kelas-kelas ini. Matriks kekeliruan menunjukkan bahawa model ini boleh dipercayai untuk klasifikasi EKG dengan kejituan yang tinggi.

Jadual 5 Kehilangan dan Kejituan Latihan dan Ujian Model TempCNN

Epoch	Kehilangan Latihan	Kejituan Latihan	Kehilangan Ujian	Kejituan Ujian
1	0.4767	0.8373	0.3301	0.8873
2	0.2361	0.9211	0.2057	0.9329
3	0.1777	0.9409	0.2143	0.9301
4	0.1500	0.9508	0.1983	0.9365
5	0.1241	0.9592	0.1416	0.9545



Rajah 3 Graf Kejituan Latihan dan Ujian Model TempCNN



Rajah Error! No text of specified style in document. Graf Kehilangan Latihan dan Ujian Model TempCNN

Berdasarkan Jadual 5, Model TempCNN telah dilatih dan diuji pada set data tertentu melalui 5 epoch. Pada epoch pertama model TempCNN menunjukkan kejitian yang tinggi sejak awal dengan kehilangan yang agak rendah. Ini menunjukkan bahawa model ini berupaya untuk cepat belajar pola dari data latihan dan memberikan prestasi yang baik pada data validasi. Pada epoch 2, terdapat peningkatan yang ketara dalam kejitian latihan dan validasi, serta penurunan yang besar dalam kehilangan. Model semakin baik dalam mempelajari pola dari data dan menerapkan pembelajaran tersebut pada data validasi. Pada epoch 3, walaupun terdapat sedikit peningkatan dalam kejitian latihan, kehilangan validasi sedikit meningkat. Ini mungkin menunjukkan bahawa model telah mencapai titik di mana peningkatan kejitian tambahan memerlukan penyesuaian yang lebih spesifik. Seterusnya pada epoch 4, Model terus menunjukkan peningkatan dalam kejitian latihan dan penurunan dalam kehilangan validasi, menunjukkan pembelajaran yang lebih baik dan penyesuaian yang baik terhadap data latihan. Pada epoch terakhir, model mencapai kejitian yang sangat tinggi dan kehilangan yang sangat rendah baik pada data latihan mahupun validasi, menunjukkan bahawa model TempCNN ini telah belajar pola data dengan sangat baik tanpa tanda-tanda overfitting yang jelas.

Secara keseluruhannya, model TempCNN ini menunjukkan prestasi yang cemerlang sepanjang proses latihan dengan peningkatan yang konsisten dalam kejitian dan pengurangan kehilangan. Model ini mampu mempelajari pola dari data dengan cepat dan tepat, memberikan prestasi yang kukuh pada data validasi.

### Penilaian Rangkaian Neural Konvolusi (CNN)

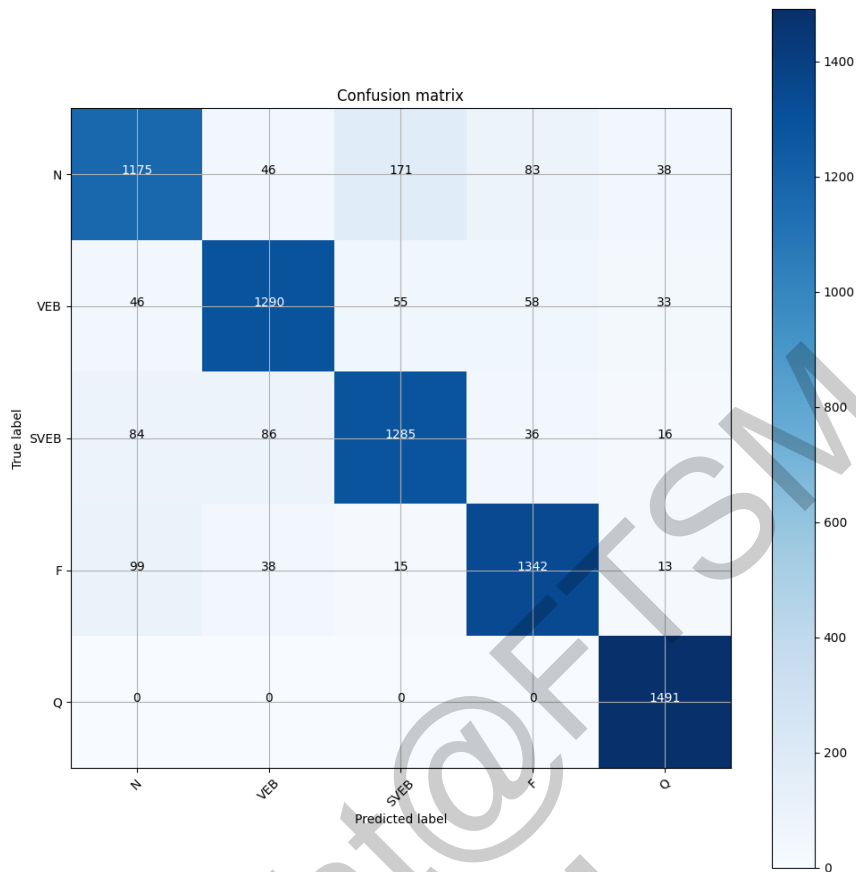
Jadual 6 menunjukkan keputusan penilaian metrik bagi model CNN. Manakala Rajah 5 memaparkan matriks konfusi model CNN. Jadual 7 menunjukkan prestasi model dalam kejitian dan kehilangan latihan dan ujian manakala Rajah 6 menunjukkan graf kejitian latihan dan ujian Model CNN dan Rajah 7 menunjukkan graf kehilangan latihan dan ujian Model CNN.

Jadual 6 Keputusan penilaian metrik model CNN

Label	Penilaian Metriks			
	Kebersihan	Dapatan semula	Skor F1	Sokongan
N	0.84	0.78	0.81	1513
VEB	0.88	0.87	0.88	1482
SVEB	0.84	0.85	0.85	1507
F	0.88	0.89	0.89	1507
Q	0.94	1.00	0.97	1491

Menurut Jadual 6, boleh didapati bahawa bagi label N, model CNN mencatatkan kepersisan sebanyak 0.81, dapatan semula sebanyak 0.78, dan skor F1 sebanyak 0.81 dengan sokongan sebanyak 1513. Nilai kepersisan dan dapatan semula yang terendah menunjukkan bahawa model ini kerap kali gagal mengenal pasti label N dengan tepat. Untuk label VEB, model mencatatkan kepersisan sebanyak 0.88, dapatan semula sebanyak 0.87, dan skor F1 sebanyak 0.88 dengan sokongan sebanyak 1482. Nilai dapatan semula yang tinggi telah menunjukkan kebolehan model dalam mengenal pasti kebanyakan label VEB dengan tepat, walaupun masih terdapat sedikit kesalahan dalam mengklasifikasikan rekod berlabel VEB. Selain itu, untuk label SVEB, model CNN telah mencatatkan kepersisan sebanyak 0.84, dapatan semula sebanyak 0.85, dan skor F1 sebanyak 0.85 dengan sokongan sebanyak 1507. Di samping itu, model menunjukkan prestasi yang terbaik dalam mengklasifikasikan label Q dengan kepersisan bernilai 0.94, dapatan semula bernilai 1.00, dan skor F1 berada pada 0.97, dengan sokongan sebanyak 1491. Ini menunjukkan model ini sangat tepat dan konsisten dalam mengenal pasti label Q, dengan sedikit kesilapan positif dan negatif palsu. Akhir sekali, bagi label F, model mencatatkan prestasi yang cemerlang dengan kepersisan sebanyak 0.88, dapatan semula sebanyak 0.89, dan skor F1 sebanyak 0.89 dengan sokongan sebanyak 1507.

Secara keseluruhannya, model CNN menunjukkan prestasi yang baik dalam mengklasifikasikan pelbagai jenis arrhythmia dengan metrik kepersisan, dapatan semula, dan skor F1 yang memuaskan.




