

# Perbandingan Algoritma CNN, LSTM, FNN untuk Diagnosa Fibrosis Hati dengan Citra Medis

*Comparison of CNN, LSTM, FNN Algorithms for Liver Fibrosis Diagnosis Using  
Medical Images*

Bagas Aji Febryanto<sup>1</sup>, Imam Tahyudin<sup>2\*</sup>

<sup>1</sup> Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Amikom Purwokerto

<sup>2</sup> Program Magister Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Amikom Purwokerto

E-mail: <sup>1</sup>bagasaji7890@gmail.com, <sup>2\*</sup>imam.tahyudin@amikompurwokerto.ac.id

**\*Corresponding author**

## **Abstrak**

Fibrosis hati merupakan kondisi yang berpotensi berkembang menjadi sirosis atau kanker hati jika tidak terdiagnosis dengan tepat. Prosedur biopsi hati yang invasif sering digunakan dalam diagnosis, namun memiliki risiko dan keterbatasan biaya. Penelitian ini bertujuan untuk membandingkan kinerja model deep learning, yaitu Convolutional Neural Network (CNN), Long Short-Term Memory (LSTM), dan Feedforward Neural Network (FNN) dalam klasifikasi fibrosis hati menggunakan citra medis. Metode yang digunakan adalah evaluasi kinerja model berdasarkan metrik akurasi, presisi, recall, F1-score, dan loss pada dataset citra medis fibrosis hati. Hasil penelitian menunjukkan bahwa CNN memberikan kinerja terbaik dengan akurasi 98%, diikuti oleh LSTM dengan akurasi 97%, dan FNN dengan akurasi 80%. CNN unggul karena kemampuannya dalam mengekstraksi fitur spasial secara otomatis dari citra medis, sementara LSTM lebih cocok untuk data sekuensial dan FNN terbatas dalam menangani data citra kompleks. Penelitian ini menyimpulkan bahwa CNN lebih efektif dalam klasifikasi fibrosis hati dan dapat menjadi alternatif non-invasif yang lebih efisien dibandingkan metode konvensional seperti biopsi. Teknologi ini berpotensi mempercepat diagnosis fibrosis hati dengan akurasi tinggi dan tanpa risiko komplikasi invasif.

Kata kunci: Fibrosis hati, CNN, LSTM, FNN, klasifikasi citra medis.

## **Abstract**

*Liver fibrosis is a condition that can progress to cirrhosis or liver cancer if not diagnosed properly. The invasive liver biopsy procedure is commonly used in diagnosis but has risks and high costs. This study aims to compare the performance of deep learning models, namely Convolutional Neural Network (CNN), Long Short-Term Memory (LSTM), and Feedforward Neural Network (FNN) in liver fibrosis classification using medical images. The methodology involves evaluating the performance of the models based on metrics such as accuracy, precision, recall, F1-score, and loss on a liver fibrosis medical image dataset. The results show that CNN performs the best with an accuracy of 98%, followed by LSTM with 97%, and FNN with 80%. CNN excels due to its ability to automatically extract spatial features from medical images, while LSTM is more suited for sequential data and FNN is limited in handling complex image data. This study concludes that CNN is more effective in liver fibrosis classification and can serve as a more efficient non-invasive alternative compared to conventional methods like biopsy. This technology has the potential to expedite liver fibrosis diagnosis with high accuracy and without the risk of invasive complications.*

*Keywords: liver fibrosis, CNN, LSTM, FNN, medical image classification.*

## 1. PENDAHULUAN

Pendahuluan Fibrosis hati merupakan kondisi patologis yang terjadi akibat penumpukan jaringan parut pada hati, yang disebabkan oleh berbagai faktor seperti infeksi kronis hepatitis B atau C, konsumsi alkohol berlebihan, serta penyakit hati berlemak non-alkohol (NAFLD) [1]. Jika tidak didiagnosis dan ditangani dengan tepat, fibrosis hati dapat berkembang menjadi sirosis atau bahkan kanker hati, yang berisiko tinggi mengarah pada gagal hati dan kematian [2]. Meskipun biopsi hati tetap menjadi metode standar dalam diagnosis fibrosis, prosedur ini bersifat invasif, mahal, dan berisiko menimbulkan komplikasi [3]. Oleh karena itu, pendekatan baru yang lebih efisien dan non-invasif, seperti penggunaan teknologi deep learning untuk analisis citra medis, semakin banyak diterapkan untuk mendeteksi fibrosis hati dengan lebih cepat dan aman.

Deep learning, cabang dari machine learning, telah terbukti efektif dalam banyak aplikasi medis, termasuk dalam analisis citra untuk deteksi penyakit hati [4]. Di antara berbagai teknik deep learning yang ada, Convolutional Neural Networks (CNN), Feedforward Neural Networks (FNN), dan Long Short-Term Memory (LSTM) menjadi model yang sering digunakan dalam klasifikasi citra medis. CNN terkenal karena kemampuannya dalam mengekstraksi fitur dari citra secara otomatis dan hierarkis, yang membuatnya sangat cocok untuk tugas-tugas seperti deteksi tumor dan segmentasi organ [5]. FNN, meskipun lebih sederhana, dapat digunakan untuk memproses data tabular dan numerik untuk prediksi berbasis klasifikasi, meskipun memiliki keterbatasan dalam mengatasi data citra yang kompleks [6]. Sementara itu, LSTM, sebagai jaringan saraf rekuren (RNN), memiliki kemampuan untuk memproses data yang bersifat temporal, yang sangat berguna dalam analisis citra medis yang diperoleh dalam urutan waktu atau sekuensial, seperti video ultrasonografi atau citra CT [7].

Meskipun masing-masing model deep learning ini memiliki keunggulannya, perbandingan langsung kinerjanya dalam klasifikasi fibrosis hati masih terbatas. CNN sering dipilih untuk tugas klasifikasi citra medis karena kemampuannya yang sangat baik dalam menangani data spasial yang kompleks, meskipun membutuhkan dataset besar dan waktu pelatihan yang lebih lama [8]. Di sisi lain, FNN lebih mudah diimplementasikan dan cocok untuk data tabular yang lebih sederhana, meskipun tidak dapat mengatasi ekstraksi fitur spasial yang lebih kompleks dalam citra [6]. LSTM, dengan kemampuan untuk mengingat informasi dari urutan data, mungkin memberikan keuntungan pada kasus-kasus yang melibatkan analisis temporal, namun aplikasi LSTM pada citra medis masih terbatas dan memerlukan penelitian lebih lanjut [7].

