

Klasifikasi Tulang Tengkorak Berdasarkan Jenis Kelamin Menggunakan Correlation-Based Feature Selection (CFS) dengan Backpropagation Neural Network (BPNN)

Laila Alfi Ma'rifah¹, Iis Afrianty², Elvia Budianita³, Fadhilah Syafria⁴

^{1,2,3,4} Program Studi Teknik Informatika, Universitas Islam Negeri Sultan Syarif Kasim Riau, Jl. HR Soebrantas Km. 15, Pekanbaru, 28293, Indonesia

Info Artikel

Riwayat Artikel:

Received 2025-03-26

Revised 2025-04-25

Accepted 2025-04-29

Abstract – In forensic anthropology, sex identification is a crucial initial step in individual identification, with a base probability of 50%, influencing subsequent examinations such as age and height estimation. The skull is considered the second-best skeletal element for sex determination after the pelvis, with an accuracy rate of up to 90%. However, morphological and metric methods are often unreliable due to the high variability of skulls, while DNA analysis becomes ineffective when bones are burned or severely damaged. This study aims to improve the accuracy of sex classification by combining Correlation-Based Feature Selection (CFS) and a Backpropagation Neural Network (BPNN). The dataset used was obtained from Dr. William Howells, consisting of 2,524 skull samples with 85 measured variables. Feature selection was conducted using CFS with two threshold values (0.1 and 0.01), followed by BPNN training using learning rates of 0.01 and 0.001 across three different network architectures adapted to the number of input neurons. Model validation was performed using k-fold cross-validation with $k = 10$. The results showed that applying CFS successfully increased classification accuracy from 92.06% to 93.25%, with the best performance achieved at a CFS threshold of 0.01, a learning rate of 0.001, and a BPNN architecture of [72; 95; 1]. This research contributes to the field of forensic informatics by introducing a feature selection and machine learning-based approach to enhance the accuracy of sex identification from skull data..

Keywords: Backpropagation Neural Network; Correlation-Based Feature Selection; Sex Classification; Skull.

Corresponding Author:

Iis Afrianty

Email: iis.afrianty@uin-suska.ac.id



This is an open access article under the [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/) license.

Abstrak – Pada antropologi forensik, identifikasi jenis kelamin merupakan langkah awal dalam identifikasi individu dengan tingkat probabilitas 50%, yang berpengaruh pada pemeriksaan lain seperti estimasi usia dan tinggi. Tulang tengkorak menjadi pilihan terbaik kedua setelah tulang panggul dalam menentukan jenis kelamin dengan akurasi hingga 90%. Namun, metode morfologi dan metrik kurang dapat diandalkan karena variabilitas tengkorak yang tinggi, sementara analisis DNA tidak efektif pada tulang yang terbakar atau rusak. Penelitian ini bertujuan meningkatkan akurasi klasifikasi jenis kelamin menggunakan kombinasi Correlation-Based Feature Selection (CFS) dan Backpropagation Neural Network (BPNN). Dataset yang digunakan berasal dari Dr. William Howells, terdiri dari 2.524 sampel tengkorak dengan 85 variabel. Seleksi fitur dilakukan dengan CFS menggunakan dua nilai threshold (0,1 dan 0,01), dan dengan pelatihan BPNN menggunakan learning rate 0,01 dan 0,001 pada tiga arsitektur jaringan yang disesuaikan dengan jumlah neuron input. Teknik validasi dilakukan menggunakan k-fold cross-validation dengan $k=10$. Hasil menunjukkan bahwa penerapan CFS mampu meningkatkan akurasi klasifikasi dari 92,06% menjadi 93,25% pada konfigurasi threshold CFS 0,01, learning rate 0,001, dan arsitektur BPNN [72; 95; 1]. Penelitian ini berkontribusi dalam bidang informatika forensik dengan memperkenalkan pendekatan berbasis seleksi fitur dan pembelajaran mesin untuk meningkatkan akurasi identifikasi jenis kelamin berdasarkan data tengkorak.

Kata Kunci: Backpropagation Neural Network, Correlation-Based Feature Selection, Klasifikasi Jenis Kelamin, Tulang Tengkorak

I. PENDAHULUAN

Antropologi forensik adalah cabang ilmu yang mempelajari sisa-sisa tulang, tengkorak, dan mumi untuk tujuan identifikasi individu [1]. Ilmu ini berperan penting dalam menentukan jumlah individu, membedakan antara tulang manusia dan bukan manusia, serta memperkirakan karakteristik fisik seperti *etnis*, *gender*, tinggi tubuh, dan umur dari sisa-sisa manusia yang belum teridentifikasi [2], [3]. Identifikasi forensik ini dapat diterapkan pada kasus individu tanpa identitas, jenazah yang telah membusuk, korban bencana alam, serta jenazah dengan bagian tubuh yang tidak lengkap [4].