Rajah 5 Matriks Konfusi model CNN

Berdasarkan matriks konfusi di atas, model CNN berjaya mengenalpasti 1175 sampel sebagai label N dengan betul. Namun, terdapat banyak kes kekeliruan dengan 46 sampel salah diklasifikasikan sebagai label VEB, 171 sebagai label SVEB, 83 sebagai label F dan 38 sebagai label Q. Seterusnya, model CNN telah mengenalpasti 1290 label VEB secara tepat, dengan 46 rekod disalahklasifikasi kepada N, 55 rekod disalahsampelkan kepada SVEB, 58 rekod disalahlabelkan kepada F dan 33 rekod disalahlabelkan kepada Q. Bukan itu sahaja, model juga menunjukkan keputusan yang sederhana dengan 1285 label SVEB berjaya diklasifikasi secara tepat dan 222 label dikelirukan dengan label lain. Bagi label F dan Q, model CNN telah menunjukkan prestasi yang cemerlang dalam mengklasifikasikan kedua-dua label ini. Label F dikenalpasti dengan baik oleh model dengan 1342 rekod dilabelkan dengan tepat dan 165 rekod disalahsampelkan kepada label lain. Akhir sekali, model mncapai prestasi yang tertinggi dalam mengenalpasti 1491 label Q dengan betul, menunjukkan prestasi yang kukuh dalam mengklasifikasikan label ini.


Secara keseluruhan, model CNN menunjukkan prestasi yang sangat baik secara keseluruhan dalam mengklasifikasikan kelima-lima label. Label Q dan F menunjukkan prestasi yang cemerlang dengan kekeliruan yang sangat sedikit. Prestasi model untuk label N, VEB, dan SVEB adalah sederhana, dengan sedikit kekeliruan antara kelas-kelas ini.

Jadual 7 Kehilangan dan Kejituan Latihan dan Ujian Model CNN

Epoch	Kehilangan Latihan	Kejituan Latihan	Kehilangan Uji	Kejituan Uji
1	1.027	0.5986	0.7355	0.7403
2	0.7511	0.7328	0.5991	0.8149
3	0.6493	0.7799	0.5129	0.8353
4	0.5883	0.7976	0.4461	0.8647
5	0.5347	0.8203	0.4019	0.8777



Rajah 6 Graf Kejituan Latihan dan Ujian Model CNN



Rajah 7 Graf Kehilangan Latihan dan Ujian Model CNN

Berdasarkan Jadual 7, Model CNN telah dilatih dan diuji pada set data tertentu melalui 5 epoch. Pada epoch pertama, model mula belajar dari data latihan. Terdapat perbezaan yang agak besar antara kehilangan latihan dan kehilangan validasi, menunjukkan bahawa model sedang dalam proses penyesuaian dengan data. Pada epoch kedua, terdapat peningkatan yang ketara dalam kejitian latihan dan validasi, dan penurunan dalam kehilangan. Ini menunjukkan bahawa model sedang belajar pola dari data dengan lebih baik. Model terus memperbaiki kejitian dan menurunkan kehilangan, menunjukkan pemahaman yang lebih baik tentang data latihan dan peningkatan prestasi pada data validasi. Pada epoch yang seterusnya, model menunjukkan peningkatan yang konsisten dalam kejitian dan penurunan kehilangan menunjukkan bahawa model semakin baik dalam mengenali pola data. Pada epoch terakhir, model mencapai kejitian yang tinggi dan kehilangan yang rendah baik pada data latihan mahupun validasi, menunjukkan bahawa model telah mencapai prestasi yang baik dalam mempelajari pola data tanpa tanda-tanda overfitting yang jelas.

Secara keseluruhannya, model CNN ini menunjukkan peningkatan yang mantap dalam kejitian dan pengurangan kehilangan sepanjang proses latihan. Model ini berupaya untuk mempelajari pola dari data dengan baik dan menerapkan pembelajaran tersebut pada data validasi, menghasilkan prestasi yang kukuh

### Penilaian Rangkaian Neural Berulang (RNN)

Jadual 8 menunjukkan keputusan penilaian metrik bagi model RNN. Rajah 8 memaparkan matriks konfusi keputusan penilaian model RNN. Jadual 9 menunjukkan prestasi model dalam kejitian dan kehilangan latihan dan ujian manakala Rajah 9 menunjukkan graf kejitian latihan dan ujian Model RNN dan Rajah 10 menunjukkan graf kehilangan latihan dan ujian Model RNN.

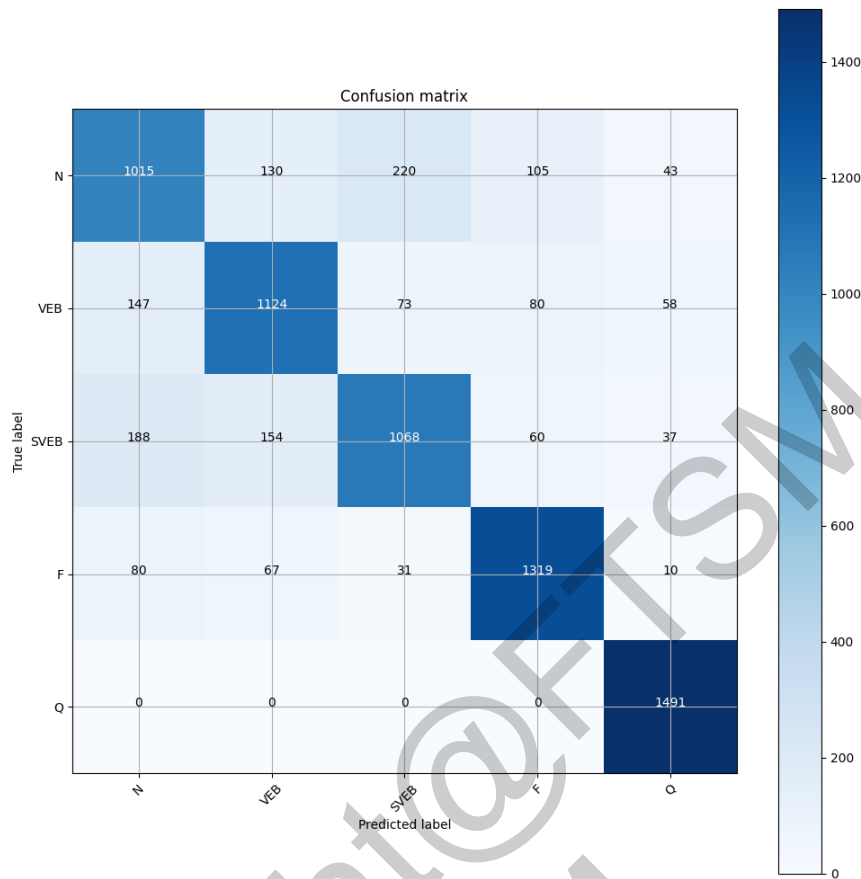
Jadual 8 Keputusan penilaian metrik model RNN

Label	Penilaian Metriks			
	Kepersisan	Dapatan semula	Skor F1	Sokongan
N	0.71	0.67	0.69	1513
VEB	0.76	0.76	0.76	1482
SVEB	0.77	0.71	0.74	1507
F	0.84	0.88	0.86	1507
Q	0.91	1.00	0.95	1491
Kejitian: 0.80				



Berdasarkan Jadual 8, Model RNN mencapai kepersisan bernilai 0.71, dapatan semula serendah 0.67 dan skor F1 bernilai 0.69 dalam mengklasifikasikan label N, menunjukkan model mempunyai kesukaran dalam mengenal pasti dan mengklasifikasikan degupan jantung berlabel N dengan tepat. Untuk label VEB, model menunjukkan prestasi yang lebih baik berbanding label N, dengan kepersisan 0.76 dan dapatan semula 0.76. Skor F1 sebanyak 0.76 menunjukkan keseimbangan yang agak baik antara kepersisan dan dapatan semula, walaupun masih terdapat ruang untuk peningkatan, khususnya dalam meningkatkan dapatan semula. Di samping itu, model RNN mencapai kepersisan sebesar 0.77, tetapi dapatan semula yang lebih rendah (0.71), dengan skor F1 sebanyak 0.74 dalam mengklasifikasikan label SVEB. Untuk label F, model prestasi yang baik dengan kepersisan 0.84 dan dapatan semula 0.88, menghasilkan skor F1 sebanyak 0.86. Dapatan semula yang tinggi menunjukkan model sangat baik dalam mengenal pasti kes sebenar bagi label ini, tetapi masih terdapat beberapa positif palsu yang mengurangkan kepersisan. Akhirnya, model RNN menunjukkan prestasi yang cemerlang dengan kepersisan 0.91 dan dapatan semula sempurna (1.00), menghasilkan skor F1 yang tinggi sebanyak 0.95. Ini menunjukkan model sangat berkesan dalam mengenal pasti dan mengklasifikasikan degupan jantung berlabel Q.