Berbagai penelitian telah mengkaji penerapan pembelajaran mesin dalam analisis gambar medis, khususnya dalam diagnosis penyakit hati. Sebagai contoh, penelitian oleh Wu et al. mengusulkan penggunaan jaringan saraf konvolusional (CNN) yang telah dilatih sebelumnya untuk klasifikasi gambar ultrasound standar hati (LUSP). Pendekatan ini terbukti efektif dalam meningkatkan akurasi klasifikasi dengan hasil mencapai 97%, sehingga mengurangi ketergantungan pada keterampilan operator dan meningkatkan efisiensi diagnosis gambar ultrasound hati. Dengan demikian, teknologi ini menawarkan potensi besar dalam meningkatkan kualitas dan kecepatan diagnosis di lingkungan klinis [9].

Di sisi lain, Iacob et al. menerapkan metode pembelajaran transfer pada gambar ultrasound untuk mendeteksi steatosis hati, dengan hasil yang sangat memuaskan, mencapai akurasi klasifikasi sebesar 92%. Penggunaan pembelajaran transfer memungkinkan penerapan model yang telah dilatih pada dataset besar untuk dataset yang lebih kecil, menghemat waktu pelatihan dan meningkatkan akurasi deteksi. Pendekatan ini sangat relevan dalam menghadapi tantangan deteksi penyakit hati non-alkohol (NAFLD), yang dapat membantu dalam pencegahan dan pengelolaan penyakit hati dengan cara yang lebih cepat dan efisien [10].

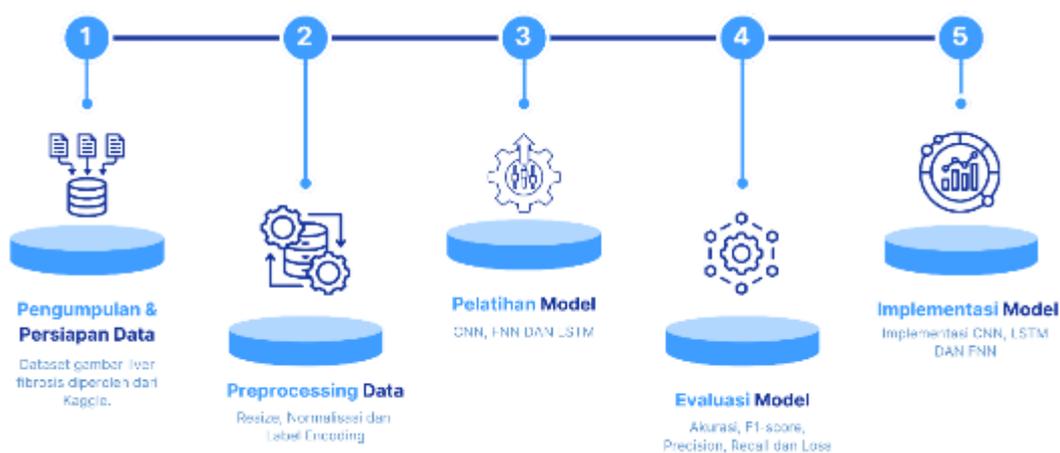
Selain itu, Jabbar et al. mengembangkan pendekatan hibrid yang menggabungkan beberapa algoritma pembelajaran mesin untuk mendeteksi dan mengklasifikasikan fibrosis hati, dengan hasil akurasi lebih dari 90%. Mereka menunjukkan bahwa kombinasi teknik seperti pohon keputusan, algoritma genetika, dan jaringan saraf tiruan dapat menghasilkan model yang lebih akurat dibandingkan dengan metode tunggal. Pendekatan hibrid ini membuka peluang untuk

mengembangkan sistem diagnosis yang lebih efektif dan efisien dalam mendeteksi berbagai kondisi hati, memberikan kontribusi besar dalam bidang kedokteran untuk diagnosis penyakit hati yang lebih baik dan otomatis [11].

Penelitian ini bertujuan untuk membandingkan kinerja model CNN, FNN, dan LSTM dalam klasifikasi fibrosis hati menggunakan citra medis. Evaluasi kinerja model akan dilakukan berdasarkan metrik-metrik utama seperti akurasi, presisi, recall, dan F1-score, untuk menentukan model yang paling efektif dalam mendeteksi fibrosis hati. Selain itu, penelitian ini akan mengidentifikasi kelebihan dan kekurangan masing-masing model dalam konteks aplikasi medis, serta menilai tantangan yang ada dalam penerapan deep learning untuk deteksi penyakit hati. Diharapkan penelitian ini dapat memberikan wawasan lebih lanjut mengenai penggunaan teknologi deep learning dalam bidang kedokteran, khususnya untuk diagnosis penyakit fibrosis hati.

## 2. METODE PENELITIAN

Alur proses penelitian ini ditampilkan pada Gambar 1 Proses dimulai dengan pengumpulan dan data, kemudian dilanjutkan dengan preprocessing data, pelatihan model, evaluasi model CNN, LSTM dan FNN, dan diakhiri dengan implementasi model.



Gambar 1 Flowchart Klasifikasi Penyakit Hati Fibrosis

### 2.1 Pengumpulan dan Persiapan Data

Dataset yang digunakan dalam penelitian ini diperoleh dari platform Kaggle, yang berisi citra ultrasonografi (ultrasound) yang digunakan untuk mendiagnosis penyakit hati fibrosis. Dataset ini terdiri dari lima kelas yang mewakili tingkat keparahan fibrosis hati, mulai dari f0 yang menunjukkan kondisi hati normal, hingga f4 yang menggambarkan tingkat fibrosis hati yang paling parah. Citra-citra tersebut digunakan untuk melakukan klasifikasi berdasarkan tingkat keparahan penyakit, yang menjadi fokus utama dalam analisis ini.

### 2.2 Preprocessing Data

Pre-processing adalah serangkaian teknik yang digunakan untuk mempersiapkan dan memodifikasi data citra sebelum diproses lebih lanjut oleh model atau algoritma. Tujuan utama dari tahap ini adalah untuk meningkatkan kualitas citra, mengurangi keberadaan noise, memperbaiki kontras, menyesuaikan dimensi citra, serta menghilangkan elemen-elemen yang tidak relevan atau dapat mengganggu hasil analisis. Pre-processing bertujuan untuk memastikan bahwa data citra yang digunakan dalam proses pelatihan model memiliki kualitas yang optimal untuk menghasilkan prediksi yang akurat [12].

#### 2.2.1 Resize Data

Proses pengubahan ukuran (resize) citra dalam dataset dilakukan dengan memperkecil dimensi citra, bertujuan untuk mengurangi kompleksitas data dan mempercepat waktu

pemrosesan. Hal ini memungkinkan model untuk lebih efisien dalam melakukan analisis, tanpa mengorbankan informasi yang relevan untuk klasifikasi atau deteksi [13].

### 2.2.2 Normalisasi Gambar

Normalisasi merupakan proses penskalaan citra yang bertujuan untuk menyesuaikan rentang nilai piksel citra, sehingga dapat meningkatkan efisiensi dan akurasi dalam proses pengenalan citra. Pada tahap ini, resolusi citra dikurangi dengan metode penskalaan, yang memfasilitasi pemrosesan data yang lebih cepat dan mendukung peningkatan kinerja model dalam mengenali pola yang ada pada citra [14].

### 2.2.3 Label Encoding

Label Encoding adalah teknik dalam pemrosesan data yang digunakan untuk mengubah data kategorikal menjadi bentuk numerik, dengan memberikan nilai integer yang unik pada setiap kategori [15].

## 2.3 Pelatihan Model

Tahapan pelatihan model ini, dataset citra penyakit liver fibrosis ini dilakukan pelatihan dengan menggunakan tiga model dari deep learning yaitu CNN, LSTM dan FNN. Model-model tersebut dilatih guna mengenali pola dan fitur penting dari citra untuk mengklasifikasikan penyakit liver fibrosis.

### 2.3.1 Convolutional Neural Network (CNN)

CNN (Convolutional Neural Network) adalah jenis arsitektur jaringan saraf dalam deep learning yang paling banyak digunakan untuk analisis citra atau data yang memiliki struktur grid (seperti gambar atau video). CNN dirancang untuk meniru cara otak manusia memproses gambar. CNN secara khusus unggul dalam tugas-tugas pengenalan pola, klasifikasi gambar, dan segmentasi citra [16].

$$f_j^l = \sigma(\sum_{m=1}^M W_{jm}^l X f_m^{l-1} + b^l) \quad (1)$$

Rumus tersebut menggambarkan proses konvolusi dalam Convolutional Neural Network (CNN), di mana setiap nilai pada feature map ( $f_j^l$ ) diperoleh dengan menggabungkan bobot kernel ( $W_{jm}^l$ ) dan input dari lapisan sebelumnya ( $f_m^{l-1}$ ), ditambah dengan bias ( $b^l$ ), kemudian diteruskan melalui fungsi aktivasi non-linear ( $\sigma$ ), seperti ReLU. Operasi ini berfungsi untuk mengekstraksi fitur-fitur dari data, seperti pola tepi, tekstur, atau objek dalam gambar, yang kemudian dapat digunakan untuk tujuan klasifikasi. Proses ini diulang pada setiap lapisan konvolusi, menghasilkan feature map yang semakin kompleks dan mendalam [17].

### 2.3.2 Long Short-Term Memory (LSTM)

LSTM (Long Short-Term Memory) adalah jenis jaringan saraf berulang (RNN) yang dirancang untuk mengatasi masalah vanishing gradient pada jaringan saraf tradisional, terutama dalam memproses urutan data atau data sekuensial. LSTM dapat mengingat informasi dalam jangka panjang dan menghindari hilangnya informasi penting pada urutan panjang, yang sering menjadi masalah pada RNN biasa [18].

$$h_t = o_t * \tanh(C_t) \quad (2)$$

Rumus ini menggambarkan cara menghitung output hidden state ( $h_t$ ) pada waktu ( $t$ ) dalam LSTM. Output dihitung berdasarkan output gate ( $o_t$ ) dan cell state ( $C_t$ ), yang telah diproses dengan fungsi aktivasi tanh. Cell state ( $C_t$ ), menyimpan informasi jangka panjang, sementara output gate ( $o_t$ ) mengontrol bagian dari informasi yang diteruskan ke output, memungkinkan

LSTM untuk mengatasi masalah vanishing gradient dan mempertahankan informasi penting dalam data urutan Panjang [19].

### 2.3.3 Feedforward Neural Network (FNN)

FNN (Feedforward Neural Network) adalah jenis jaringan saraf yang paling sederhana dan paling dasar dalam arsitektur deep learning. FNN beroperasi dengan cara mengalirkan informasi dari lapisan input menuju lapisan output melalui lapisan tersembunyi (hidden layers) tanpa adanya umpan balik (feedback). Dalam FNN, informasi mengalir satu arah (feedforward) dari input ke output.

$$f(x_t, v, w) = g_2\left\{\sum_{j=0}^m v_j g_1\left[\sum_i^p w_{ji} x_{it}\right]\right\} \quad (3)$$

Pada rumus tersebut, ( $W$ ) merupakan vektor bobot yang menghubungkan lapisan input dengan lapisan tersembunyi, sementara ( $V$ ) adalah vektor bobot yang menghubungkan lapisan tersembunyi dengan lapisan output (respons). Fungsi aktivasi  $g_1(\cdot)$  dan  $g_2(\cdot)$  digunakan untuk memodifikasi data di setiap lapisan. Selain itu,  $w_{ji}$  dan  $v_j$  adalah bobot yang diperoleh melalui proses pembelajaran menggunakan algoritma backpropagation [20].

## 2.4 Evaluasi Model

PEvaluasi model dilakukan untuk mengukur kinerja ketiga algoritma CNN, LSTM dan FNN dalam klasifikasi penyakit hati fibrosis menggunakan sejumlah metrik, yaitu akurasi, precision, recall dan F1-score serta loss.

### 2.4.1 Akurasi

Akurasi mengukur frekuensi prediksi benar yang dihasilkan oleh model dari keseluruhan prediksi yang dibuat, dengan TP sebagai true positive, TN sebagai true negative, FP sebagai false positive, dan FN sebagai false negative. Persamaan untuk akurasi dapat dilihat pada Persamaan (4) dibawah ini [21].

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

### 2.4.2 Recall

Recall adalah persentase data yang positif dan akurat dibandingkan dengan total data yang positif, benar, atau tidak akurat. Persamaan (5) memiliki kemampuan untuk menghitung nilai recall [21].

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

### 2.4.3 Precision

Precision mengukur ketepatan prediksi positif yang dihasilkan oleh model dengan mengesampingkan prediksi positif yang salah yang dapat dilihat pada persamaan (6) dibawah ini [22].

$$Precesion = \frac{TP}{TP+FP} \quad (6)$$

### 2.4.4 F1 – Score

F1-Score merupakan rata-rata harmonis antara precision dan recall, yang memberikan keseimbangan antara kedua matrik tersebut yang dapat dilihat pada persamaan (7) dibawah ini [23].

$$F1 - Score = 2x \frac{Precesion \times Recall}{Precesion + Recal} \quad (7)$$

## 2.5 Implementasi Model

Setelah proses pelatihan dan evaluasi model deep learning selesai dilakukan, langkah berikutnya adalah mengimplementasikannya secara sederhana untuk membandingkan performa