Secara keseluruhan, Model RNN menunjukkan prestasi yang baik secara keseluruhan, dengan prestasi terbaik dalam mengklasifikasikan label Q dan prestasi sederhana untuk label N. Prestasi ini menunjukkan bahawa model berfungsi dengan baik untuk beberapa jenis aritmia, tetapi memerlukan penambahbaikan untuk jenis yang lain, terutama dalam meningkatkan kepersisan dan dapatan semula untuk label N dan SVEB.




Rajah 8 Matriks Konfusi model RNN

Berdasarkan matriks keliruan yang dilampirkan, Model RNN berjaya mengklasifikasikan 1015 sampel dengan betul sebagai label N, namun ada 498 sampel berlabel N yang salah diklasifikasikan sebagai kelas lain. Selain itu, model mempunyai sedikit kesalahan dalam mengklasifikasikan VEB, dengan 81 sampel yang salah diklasifikasikan sebagai kelas lain. Begitu juga dengan klasifikasi label SVEB, terdapat sedikit kesalahan dalam mengklasifikasikan SVEB, dengan 54 sampel yang salah diklasifikasikan sebagai kelas lain. Model menunjukkan prestasi yang sangat baik dalam mengklasifikasikan F, dengan hanya 63 sampel yang salah diklasifikasikan. Model hampir sempurna dalam mengklasifikasikan kelas Q dengan 1491 sampel betul diklasifikasikan dan hanya 15 kesalahan.


Secara keseluruhan, model menunjukkan bahawa ia berkesan dalam menangani tugas klasifikasi EKG, tetapi ada ruang untuk peningkatan dalam mengurangkan kesalahan antara kelas tertentu.

Jadual 9 Kehilangan dan Kejituan Latihan dan Ujian Model RNN

Epoch	Kehilangan Latihan	Kejituan Latihan	Kehilangan Uji	Kejituan Uji
1	1.2825	0.4595	1.0238	0.6087
2	0.9958	0.6217	0.8003	0.7277
3	0.8401	0.6952	0.6587	0.7661
4	0.7630	0.7234	0.6060	0.773
5	0.6902	0.7495	0.5421	0.8023



Rajah 9 Graf Kejituan Latihan dan Ujian Model RNN



Rajah 10 Graf Kehilangan Latihan dan Ujian Model RNN

Berdasarkan Jadual 9, Model RNN telah dilatih dan diuji pada set data tertentu melalui 5 epoch. Pada epoch pertama, model mula belajar dari data latihan. Terdapat perbezaan yang agak besar antara kehilangan latihan dan kehilangan validasi, menunjukkan bahawa model sedang dalam proses penyesuaian dengan data. Pada epoch kedua, terdapat peningkatan yang ketara dalam kejituan latihan dan validasi, dan penurunan dalam kehilangan. Ini menunjukkan bahawa model sedang belajar pola dari data dengan lebih baik. Model terus memperbaiki kejituan dan menurunkan kehilangan, menunjukkan pemahaman yang lebih baik tentang data

latihan dan peningkatan prestasi pada data validasi. Pada epoch yang seterusnya, model menunjukkan peningkatan yang konsisten dalam kejituan dan penurunan kehilangan menunjukkan bahawa model semakin baik dalam mengenali pola data. Pada epoch terakhir, model mencapai kejituan yang tinggi dan kehilangan yang rendah baik pada data latihan mahupun validasi, menunjukkan bahawa model telah mencapai prestasi yang baik dalam mempelajari pola data tanpa tanda-tanda overfitting yang jelas.

Secara keseluruhannya, model RNN ini menunjukkan peningkatan yang mantap dalam kejituan dan pengurangan kehilangan sepanjang proses latihan. Model ini berupaya untuk mempelajari pola dari data dengan baik dan menerapkan pembelajaran tersebut pada data validasi, menghasilkan prestasi yang kukuh.

### Penilaian Memori Pendek Jangka Panjang (LSTM)

Jadual 10 menunjukkan keputusan penilaian metrik bagi model LSTM. Rajah 11 memaparkan matriks konfusi keputusan penilaian model LSTM. Jadual 11 menunjukkan prestasi model dalam kejituan dan kehilangan latihan dan ujian manakala Rajah 12 menunjukkan graf kejituan latihan dan ujian Model LSTM dan Rajah 13 menunjukkan graf kehilangan latihan dan ujian Model LSTM.

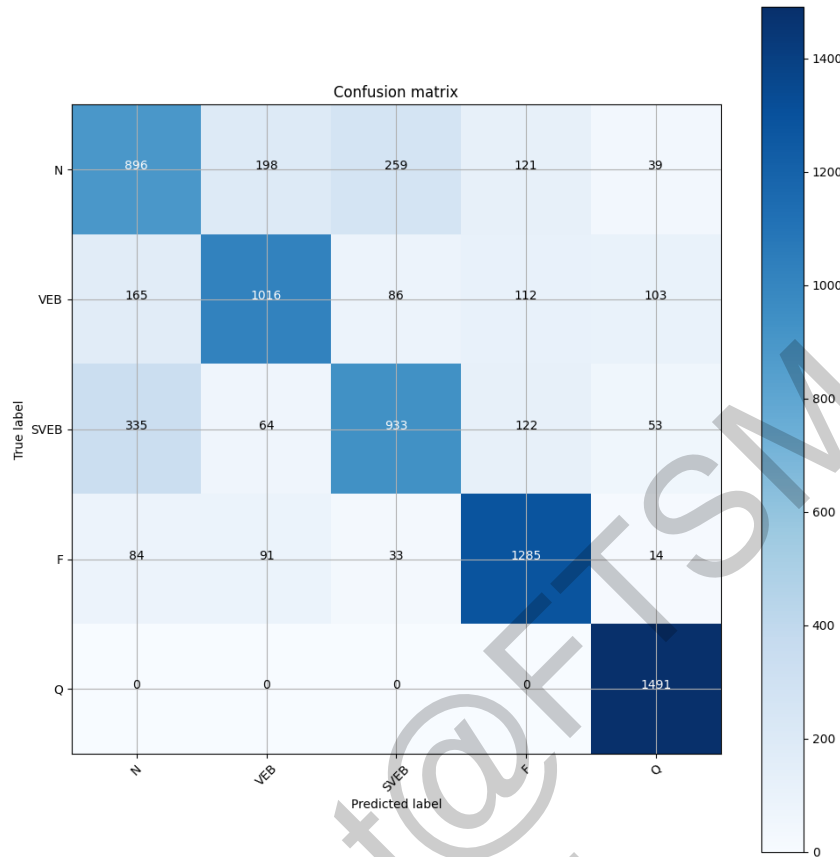
Jadual 10 Keputusan penilaian metrik model LSTM

Label	Penilaian Metriks			
	Kepersisan	Dapatan semula	Skor F1	Sokongan
N	0.61	0.59	0.60	1513
VEB	0.74	0.69	0.71	1482
SVEB	0.71	0.62	0.66	1507
F	0.78	0.85	0.82	1507
Q	0.88	1.00	0.93	1491
Kejituan: 0.75				

Berdasarkan Jadual 10, Model LSTM mencapai kepersisan bernilai 0.61, dapatan semula serendah 0.59 dan skor F1 bernilai 0.60 dalam mengklasifikasikan label N, menunjukkan model mempunyai kesukaran dalam mengenal pasti dan mengklasifikasikan degupan jantung berlabel N dengan tepat. Untuk label VEB, model menunjukkan prestasi yang lebih baik berbanding label N, dengan kepersisan 0.74 dan dapatan semula 0.69. Skor F1 sebanyak 0.71 menunjukkan keseimbangan yang agak baik antara kepersisan dan dapatan semula, walaupun masih terdapat ruang untuk peningkatan, khususnya dalam meningkatkan

dapatan semula. Di samping itu, model LSTM mencapai kepersisan sebesar 0.71, tetapi dapatan semula yang lebih rendah (0.62), dengan skor F1 sebanyak 0.66 dalam mengklasifikasikan label SVEB. Untuk label F, model prestasi yang baik dengan kepersisan 0.78 dan dapatan semula 0.85, menghasilkan skor F1 sebanyak 0.82. Dapatan semula yang tinggi menunjukkan model sangat baik dalam mengenal pasti kes sebenar bagi label ini, tetapi masih terdapat beberapa positif palsu yang mengurangkan kepersisan. Akhirnya, model LSTM menunjukkan prestasi yang cemerlang dengan kepersisan 0.88 dan dapatan semula sempurna (1.00), menghasilkan skor F1 yang tinggi sebanyak 0.93 dalam mengklasifikasikan rekod berlabel Q. Ini menunjukkan model sangat berkesan dalam mengenal pasti dan mengklasifikasikan degupan jantung berlabel Q.

Secara keseluruhan, Model LSTM menunjukkan prestasi yang baik secara keseluruhan, dengan prestasi terbaik dalam mengklasifikasikan label Q dan prestasi sederhana untuk label N. Prestasi ini menunjukkan bahawa model berfungsi dengan baik untuk beberapa jenis aritmia, tetapi memerlukan penambahbaikan untuk jenis yang lain, terutama dalam meningkatkan kepersisan dan dapatan semula untuk label N dan SVEB.



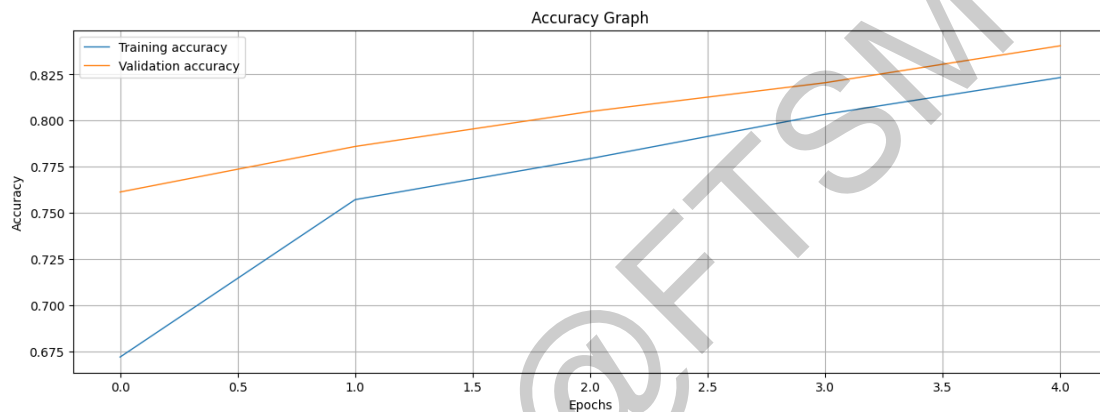
Rajah 11 Matriks Konfusi model LSTM

Berdasarkan matriks konfusi di atas, Model LSTM berjaya mengklasifikasikan 896 sampel dengan betul sebagai normal, namun ada 642 sampel normal yang salah diklasifikasikan sebagai kelas lain. Di samping itu, model mengklasifikasikan 1016 rekod berlabel VEB dengan betul, dengan 569 sampel yang salah diklasifikasikan sebagai kelas lain. Selain itu, terdapat banyak kesalahan dalam mengklasifikasikan SVEB, dengan 574 sampel yang salah diklasifikasikan sebagai kelas lain. Sebaliknya, model menunjukkan prestasi yang sangat baik dalam mengklasifikasikan F, dengan 1285 sampel berjaya diklasifikasikan dengan tepat dan hanya 222 sampel yang salah diklasifikasikan. Bukan itu sahaja, model hampir sempurna dalam mengklasifikasikan kelas Q dengan 1491 sampel betul diklasifikasikan.

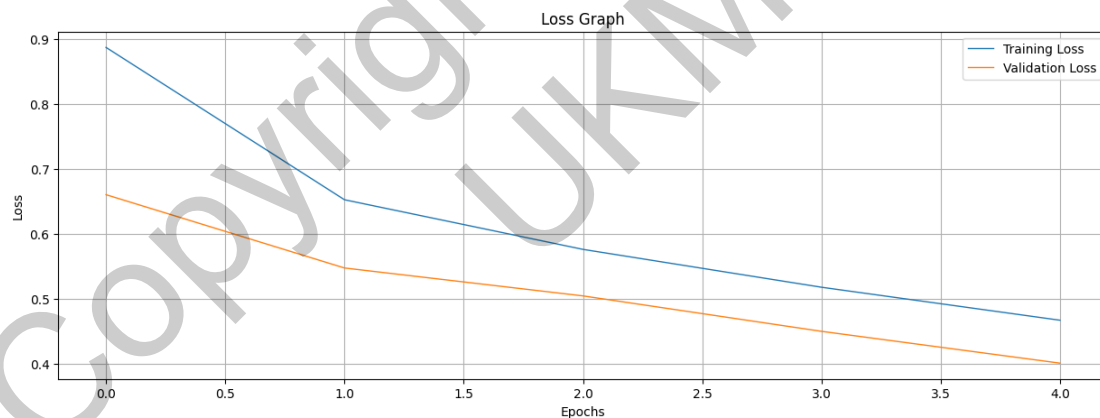
Secara keseluruhannya, Model LSTM menunjukkan prestasi yang sederhana dalam mengklasifikasikan kelima-lima label. Matriks kekeliruan ini menunjukkan bahawa model LSTM mempunyai banyak ruang untuk penambahbaikan, terutamanya dalam mengurangkan kekeliruan antara kelas-kelas yang berbeza.

Jadual 11 Kehilangan dan Kejituan Latihan dan Ujian Model LSTM

Epoch	Kehilangan Latihan	Kejituan Latihan	Kehilangan Uji	Kejituan Uji
1	1.2676	0.4748	1.095	0.5595
2	1.0563	0.5768	0.9496	0.6431
3	0.9269	0.6409	0.8127	0.7097
4	0.7968	0.7009	0.7264	0.7377
5	0.7059	0.7381	0.6507	0.7495



Rajah 12 Graf Kejituan Latihan dan Ujian Model LSTM



Rajah 13 Graf Kehilangan Latihan dan Ujian Model LSTM

Berdasarkan Jadual 11, Model LSTM telah dilatih dan diuji pada set data tertentu melalui 5 epoch. Pada epoch pertama, model menunjukkan kehilangan latihan dan ujian yang tinggi serta kejituan yang rendah. Ini adalah biasa kerana model masih dalam fasa awal pembelajaran. Pada epoch kedua, terdapat peningkatan yang ketara dalam kejituan latihan dan ujian, dan penurunan dalam kehilangan. Ini menunjukkan bahawa model mula memahami pola dalam data dan menunjukkan pembelajaran yang positif. Pada epoch yang seterusnya, kejituan terus meningkat dan kehilangan menurun, menunjukkan model semakin baik dalam mengenali

pola data dan membuat ramalan yang lebih tepat. Pada epoch terakhir, model mencapai kejituan latihan dan validasi yang paling tinggi dan kehilangan yang paling rendah sepanjang proses latihan. Ini menunjukkan bahawa model telah belajar pola data dengan baik dan mampu membuat ramalan yang tepat.