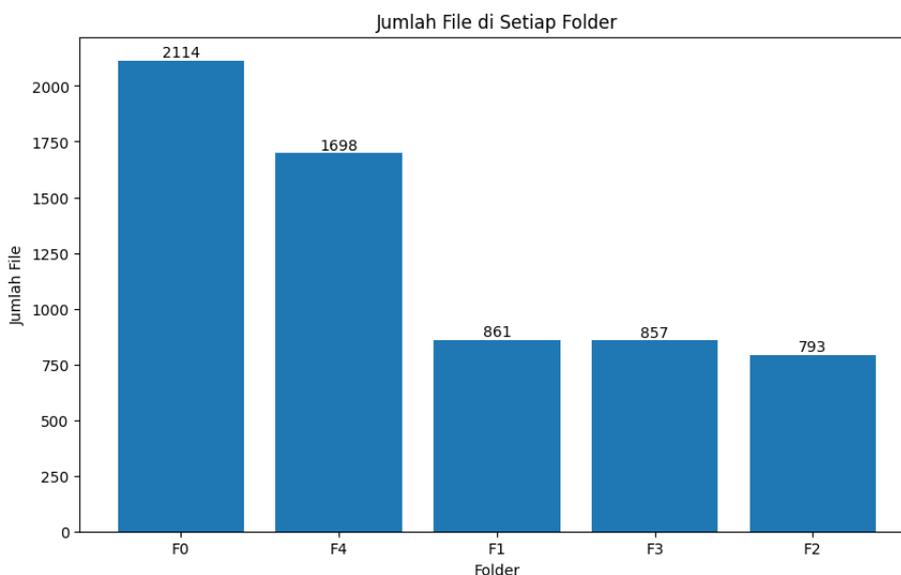
ketiga algoritma yang digunakan, yaitu CNN, LSTM, dan FNN. Perbandingan dilakukan dengan skenario yang dirancang khusus agar setiap algoritma diuji dalam lingkungan dan data yang sama. Hal ini bertujuan untuk memastikan hasil evaluasi yang adil dan konsisten, sehingga dapat ditentukan algoritma yang paling akurat dalam memprediksi penyakit liver fibrosis berdasarkan citra medis.

### 3. HASIL DAN PEMBAHASAN

Pada bagian ini, akan dijelaskan secara komprehensif mengenai setiap tahapan yang dilakukan dalam penelitian ini. Penelitian ini menggunakan bahasa pemrograman Python dan diimplementasikan melalui platform Google Colab

#### 3.1 Pengumpulan dan Persiapan Data

Dataset yang digunakan dalam penelitian ini diperoleh dari platform Kaggle yang dapat diakses melalui URL <https://www.kaggle.com/datasets/vibhingupta028/liver-histopathology-fibrosis-ultrasound-images/data>. Dataset ini merupakan penelitian yang dilakukan oleh Y. Joo, H.-C. Park, O.-J. Lee, C. Yoon, M. H. Choi, dan C. Choi. Dataset ini mencakup gambar ultrasonografi (US) yang diperoleh dari sebuah rumah sakit universitas tersier (Seoul St. Mary’s Hospital) untuk keperluan pelatihan dan validasi. Sementara itu, data dari rumah sakit universitas lain (Eunpyeong St. Mary’s Hospital) digunakan untuk pengujian [24]. Dataset ini terdiri dari lima kelas yang menggambarkan tingkat keparahan fibrosis hati, yaitu: F0 (Tanpa Fibrosis) yang menunjukkan hati sehat tanpa fibrosis, F1 (Fibrosis Portal) yang menunjukkan fibrosis di sekitar area portal hati, F2 (Fibrosis Periportal) yang menggambarkan fibrosis di sekitar tepi area portal hati, F3 (Fibrosis Septal) yang menunjukkan fibrosis yang membentuk pita atau septa dalam jaringan hati dan F4 (Sirosis) yang merupakan tahap fibrosis paling parah ditandai dengan jaringan parut yang luas dan kehilangan fungsi hati. Total dataset ini berjumlah 6323 gambar.. Gambar 2 merupakan distribusi jumlah dari masing – masing kelas dan gambar 3 merupakan contoh dari gambar masing – masing kelas.



Gambar 2 Distribusi masing – masing kelas dari Fibrosis Hati

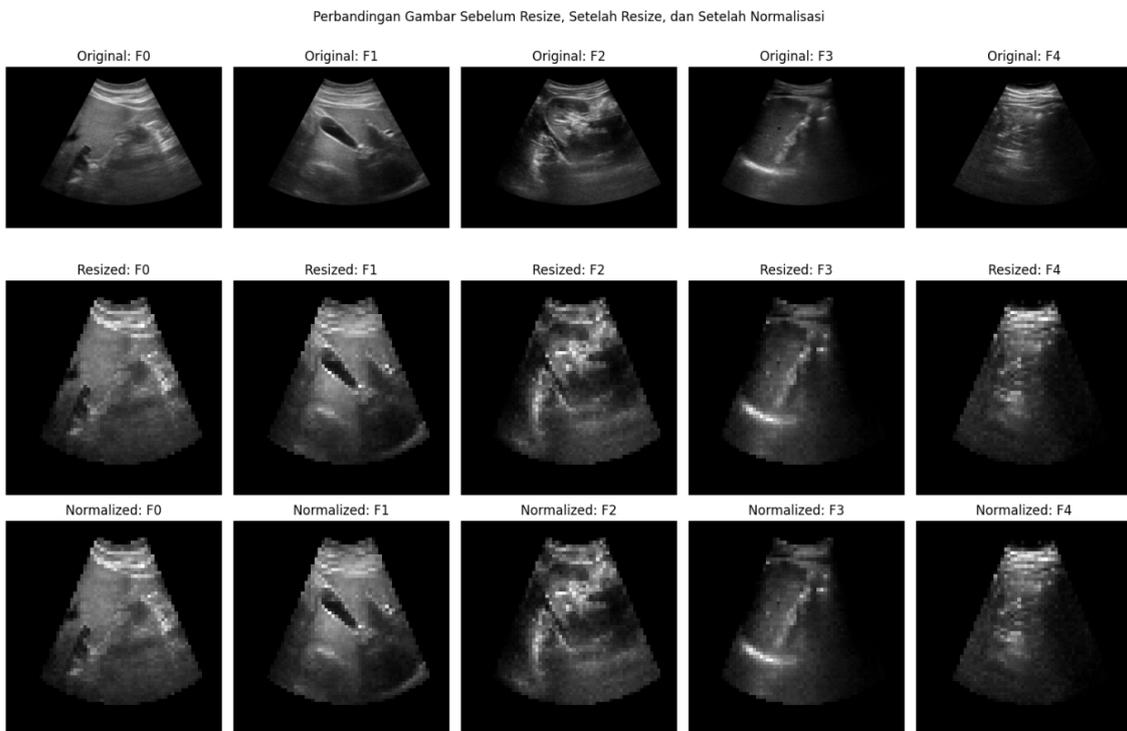
Gambar 2 menggambarkan distribusi tingkat keparahan fibrosis hati berdasarkan jumlah gambar di setiap kelas. Kelas dengan jumlah gambar terbanyak adalah F0 (Tanpa Fibrosis) sebanyak 2114 gambar, sementara kelas dengan jumlah gambar paling sedikit adalah F2 (Fibrosis Periportal) dengan 793 gambar.



Gambar 3 Menampilkan Gambar Setiap Kelas Fibrosis Hati

### 3.2 Preprocessing Data

Setelah tahap pengumpulan dan persiapan data, langkah berikutnya adalah tahap preprocessing, yang bertujuan untuk mempersiapkan data agar siap digunakan dalam pelatihan model. Proses ini melibatkan berbagai teknik seperti resize, normalisasi gambar dan label encoding.



Gambar 4 Resize Image dan Normalisasi

Gambar 4 menggambarkan tahapan preprocessing data untuk model deep learning, yaitu FNN, CNN, dan LSTM, yang mencakup perubahan ukuran gambar dan normalisasi. Citra asli diubah ukurannya menjadi 64x64 piksel untuk memastikan konsistensi dan efisiensi dalam pemrosesan. Kemudian, dimensi saluran ditambahkan agar sesuai dengan format input yang dibutuhkan oleh model deep learning, khususnya CNN yang memerlukan data dalam bentuk berdimensi tiga. Selanjutnya, normalisasi dilakukan dengan membagi setiap nilai piksel dengan 255, yang mengubah rentang nilai piksel menjadi antara 0 hingga 1. Proses ini bertujuan untuk meningkatkan stabilitas numerik, mempercepat proses konvergensi, serta memastikan model dapat lebih efektif dalam mempelajari pola-pola kompleks yang terdapat dalam citra medis.

```
Contoh label asli:  
['f0' 'f0' 'f0' 'f0' 'f0']  
  
Contoh label setelah encoding:  
[0 0 0 0 0]
```

Gambar 5 Label Encoding

Pada Gambar 5, dilakukan tahap label encoding untuk mengonversi label kategori menjadi nilai numerik. Setiap kategori yang semula berupa string, seperti "f0", "f1", "f2", "f3", dan "f4", diubah menjadi angka unik, yaitu 0, 1, 2, 3, dan 4. Gambar tersebut menunjukkan contoh output untuk kelas "f0".

### 3.3 Pelatihan Model

Pada pelatihan model CNN, FNN, dan LSTM, jumlah epoch ditentukan untuk melatih model hingga mencapai konvergensi. Selama proses pelatihan, teknik early stopping diterapkan untuk menghentikan pelatihan jika tidak ada peningkatan signifikan pada akurasi model di data validasi setelah beberapa epoch, sehingga mencegah overfitting.

```
lstm_model = Sequential([  
    LSTM(64, input_shape=(64, 64), return_sequences=True),  
    Flatten(),  
    Dense(64, activation='relu'),  
    Dense(total_classes, activation='softmax')  
])
```

Gambar 6. Arsitektur Model LSTM

Pada Gambar 6, arsitektur model LSTM memiliki input berukuran 64 x 64 pixel, dimulai dengan lapisan LSTM berisi 64 unit untuk menangkap informasi temporal dalam data. Hasilnya diratakan menggunakan lapisan Flatten, kemudian diproses oleh lapisan Dense dengan 64 neuron dan fungsi aktivasi relu.

```
cnn_model = Sequential([  
    Conv2D(32, (3, 3), activation='relu', input_shape=(64, 64, 1)),  
    MaxPooling2D(pool_size=(2, 2)),  
    Dropout(0.25),  
  
    Conv2D(64, (3, 3), activation='relu'),  
    MaxPooling2D(pool_size=(2, 2)),  
    Dropout(0.25),  
  
    Conv2D(128, (3, 3), activation='relu'),  
    MaxPooling2D(pool_size=(2, 2)),  
    Dropout(0.25),  
  
    Flatten(),  
    Dense(128, activation='relu'),  
    Dropout(0.5),  
    Dense(total_classes, activation='softmax')  
])
```

Gambar 7. Arsitektur Model CNN

Pada Gambar 7, model CNN menerima input gambar 64 x 64 piksel dengan satu channel. Model ini terdiri dari tiga blok konvolusi, masing-masing diikuti oleh MaxPooling2D dan Dropout untuk mengurangi overfitting. Setelah itu, output diratakan dengan Flatten dan diproses melalui lapisan Dense dengan 128 neuron dan aktivasi ReLU

```
fnn_model = Sequential()

# Flattening input image
fnn_model.add(Flatten(input_shape=(64, 64, 1)))

# Menambahkan layer hidden pertama
fnn_model.add(Dense(32, activation='relu'))
fnn_model.add(Dropout(0.25))

# Menambahkan layer hidden kedua
fnn_model.add(Dense(64, activation='relu'))
fnn_model.add(Dropout(0.25))

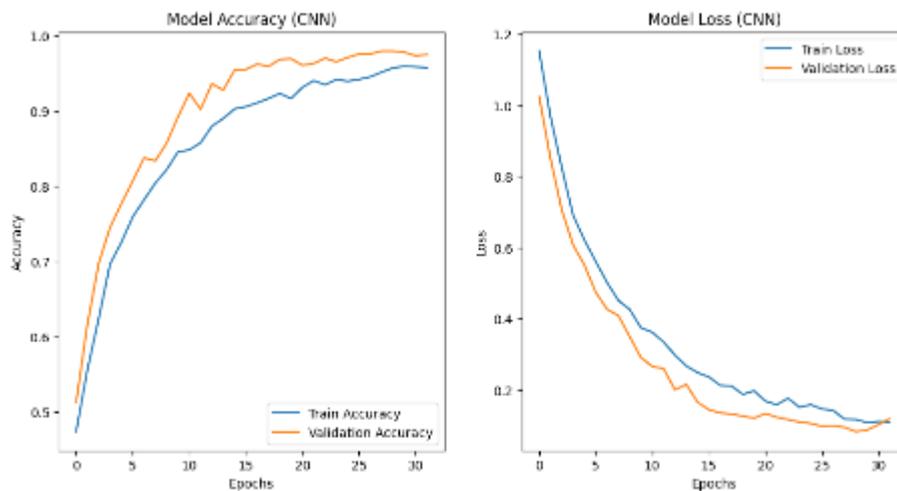
# Menambahkan layer hidden ketiga
fnn_model.add(Dense(128, activation='relu'))
fnn_model.add(Dropout(0.25))

# Menambahkan layer Dense sebelum output layer
fnn_model.add(Dense(128, activation='relu'))
fnn_model.add(Dropout(0.5))

# Output layer dengan softmax untuk 5 kelas
fnn_model.add(Dense(len(categories), activation='softmax'))
```