Secara keseluruhan, model LSTM ini menunjukkan peningkatan konsisten dalam kejituan dan pengurangan kehilangan sepanjang epoch. Model ini mampu mempelajari pola dari data dengan berkesan dan memberikan prestasi yang baik pada data validasi, menunjukkan bahawa model ini berupaya generalisasi dengan baik terhadap data baru.

### Perbandingan Model secara Keseluruhan

Perbandingan model adalah langkah kritikal dalam proses pembangunan dan penilaian sistem pembelajaran mesin. Tujuan utamanya adalah untuk menentukan model yang paling efektif dan efisien dalam menyelesaikan masalah tertentu berdasarkan metrik penilaian yang relevan. Jadual 12 menunjukkan perbandingan antara keputusan model-model klasifikasi.

Jadual 12 Perbandingan keputusan model klasifikasi

Model	Penilaian Metriks				
	Kepersisan	Dapatan Semula	Kejituan	Skor F1	Ranking
TempCNN	0.96	0.95	0.95	0.95	1
CNN	0.87	0.87	0.87	0.87	2
RNN	0.80	0.80	0.80	0.80	3
LSTM	0.74	0.75	0.75	0.75	4

Berdasarkan Jadual 12 di atas, model TempCNN menunjukkan prestasi tertinggi dengan semua metrik penilaian mencatatkan nilai 0.95. Ini menunjukkan model ini mempunyai keupayaan yang sangat baik dalam mengesan dan mengklasifikasikan pelbagai jenis aritmia EKG dengan kejituan yang tinggi. Keputusan ini menandakan bahawa TempCNN mampu membuat ramalan yang konsisten dan tepat. Seterusnya, Model CNN juga menunjukkan prestasi yang baik dengan semua metrik pada nilai yang sama, 0.87. Ini menunjukkan bahawa model ini konsisten dalam mengenal pasti kes sebenar dan meminimumkan positif palsu. Walaupun prestasinya tidak setinggi TempCNN, ia masih merupakan pilihan yang kukuh untuk pengesanan aritmia. Di samping itu, Model RNN juga menunjukkan prestasi yang baik dengan semua metrik penilaian mencatatkan nilai 0.80. Ini menunjukkan bahawa model ini mempunyai



keseimbangan yang baik antara kepersisan dan dapatan semula, tetapi terdapat ruang untuk peningkatan untuk mencapai kejitian yang lebih tinggi. Model LSTM menunjukkan prestasi yang paling rendah antara semua model dengan kepersisan dan kejitian yang sedikit lebih rendah. Skor F1 0.75 menunjukkan bahawa model ini memerlukan penambahbaikan untuk mengurangkan positif palsu dan negatif palsu. Walaupun LSTM dikenali kerana prestasi yang baik dalam pemprosesan data berurutan, dalam kes ini, ia tidak menunjukkan prestasi yang sebaik model lain.

Secara keseluruhan, TempCNN adalah model terbaik untuk klasifikasi aritmia dalam dataset ini, diikuti oleh CNN, RNN, dan LSTM. TempCNN menunjukkan prestasi cemerlang dalam semua metrik, menjadikannya pilihan utama. CNN juga merupakan model yang kukuh, manakala RNN dan LSTM memerlukan penambahbaikan lebih lanjut untuk mencapai kejitian dan prestasi yang lebih tinggi.

#### **KEBOLEHGUNAAN MODEL PADA SET DATA ST PETERSBURG INCART 12-LEAD ARRHYTHMIA DATABASE**

Pangkalan Data St Petersburg INCART 12-lead Arrhythmia telah digunakan untuk pengesanan model bagi memastikan bahawa model yang telah dilatih dan diuji dapat mengesan aritmia dengan berkesan. Ini penting kerana walaupun model mungkin menunjukkan prestasi yang baik pada set data latihan dan ujian, ia mesti diuji pada set data yang berbeza tetapi berkaitan untuk memastikan generalisasi dan kejitian dalam pengesanan aritmia.

Dalam dataset ini, setiap rakaman terdiri daripada 12 saluran isyarat EKG yang diperoleh secara serentak dan disampel pada 257 sampel sesaat. Setiap degupan jantung dalam rakaman dianotasi dengan jenisnya, seperti degupan normal (N), degupan ektopik ventrikular (VEB), degupan ektopik supraventrikular (SVEB), fibrilasi atrium (F), dan lain-lain(Q).

Sama seperti set data Pangkalan Data Aritmia MIT-BIH, data yang diperolehi melalui langkah prapemprosesan yang sama untuk memastikan ketekalan dan kebolehbandingan. Ini termasuk penyingkiran bunyi bising, dan penskalaan data untuk menjajarkan data dengan format yang digunakan dalam set data Pangkalan Data Aritmia MIT-BIH.

Nisbah pembahagian data latih-uji (70-30) dan model (TempCNN, CNN, RNN, LSTM), yang pada mulanya dilatih pada set data Pangkalan Data Aritmia MIT-BIH, telah

digunakan untuk eksperimen. Model-model ini digunakan secara langsung tanpa sebarang pelarasan atau pengubahsuaian. Dengan menyesuaikan model terlatih ke dalam set data St Petersburg INCART 12-lead Arrhythmia, penyelidik menasaskan untuk menilai kebolegunaan dan keupayaan generalisasi model kepada jenis aritmia yang berbeza. Pendekatan ini membolehkan penyelidik menilai sama ada pengetahuan yang diperolehi daripada dataset Pangkalan Data Aritmia MIT-BIH boleh dipindahkan dengan berkesan untuk membuat klasifikasi yang tepat untuk isyarat EKG yang baru. Jadual 4.10 berikut meringkaskan keputusan yang diperolehi untuk klasifikasi isyarat EKG, menunjukkan kepersisan, kejituan, dapatan semula dan skor F1 masing-masing untuk set data St Petersburg INCART 12-lead Arrhythmia serta kedudukan model berdasarkan prestasinya.

Jadual 13 Keputusan penilaian metrik model klasifikasi untuk set data St Petersburg INCART 12-lead Arrhythmia

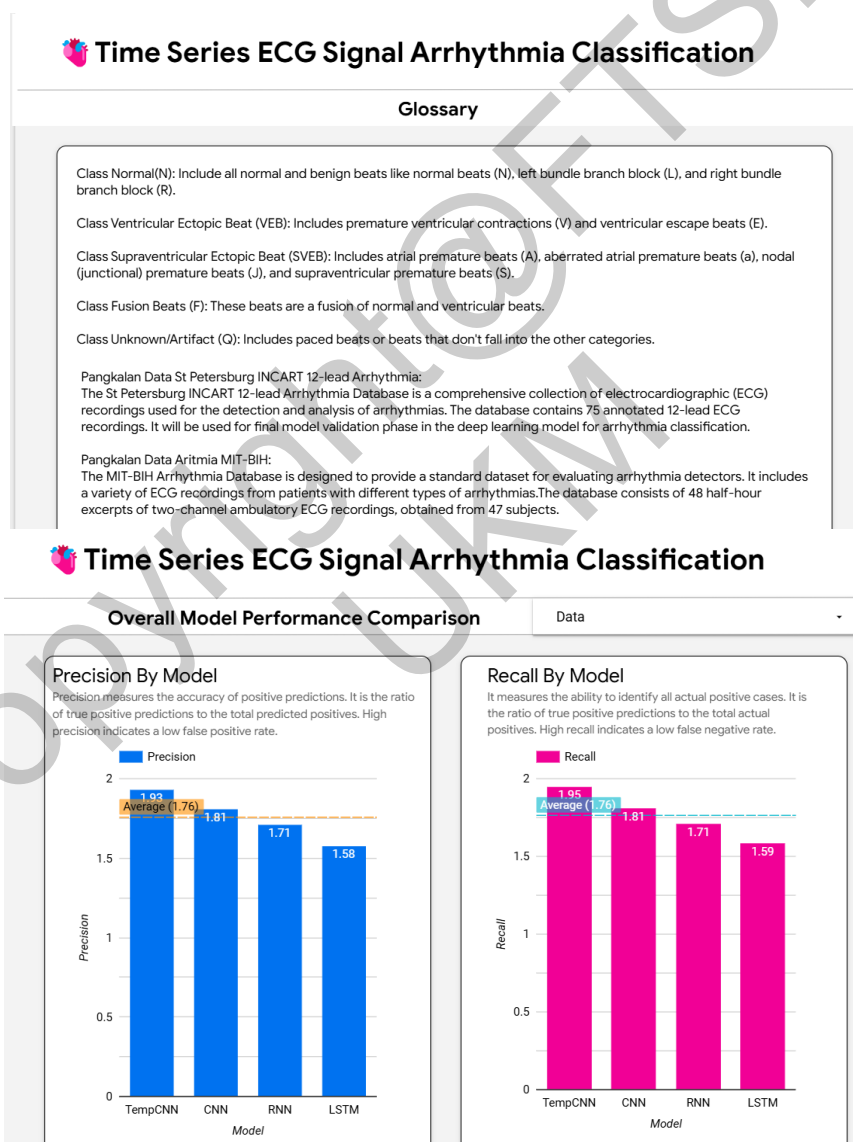
Model	Penilaian Metriks				
	Kepersisan	Dapatan Semula	Kejituan	Skor F1	Ranking
TempCNN	0.97	0.97	0.97	0.97	1
CNN	0.94	0.94	0.94	0.94	2
RNN	0.91	0.91	0.91	0.91	3
LSTM	0.84	0.84	0.84	0.84	4