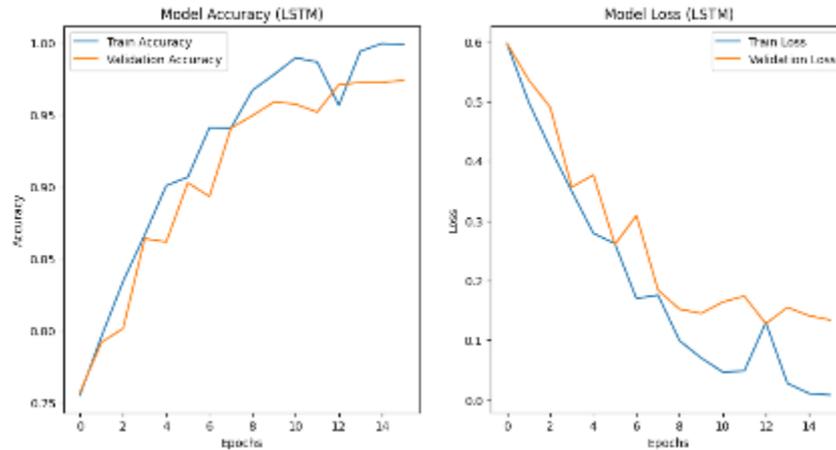
Gambar 8. Arsitektur Model FNN

Pada Gambar 8, model Feedforward Neural Network (FNN) menerima input gambar 64 x 64 piksel dengan satu channel. Model ini terdiri dari empat lapisan Dense berturut-turut dengan 32, 64, 128, dan 128 neuron, masing-masing menggunakan aktivasi ReLU, diikuti oleh Dropout untuk mencegah overfitting.



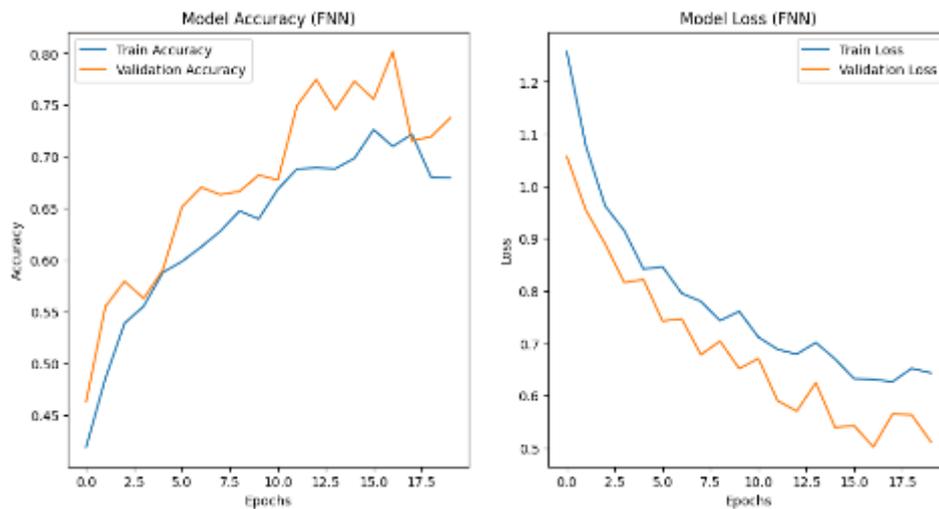
Gambar 9 Grafik Accuracy dan Loss Model CNN

Dalam gambar 9 grafik Model CNN menunjukkan performa yang sangat baik dengan training accuracy dan validation accuracy yang meningkat stabil hingga mencapai sekitar 98% pada epoch ke-30, didukung oleh loss yang terus menurun hingga 0.0833. Validation loss yang lebih rendah dibandingkan training loss menunjukkan model memiliki generalisasi yang baik tanpa tanda-tanda overfitting. Dengan kemampuan ini, CNN terbukti optimal untuk klasifikasi fibrosis hati pada dataset yang digunakan.



Gambar 10 Grafik Accuracy dan Loss Model LSTM

Berdasarkan gambar 10 grafik performa model LSTM, model menunjukkan peningkatan akurasi baik pada data pelatihan maupun validasi hingga mencapai lebih dari 97% pada akhir epoch ke-16. Kurva akurasi untuk pelatihan dan validasi relatif stabil dan konvergen, menunjukkan tidak adanya indikasi overfitting. Sementara itu, kurva loss untuk pelatihan dan validasi terus menurun hingga mencapai nilai yang rendah, meskipun pada beberapa epoch terakhir, validation loss sedikit fluktuatif. Hal ini menunjukkan bahwa model mampu belajar dengan baik dari data tanpa kehilangan kemampuan generalisasi. Secara keseluruhan, model LSTM memiliki performa yang optimal pada tugas klasifikasi dengan data ini.



Gambar 11 Grafik Accuracy dan Loss Model FNN

Pada grafik gambar 11 model FNN gambar 12 yang telah dilatih dengan menerapkan early stopping menunjukkan performa yang optimal hingga epoch ke-17, dengan akurasi validasi mencapai sekitar 80% dan penurunan loss validasi yang konsisten. Meski terdapat sedikit fluktuasi akurasi pada tahap akhir pelatihan, model berhasil menghindari overfitting secara signifikan. Hasil ini mengindikasikan bahwa model telah mencapai keseimbangan yang baik antara pembelajaran data pelatihan dan kemampuan generalisasi pada data validasi.

### 3.4 Evaluasi Model

Pada tahap evaluasi model, kinerja model CNN, FNN, dan LSTM dalam klasifikasi fibrosis hati dianalisis menggunakan berbagai metrik evaluasi, yaitu accuracy, precision, recall, F1-score, dan loss untuk mengukur performa setiap model secara komprehensif dan menentukan model

yang paling efektif dalam melakukan klasifikasi. Langkah pertama evaluasi model adalah pembagian data menjadi training dan testing.

Tabel 1 Distribusi Data Setelah Pembagian

DATA TRAINING	DATA TESTING
5058	1265

Tabel 1 merupakan jumlah distribusi dataset setelah dilakukan pembagian data dengan komposisi 80% dan 20% yaitu training dengan jumlah 5058 dan testing 1265.

```

Classification Report for CNN Model:
      precision    recall  f1-score   support

 F0       1.00      1.00      1.00     423
 F3       0.94      0.98      0.96     171
 F4       1.00      1.00      1.00     340
 F2       0.96      0.94      0.95     159
 F1       0.96      0.94      0.95     172

 accuracy                0.98     1265
 macro avg              0.97     1265
 weighted avg           0.98     1265
    
```

Gambar 12 Classification Report Model CNN

Setelah pembagian data, selanjutnya dilakukan evaluasi terhadap kinerja setiap model. Berdasarkan Gambar 12, model CNN menunjukkan performa yang sangat baik dengan akurasi sekitar 98%. Precision mencapai 97%, recall 97%, dan F1-Score 97%. Hasil ini mengindikasikan keseimbangan yang sangat baik antara semua kelas, yang menunjukkan bahwa model berhasil mencapai kesetimbangan optimal antara Precision dan Recall.

```

Classification Report for LSTM Model:
      precision    recall  f1-score   support

 F0       1.00      1.00      1.00     423
 F3       0.93      0.98      0.95     171
 F4       0.97      1.00      0.99     340
 F2       0.92      0.91      0.92     159
 F1       0.98      0.89      0.93     172

 accuracy                0.97     1265
 macro avg              0.96     1265
 weighted avg           0.97     1265
    
```

Gambar 13 Classification Report Model LSTM

Berdasarkan Gambar 13, model LSTM menunjukkan kinerja yang sangat baik dengan akurasi sekitar 97%. Precision mencapai 96%, recall 96%, dan F1-Score 96%. Hal ini menunjukkan hasil yang seimbang antara semua kelas menunjukkan bahwa model memiliki keseimbangan yang baik antara Precision dan Recall.