Berdasarkan Jadual 13, Model TempCNN menunjukkan prestasi unggul dengan semua metrik (kepersisan, dapatan semula, kejituan, skor F1) pada 0.97, menjadikannya model yang paling berkesan untuk klasifikasi isyarat EKG aritmia. Model LSTM mencapai skor yang lebih rendah berbanding model lain dengan semua metrik pada 0.84. Selain itu, Model CNN juga menunjukkan prestasi cemerlang dengan semua metrik pada 0.94, Manakala Model RNN mencapai metrik yang sedikit lebih rendah dengan semua metrik pada 0.91.

Kesimpulannya, dalam perbandingan prestasi model untuk klasifikasi aritmia EKG, Model TempCNN dan CNN menunjukkan prestasi yang cemerlang, menjadikan kedua-dua model ini sebagai pilihan terbaik untuk klasifikasi isyarat EKG aritmia. Model RNN, walaupun menunjukkan prestasi yang baik, sedikit ketinggalan berbanding TempCNN dan CNN dengan skor 0.91 dalam semua metrik. Model LSTM pula menunjukkan prestasi yang paling rendah dengan skor 0.84.


## Papan Pemuka

Dalam penyelidikan ini, penyelidik menggunakan Looker Studio, sebuah platform visualisasi dan analisis data yang dikembangkan oleh Google, untuk membangunkan papan pemuka yang mempamerkan hasil dan visualisasi projek. Dengan Looker Studio, pengkaji boleh mencipta antara muka interaktif dan mesra pengguna dengan mudah yang membolehkan pengguna meneroka analisis klasifikasi isyarat EKG siri masa. Papan pemuka akan menyediakan platform untuk memaparkan metrik penilaian dan mempersembahkan dan membandingkan prestasi model klasifikasi.




### Accuracy By Model

Accuracy measures the overall correctness of the model. It is the ratio of correctly predicted instances (both false positives and true negatives) to the total instances.



### F1 Score By Model

The F1 Score is the harmonic mean of precision and recall. It provides a balance between precision and recall, especially useful when the classes are imbalanced.




## TEMPORAL CONVOLUTIONAL NEURAL NETWORK

### Model Result Performance

Data: Pangkalan Data St Petersburg INCART...(1)


### Classification Report by Label

A classification report is a text summary that shows the main metrics for each class of a machine learning model. It includes the precision, recall, F1 score, for each class.



### Graph of Training & Test Accuracy By Epoch

Training accuracy is the percentage of correct predictions made by the model on the training data while test accuracy is the percentage of correct predictions made by the model on the test dataset. Similar Training and Test Accuracy indicates good generalization, suggesting that the model is neither underfitting nor overfitting.



### Graph of Training & Test Loss By Epoch

Training loss refers to the error on the training dataset. Test or validation loss refers to the error on the test dataset, which is a separate dataset used to evaluate the model. Similar training and test losses here are a positive sign indicating that the model has learned well from the training data and generalizes effectively to unseen data.




## CONVOLUTIONAL NEURAL NETWORK

### Model Result Performance

Data

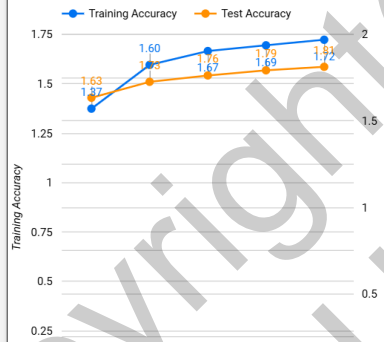
#### Classification Report by Label

A classification report is a text summary that shows the main metrics for each class of a machine learning model. It includes the precision, recall, F1-score, for each class.



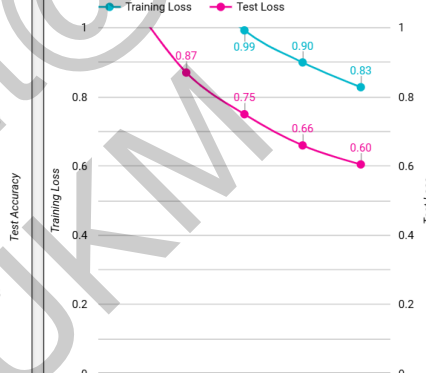
#### Graph of Training & Test Accuracy By Epoch

Training accuracy is the percentage of correct predictions made by the model on the training data while test accuracy is the percentage of correct predictions made by the model on the test dataset. Similar Training and Test Accuracy indicates good generalization, suggesting that the model is neither underfitting nor overfitting.



#### Graph of Training & Test Loss By Epoch

Training loss refers to the error on the training dataset. Test or validation loss refers to the error on the test dataset, which is a separate dataset used to evaluate the model. Similar training and test losses here are a positive sign indicating that the model has learned well from the training data and generalizes effectively to unseen data.



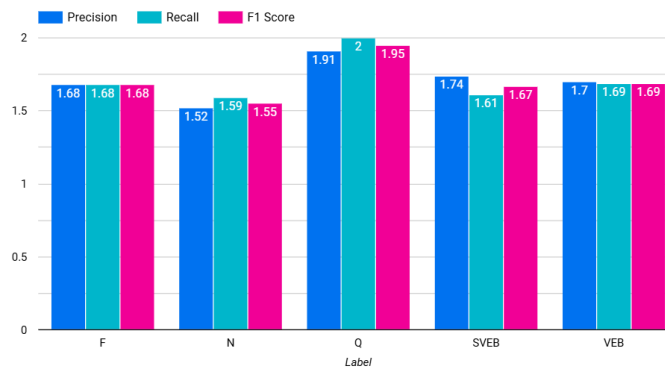
## RECURRENT NEURAL NETWORK

### Model Result Performance

Data


#### Classification Report by Label

A classification report is a text summary that shows the main metrics for each class of a machine learning model. It includes the precision, recall, F1-score, for each class.



Graph of Training & Test Accuracy By Epoch

Training accuracy is the percentage of correct predictions made by the model on the training data while test accuracy is the percentage of correct predictions made by the model on the test dataset. Similar Training and Test Accuracy indicates good generalization, suggesting that the model is neither underfitting nor overfitting.



Graph of Training & Test Loss By Epoch

Training loss refers to the error on the training dataset. Test or validation loss refers to the error on the test dataset, which is a separate dataset used to evaluate the model.

Similar training and test losses here are a positive sign indicating that the model has learned well from the training data and generalizes effectively to unseen data.