Classification Report for FNN Model:

	precision	recall	f1-score	support
F0	1.00	0.99	1.00	423
F1	0.85	0.81	0.83	172
F2	0.36	0.34	0.35	159
F3	0.53	0.58	0.55	171
F4	0.87	0.89	0.88	340
accuracy			0.80	1265
macro avg	0.72	0.72	0.72	1265
weighted avg	0.80	0.80	0.80	1265

Gambar 14 Classification Report Model FNN

Berdasarkan Gambar 14, model FNN menunjukkan kinerja yang sangat baik dengan akurasi sekitar 80%. Precision mencapai 72%, recall 72%, dan F1-Score 72%. Hal ini menunjukkan hasil yang seimbang meskipun model FNN menjadi yang terendah dari model lainnya.

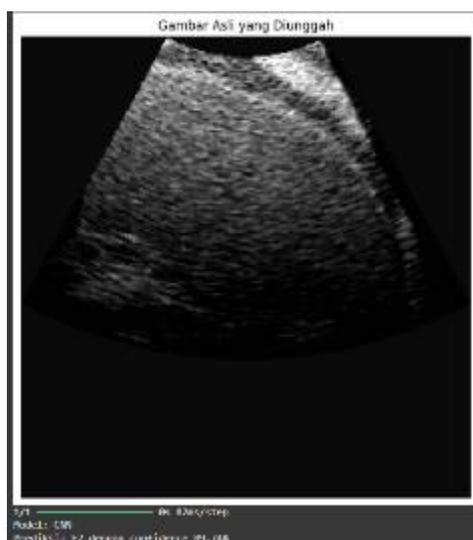
Tabel 2 Perbandingan Ketiga Model Deep Learning

Nama Model	Accuracy	Precision	Recall	F1 Score	Loss
CNN	98%	97%	97%	97%	0.0833
LSTM	97%	96%	96%	96%	0.1276
FNN	80%	72%	72%	72%	0.5019

Dalam tabel 2 perbandingan ini, tiga model deep learning FNN, CNN, dan LSTM dibandingkan untuk klasifikasi fibrosis hati. Hasil menunjukkan bahwa CNN memberikan performa terbaik dengan accuracy 98%, precision, recall, dan F1 score masing-masing sebesar 97%, serta loss terendah (0.0833). LSTM berada di peringkat kedua dengan accuracy 97% dan metrik lainnya sebesar 96%, sementara FNN menunjukkan performa terendah dengan accuracy hanya 80% dan loss tertinggi (0.5019).

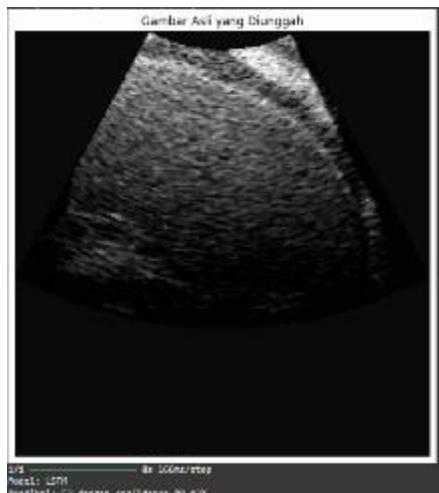
### 3.5 Implementasi Model

Tahap implementasi dimulai setelah diperoleh hasil dari perbandingan akurasi masing-masing model, yaitu CNN, LSTM, dan FNN. Perbandingan ini dilakukan untuk menentukan model yang paling optimal berdasarkan performa dalam memprediksi data uji. Implementasi dilakukan dengan dataset gambar yang sama untuk memastikan konsistensi dalam evaluasi kinerja ketiga model.



Gambar 15 Implementasi Model CNN

Gambar 15 menunjukkan hasil prediksi menggunakan model CNN untuk mendeteksi liver fibrosis. Prediksi menunjukkan bahwa data tersebut diklasifikasikan sebagai kelas F2 dengan tingkat kepercayaan 89.74%.



Gambar 16 Implementasi Model LSTM

Gambar 16 menunjukkan hasil prediksi menggunakan model LSTM untuk mendeteksi liver fibrosis. Prediksi menunjukkan bahwa data tersebut diklasifikasikan sebagai kelas F2 dengan tingkat kepercayaan 89.42%.



Gambar 17 Implementasi Model FNN

Gambar 17 menunjukkan hasil prediksi menggunakan model FNN untuk mendeteksi liver fibrosis. Prediksi menunjukkan bahwa data tersebut diklasifikasikan sebagai kelas F2 dengan tingkat kepercayaan 48.86%. Dari ketiga model tersebut, FNN memiliki tingkat kepercayaan paling rendah dalam memprediksi liver fibrosis. Dengan demikian, model CNN menunjukkan performa terbaik di antara ketiga algoritma, diikuti oleh LSTM, berdasarkan tingkat kepercayaan prediksi pada data ini.

#### 4. KESIMPULAN DAN SARAN

Penelitian ini membandingkan tiga model deep learning CNN, LSTM, dan FNN untuk klasifikasi fibrosis hati menggunakan citra medis. Hasilnya menunjukkan bahwa CNN memberikan kinerja terbaik dengan akurasi 98%, diikuti oleh LSTM dengan akurasi 97%, dan FNN dengan akurasi 80%. CNN unggul karena kemampuannya dalam mengekstraksi fitur spasial

dari citra medis secara otomatis dan hierarkis, membuatnya sangat efektif untuk tugas klasifikasi citra. Sebaliknya, LSTM meskipun baik dalam menangani data sekuensial, tidak dapat sepenuhnya memanfaatkan keunggulannya pada data citra yang bersifat spasial, sementara FNN menunjukkan performa yang kurang memadai pada dataset ini.

Dengan demikian, model CNN terbukti lebih unggul dibandingkan LSTM dan FNN dalam mendeteksi fibrosis hati, menjadikannya pilihan yang lebih efisien dan akurat untuk aplikasi medis, khususnya dalam deteksi dini penyakit hati. Temuan ini menunjukkan potensi deep learning dalam mempercepat diagnosis fibrosis hati secara non-invasif dan memberikan solusi alternatif yang lebih aman daripada prosedur biopsi konvensional.

#### UCAPAN TERIMA KASIH

Kami menyampaikan rasa terima kasih kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat (LPPM) Universitas Amikom Purwokerto atas dukungannya dalam pendanaan publikasi penelitian ini.