**LONG SHORT-TERM MEMORY**

**Model Result Performance**

Data: Pangkalan Data St Petersburg INCART... (1)

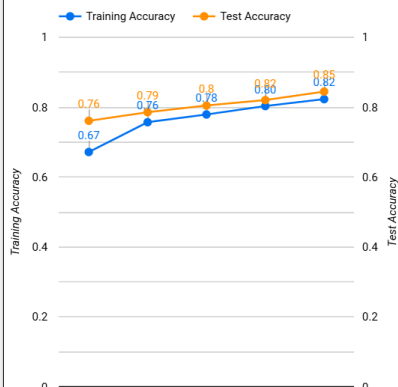
Classification Report by Label

A classification report is a text summary that shows the main metrics for each class of a machine learning model. It includes the precision, recall, F1-score, for each class.



Graph of Training & Test Accuracy By Epoch

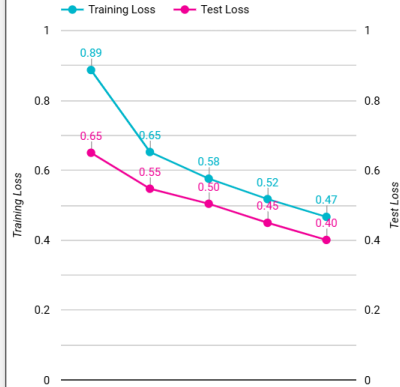
Training accuracy is the percentage of correct predictions made by the model on the training data while test accuracy is the percentage of correct predictions made by the model on the test dataset. Similar Training and Test Accuracy indicates good generalization, suggesting that the model is neither underfitting nor overfitting.



Graph of Training & Test Loss By Epoch

Training loss refers to the error on the training dataset. Test or validation loss refers to the error on the test dataset, which is a separate dataset used to evaluate the model.

Similar training and test losses here are a positive sign indicating that the model has learned well from the training data and generalizes effectively to unseen data.



Gambar 1 Papan pemuka

Melalui papan permuka tersebut, pengguna boleh mengetahui dan membandingkan prestasi semua model yang dikaji dalam projek ini, iaitu model CNN, LSTM, RNN dan CNN. Papan pemuka akan memaparkan nilai klasifikasi secara keseluruhan semua model, membolehkan pengguna membandingkan secara visual. Kemudian, pengguna boleh memilih muka surat bagi setiap model untuk dipersembahkan keputusan metrik prestasi model secara lebih lanjut dengan grafik yang berbagai seperti carta bar. Papan pemuka boleh diakses melalui pautan <https://lookerstudio.google.com/reporting/86aee71b-aed3-4491-8d85-a743dc2c3469>

## KESIMPULAN

Kesimpulannya, projek ini telah berjaya mencapai objektifnya untuk mengklasifikasikan isyarat EKG aritmia siri masa menggunakan pelbagai model pembelajaran mesin seperti TempCNN, CNN, LSTM, dan RNN. Penilaian komprehensif model-model ini memberikan cerapan berharga tentang prestasinya, dengan TempCNN muncul sebagai model paling tepat untuk klasifikasi isyarat EKG. CNN dan RNN juga menunjukkan prestasi yang baik, manakala LSTM memberikan hasil yang agak kurang berprestasi.

Selain itu, penyiasatan terhadap pelbagai kategori aritmia menunjukkan bahawa TempCNN dan CNN kekal teguh dan berkesan dalam mengklasifikasikan isyarat EKG merentas kategori ini. Walau bagaimanapun, projek ini juga menyerlahkan cabaran yang ditimbulkan oleh batasan pengiraan dalam platform berasaskan awan dan keperluan untuk ensemble model yang lebih kompleks.

Bagi penyelidikan masa depan, projek ini berfungsi sebagai asas akademik yang kukuh untuk penyelidikan klasifikasi isyarat EKG, menawarkan panduan tentang pemilihan model, pemprosesan isyarat EKG serta seni bina model untuk meningkatkan keupayaan klasifikasi.

## PENGHARGAAN

Segala puji dan syukur bagi Allah, Yang Maha Pengasih lagi Maha Penyayang. Saya dengan rendah hati menadah tangan tanda kesyukuran, terharu kerana telah menyiapkan projek tahun akhir saya dengan bimbingan dan rahmat yang dikurniakan kepada saya. Saya ingin merakamkan setinggi-tinggi penghargaan kepada penyelia saya, Prof. Dr. Salwani Abdullah, atas bimbingan, sokongan dan dorongan sepanjang semester sebagai penyelia projek akhir tahun saya. Kepakaran dan pandangan beliau yang tidak ternilai telah memainkan peranan penting dalam membentuk hala tuju dan hasil projek saya. Saya amat berterima kasih atas masa dan usaha yang dia telah laburkan untuk saya dan kerja saya. Saya tidak akan dapat menyiapkan projek ini tanpa bimbingan beliau. Terima kasih, Prof. Dr. Salwani.

Saya juga ingin mengucapkan terima kasih juga kepada para pensyarah dari FTSM yang telah menaburkan ilmu pengetahuan kepada saya sepanjang pengajian saya di Universiti Kebangsaan Malaysia (UKM). Saya juga ingin merakamkan ribuan terima kasih kepada ahli keluarga saya kerana memberi sokongan dan semangat serta sentiasa berdoa terhadap kejayaan saya di universiti.

Akhirnya, terima kasih kepada semua yang terlibat secara langsung atau tidak langsung dalam menghasilkan laporan usulan ini. Saya juga ingin memohon maaf sekiranya terdapat kesilapan sepanjang pelaksanaan projek ini.

Sekian, terima kasih.



## RUJUKAN

- Bordignon, S., Chiara Corti, M. & Bilato, C. 2012. Atrial Fibrillation Associated with Heart Failure, Stroke and Mortality. *J Atr Fibrillation* 5(1): 467.
- Brouillette, J., Cyr, S. & Fiset, C. 2019. Mechanisms of Arrhythmia and Sudden Cardiac Death in Patients With HIV Infection. *Can J Cardiol* 35(3): 310-319.
- Cheng, J., Zou, Q. & Zhao, Y. 2021. ECG signal classification based on deep CNN and BiLSTM. *BMC Med Inform Decis Mak* 21(1): 365.
- Hassaballah, M., Wazery, Y. M., Ibrahim, I. E. & Farag, A. 2023. ECG Heartbeat Classification Using Machine Learning and Metaheuristic Optimization for Smart Healthcare Systems. *Bioengineering (Basel)* 10(4):
- Miquel, M., Nicola, S. M., Gil-Miravet, I., Guarque-Chabrera, J. & Sanchez-Hernandez, A. 2019. A Working Hypothesis for the Role of the Cerebellum in Impulsivity and Compulsivity. *Front Behav Neurosci* 13(99).
- R. Kavitha, T. C. 2014. A Study on ECG Signal Classification Techniques. *International Journal of Computer Applications* (0975 – 8887) 86(
- Shaik, A., Patel, N., Alvarez, C., Panza, G., Baker, W. L., McMahon, S. & Kluger, J. 2023. Erroneous electrocardiographic interpretations and its clinical implications. *J Cardiovasc Electrophysiol* 34(7): 1515-1522.
- Larissa Montenegro, M. A., Ana Fred, Jose M. Machado. 2022. Human-Assisted vs. Deep Learning Feature Extraction: An Evaluation of ECG Features Extraction Methods for Arrhythmia Classification Using Machine Learning. *Applied Sciences* 12
- Abdullah, L. A. & Al-Ani, M. S. 2020. CNN-LSTM Based Model for ECG Arrhythmias and Myocardial Infarction Classification. *Advances in Science, Technology and Engineering Systems Journal* 5(5): 601-606.
- An, Q., Rahman, S., Zhou, J. & Kang, J. J. 2023. A Comprehensive Review on Machine Learning in Healthcare Industry: Classification, Restrictions, Opportunities and Challenges. *Sensors (Basel)* 23(9):
- Andrés Ayala-Cucas, H., Mora-Piscal, E. A., Mayorca-Torres, D., Peluffo-Ordoñez, D. H. & León-Salas, A. J. 2022. Impact of ECG Signal Preprocessing and Filtering on Arrhythmia Classification Using Machine Learning Techniques. 27-40.
- Aziz, S., Ahmed, S. & Alouini, M.-S. 2021. ECG-based machine-learning algorithms for heartbeat classification. *Scientific Reports* 11(1): 18738.
- Cai, H., Xu, L., Xu, J., Xiong, Z. & Zhu, C. 2022. Electrocardiogram Signal Classification Based on Mix Time-Series Imaging. *Electronics* 11(13): 1991.

- Cheng, J., Zou, Q. & Zhao, Y. 2021. ECG signal classification based on deep CNN and BiLSTM. *BMC Medical Informatics and Decision Making* 21(1): 365.
- Gao, J., Zhang, H., Lu, P. & Wang, Z. 2019. An Effective LSTM Recurrent Network to Detect Arrhythmia on Imbalanced ECG Dataset. *J Healthc Eng* 2019(6320651).
- Hochreiter, S. & Schmidhuber, J. 1997. Long Short-term Memory. *Neural computation* 9(1735-1780).
- Ismail, A. R., Jovanovic, S., Ramzan, N. & Rabah, H. 2023. ECG Classification Using an Optimal Temporal Convolutional Network for Remote Health Monitoring. *Sensors (Basel)* 23(3):
- Moulton, K. P., Bhutta, B. S. & Mullin, J. C. 2023. Evaluation of Suspected Cardiac Arrhythmia. Dlm. (pnyt.). *StatPearls*, hlm. Treasure Island (FL).
- Nayan, N. A. & Ab Hamid, H. 2019. Evaluation of patient electrocardiogram datasets using signal quality indexing. *Bulletin of Electrical Engineering and Informatics* 8(2): 519-526.
- R. Kavitha, T. C. 2014. A Study on ECG Signal Classification Techniques. *International Journal of Computer Applications* (0975 – 8887) 86(
- Ramachandran, D., Kumar, R. S., Alkhayat, A., Malik, R. Q., Srinivasan, P., Priya, G. G. & Gosu Adigo, A. 2022. Classification of Electrocardiography Hybrid Convolutional Neural Network-Long Short Term Memory with Fully Connected Layer. *Comput Intell Neurosci* 2022(6348424).
- Saclova, L., Nemcova, A., Smisek, R., Smital, L., Vitek, M. & Ronzhina, M. 2022. Reliable P wave detection in pathological ECG signals. *Scientific Reports* 12(1): 6589.
- Sak, H., Senior, A. W. & Beaufays, F. 2014. Long short-term memory recurrent neural network architectures for large scale acoustic modeling. *Interspeech*, hlm.
- Salehi, N. M. F. a. L. M. a. C. W. T. a. G. I. W. a. G. F. a. M. 2023. Deep Learning for Time Series Classification and Extrinsic Regression: A Current Survey.
- Sattar, Y. & Chhabra, L. 2023. Electrocardiogram. Dlm. (pnyt.). *StatPearls*, hlm. Treasure Island (FL).
- Schmidt, R. M. 2019. Recurrent Neural Networks (RNNs): A gentle Introduction and Overview. [arXiv:1912.05911. https://ui.adsabs.harvard.edu/abs/2019arXiv191205911S](https://ui.adsabs.harvard.edu/abs/2019arXiv191205911S) [November 01, 2019].
- Singh, S., Pandey, S. K., Pawar, U. & Janghel, R. R. 2018. Classification of ECG Arrhythmia using Recurrent Neural Networks. *Procedia Computer Science* 132(1290-1297).
- Smigiel, S., Palczynski, K. & Ledzinski, D. 2021. ECG Signal Classification Using Deep Learning Techniques Based on the PTB-XL Dataset. *Entropy (Basel)* 23(9):
- Taye, M. M. 2023. Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions. *Computation* 11(3): 52.

- Venkatesan, C., Karthigaikumar, P., Paul, A., Satheeskumaran, S. & Kumar, R. 2018. ECG Signal Preprocessing and SVM Classifier-Based Abnormality Detection in Remote Healthcare Applications. *IEEE Access* 6(9767-9773).
- Wu, M., Lu, Y., Yang, W. & Wong, S. Y. 2021. A Study on Arrhythmia via ECG Signal Classification Using the Convolutional Neural Network. *Frontiers in Computational Neuroscience* 14(
- Yamashita, R., Nishio, M., Do, R. K. G. & Togashi, K. 2018. Convolutional neural networks: an overview and application in radiology. *Insights into Imaging* 9(4): 611-629.
- Abdallah, Z., Du, L. & Webb, G. 2017. Data Preparation. *Dlm. (pnyt.). hlm.*
- Chatterjee, S., Thakur, R. S., Yadav, R. N., Gupta, L. & Raghuvanshi, D. K. 2020. Review of noise removal techniques in ECG signals. *IET Signal Processing* 14(9): 569-590.
- Dobilas, S. 2022. LSTM Recurrent Neural Networks — How to Teach a Network to Remember the Past. <https://towardsdatascience.com/lstm-recurrent-neural-networks-how-to-teach-a-network-to-remember-the-past-55e54c2ff22e>
- Feng, W., Guan, N., Li, Y., Zhang, X. & Luo, Z. 2017. Audio visual speech recognition with multimodal recurrent neural networks.
- Fuhg, J., Karmarkar, A., Kadeethum, T., Yoon, H. & Bouklas, N. 2023. Deep convolutional Ritz method: parametric PDE surrogates without labeled data. *Applied Mathematics and Mechanics* 44(1151-1174).
- Holmström, L. 2008. Nonlinear Dimensionality Reduction by John A. Lee, Michel Verleysen. *International Statistical Review* 76(308-309).
- Islam, M. A. 2020. Reduced Dataset Neural Network Model for Manuscript Character Recognition.
- Kumar, P., Bhatnagar, R., Gaur, K. & Bhatnagar, A. 2021. Classification of Imbalanced Data: Review of Methods and Applications. *IOP Conference Series: Materials Science and Engineering* 1099(1): 012077.
- Liu, M., Qin, H., Cao, R. & Deng, S. 2022. Short-Term Load Forecasting Based on Improved TCN and DenseNet. *IEEE Access* PP(1-1).
- Ma, S., Xiao, B., Hong, R., Addissie, B., Drikas, Z., Antonsen, T., Ott, E. & Anlage, S. 2019. Classification and prediction of wave chaotic systems with machine learning techniques.
- Phung & Rhee. 2019. A High-Accuracy Model Average Ensemble of Convolutional Neural Networks for Classification of Cloud Image Patches on Small Datasets. *Applied Sciences* 9(4500).
- Taye, M. M. 2023. Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions. *Computation* 11(3): 52.

- Yamashita, R., Nishio, M., Do, R. K. G. & Togashi, K. 2018. Convolutional neural networks: an overview and application in radiology. *Insights into Imaging* 9(4): 611-629.
- Zhao, Y., Li, H., Yu, X., Ma, N., Yang, T. & Zhou, J. 2022. An independent central point OPTICS clustering algorithm for semi-supervised outlier detection of continuous glucose measurements. *Biomedical Signal Processing and Control* 71(103196)
- Chourasia, M., Thakur, A., Gupta, S. & Singh, A. 2020. ECG Heartbeat Classification Using CNN. *Anjuran*
- Gao, J., Zhang, H., Lu, P. & Wang, Z. 2019. An Effective LSTM Recurrent Network to Detect Arrhythmia on Imbalanced ECG Dataset. *J Healthc Eng* 2019(6320651).
- Shraddha, S., Saroj Kumar, P., Urja, P. & Rekh Ram, J. 2018. Classification of ECG Arrhythmia using Recurrent Neural Networks. *Procedia Computer Science* 132(1290-1297).

*Ng Xin Yen (A189439)*

*Prof. Dr. Salwani Abdullah*

Fakulti Teknologi & Sains Maklumat

Universiti Kebangsaan Malaysia