#### DAFTAR PUSTAKA

- [1] D. U. Hajarsari, "Evaluasi Fibrosis Hati Dengan USG, CT-Scan dan MR," *Cerdika J. Ilm. Indones.*, vol. 2, no. 9, pp. 837–846, 2022.
- [2] N. Roehlen, E. Crouchet, and T. E. Baumen, *Liver Fibrosis : Mechanistic Concepts and*, no. 9. 2020.
- [3] R. Masuzaki *et al.*, "Noninvasive assessment of liver fibrosis: Current and future clinical and molecular perspectives," *Int. J. Mol. Sci.*, vol. 21, no. 14, pp. 1–18, 2020.
- [4] A. Misbullah, W. Mursyida, L. Farsiah, and K. M. Sukiakhy, "Analisis Performa Segmentasi Citra MRI Tumor Otak dengan Arsitektur U-Net," vol. 2, no. 2, pp. 83–95, 2024.
- [5] F. Citra R, F. Indriyani, and I. R. Rahadjeng, "Klasifikasi Tumor Otak Berbasis Magnetic Resonance Imaging Menggunakan Algoritma Convolutional Neural Network," *Digit. Transform. Technol.*, vol. 3, no. 2, pp. 918–924, 2024.
- [6] Z. Chen *et al.*, "Using elastography-based multilayer perceptron model to evaluate renal fibrosis in chronic kidney disease," *Ren. Fail.*, vol. 45, no. 1, p. , 2023.
- [7] A. Azhie *et al.*, "A deep learning framework for personalised dynamic diagnosis of graft fibrosis after liver transplantation: a retrospective, single Canadian centre, longitudinal study," *Lancet Digit. Heal.*, vol. 5, no. 7, pp. e458–e466, 2023.
- [8] K. A. H. Wibowo and A. Alamsyah, "Klasifikasi Diabetic Retinopathy Menggunakan CNN dengan Arsitektur yang Dimodifikasi," *Indones. J. Math. Nat. Sci.*, vol. 46, no. 1, pp. 45–52, 2023.
- [9] J. Wu, P. Zeng, P. Liu, and G. Lv, "Automatic classification method of liver ultrasound standard plane images using pre-trained convolutional neural network," *Conn. Sci.*, vol. 34, no. 1, pp. 975–989, 2022.
- [10] E. C. Constantinescu *et al.*, "Transfer learning with pre-trained deep convolutional neural networks for the automatic assessment of liver steatosis in ultrasound images," *Med. Ultrason.*, vol. 23, no. 2, pp. 135–139, 2021.
- [11] Z. S. Jabbar, A. Q. Al-Neami, A. A. Khawwam, and S. M. Salih, "Liver fibrosis processing, multiclassification, and diagnosis based on hybrid machine learning approaches," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 29, no. 3, pp. 1614–1622, 2023.
- [12] A. M. Simarmata, A. Zizwan Putra, and A. Mahmud Husein, "Penerapan Metode Computer Vision Dalam Klasifikasi Buah Jeruk Menggunakan Teknik Image Pre-Processing," *Data Sci. Indones.*, vol. 3, no. 2, pp. 110–116, 2023.
- [13] L. Aumatullah, I. Ein, and M. M. Santoni, "Identifikasi Penyakit Daun Kentang Berdasarkan Fitur Tekstur dan Warna Dengan Menggunakan Metode K-Nearest Neighbor," *Semin. Nas. Mhs. Ilmu Komput. dan Apl.*, no. April, pp. 783–791, 2021.
- [14] I. Supiyani and N. Arifin, "Identifikasi Nomor Rumah Pada Citra Digital Menggunakan

- Neural Network,” *Method. J. Tek. Inform. dan Sist. Inf.*, vol. 8, no. 1, pp. 18–21, 2022.
- [15] A. R. Dana, R. V. Kristananda, M. Bagas, S. Wibowo, and D. A. Prasetya, “Perbandingan Algoritma Decision Tree dan Random Forest dengan Hyperparameter Tuning dalam Mendeteksi Penyakit Stroke,” vol. 4, pp. 66–75, 2024.
- [16] R. A. Mas’ud and Junta Zeniarja, “Optimasi Convolutional Neural Networks untuk Deteksi Kanker Payudara menggunakan Arsitektur DenseNet,” *Edumatic J. Pendidik. Inform.*, vol. 8, no. 1, pp. 310–318, 2024.
- [17] V. Praskatama, C. A. Sari, E. H. Rachmawanto, and N. Mohd Yaacob, “Pneumonia Prediction Using Convolutional Neural Network,” *J. Tek. Inform.*, vol. 4, no. 5, pp. 1217–1226, 2023.
- [18] Firmansyah, D. P. Rini, and Sukemi, “Klasifikasi Data Penderita Skizofrenia Menggunakan CNN-LSTM dan Cnn-Gru pada Data Sinyal EEG 2D,” *J. JTIK (Jurnal Teknol. Inf. dan Komunikasi)*, vol. 7, no. 4, pp. 642–650, 2023.
- [19] L. Zhou, C. Zhao, N. Liu, X. Yao, and Z. Cheng, “Improved LSTM-based deep learning model for COVID-19 prediction using optimized approach,” *Eng. Appl. Artif. Intell.*, vol. 122, no. March, p. 106157, 2023.
- [20] D. Aprillia, T. Rohana, T. Al Mudzakir, and D. Wahiddin, “KLIK: Kajian Ilmiah Informatika dan Komputer Deteksi Nominal Mata Uang Rupiah Menggunakan Metode Convolutional Neural Network dan Feedforward Neural Network,” *Media Online*, vol. 4, no. 4, pp. 2068–2077, 2024.
- [21] J. Anggraini and D. Alita, “Implementasi Metode SVM Pada Sentimen Analisis Terhadap Pemilihan Presiden (Pilpres) 2024 Di Twitter,” *J. Inform. J. Pengemb. IT*, vol. 9, no. 2, pp. 102–111, Aug. 2024.
- [22] S. Bahri, E. Utami, and A. Nasiri, “Classification of Public Complaints Basedon Text Mining Using Modified K-Nearest Neighbor, Naïve Bayes and C4.5 Algorithm,” *CCIT J.*, vol. 15, no. 2, pp. 198–207, Aug. 2022.
- [23] A. A. Kurniawan and M. Mustikasari, “Evaluasi Kinerja MLLIB APACHE SPARK pada Klasifikasi Berita Palsu dalam Bahasa Indonesia,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 3, p. 489, Jun. 2022.
- [24] Y. Joo, H. C. Park, O. J. Lee, C. Yoon, M. H. Choi, and C. Choi, “Classification of Liver Fibrosis From Heterogeneous Ultrasound Image,” *IEEE Access*, vol. 11, no. February, pp. 9920–9930, 2023.