Identifikasi jenis kelamin adalah tahap awal yang krusial dalam tahap identifikasi individu, sebab mampu meningkatkan probabilitas kecocokan hingga 50% serta memengaruhi metode pemeriksaan lainnya, seperti estimasi usia dan tinggi tubuh [2], [5]. Penentuan jenis kelamin biasanya dilakukan melalui analisis tulang seperti panggul, *humerus*, *tibia*, rahang bawah, dan tengkorak menjadi indikator utama. Tulang tengkorak dianggap sebagai salah satu tulang terbaik dalam menentukan jenis kelamin dengan akurasi hingga 90% setelah tulang

panggul [6], [7], [8]. Hal ini disebabkan oleh struktur jaringan keras yang tahan lama dan stabilitas fitur dimorfik seksual yang lebih jelas dibandingkan tulang lainnya [8], [9].

Proses identifikasi jenis kelamin dapat dilakukan menggunakan dua metode utama yaitu metode morfologi dan metrik [6], [8]. Metode morfologi mengandalkan observasi visual terhadap ciri fisik [3], [8], sementara metode metrik menggunakan pengukuran osteometrik seperti panjang, lebar, dan ketebalan tulang [3]. Meskipun kedua metode ini masih menjadi standar dalam identifikasi forensik, keduanya memiliki keterbatasan, yaitu variabilitas morfologi tinggi serta ketidakjelasan detail penanda seksual yang dapat mempengaruhi hasil akurasi [10]. Selain itu, metode analisis *Deoxyribose Nucleic Acid* (DNA) yang semakin berkembang juga memiliki kelemahan, terutama pada kasus tulang yang telah terbakar, tidak utuh, atau sangat kering, di mana ekstraksi DNA menjadi sangat sulit [6], [11], [12]. Metode DNA juga memerlukan biaya tinggi serta waktu analisis yang lebih lama, sehingga kurang dapat diandalkan dalam kondisi darurat seperti bencana massal atau kecelakaan besar [6], [13].

Perkembangan teknologi kecerdasan buatan telah membuka peluang baru dalam klasifikasi jenis kelamin berbasis tulang tengkorak sebagai solusi atas keterbatasan metode morfologi, metrik, dan analisis DNA. Salah satu teknik yang potensial adalah penerapan *Artificial Neural Networks* (ANN), khususnya *Backpropagation Neural Network* (BPNN), yang telah terbukti mampu mengolah data kompleks dengan tingkat akurasi tinggi [14]. Penelitian yang dilakukan oleh [15] menggunakan BPNN dalam klasifikasi jenis kelamin berdasarkan model tiga dimensi tengkorak, menghasilkan akurasi hingga 96,76%. Penelitian lain oleh [16] yang menggabungkan metode *metaheuristic* dengan BPNN menunjukkan bahwa klasifikasi jenis kelamin menggunakan berbagai bagian tulang utama, seperti *femur*, *humerus*, dan *tibia*, menghasilkan akurasi masing-masing sebesar 89,44%, 88,97%, dan 87,52%. Sementara itu, penelitian oleh [8] menggunakan BPNN untuk klasifikasi tulang tengkorak berdasarkan jenis kelamin, dengan akurasi tertinggi 92,32% pada satu lapisan tersembunyi dan 90,74% pada dua lapisan tersembunyi.

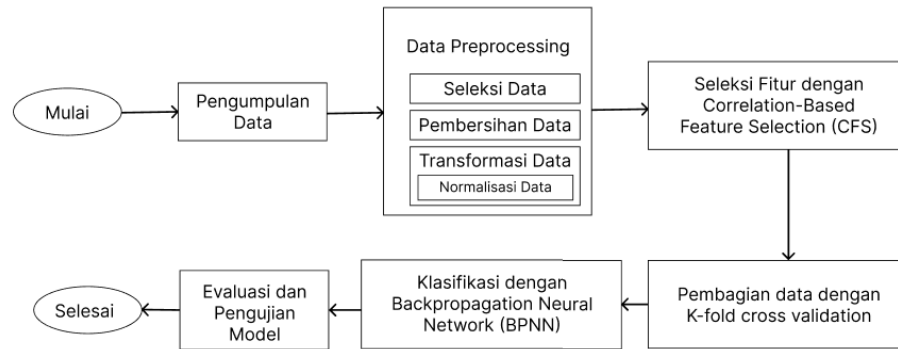
Pada kasus klasifikasi tulang tengkorak dengan jumlah fitur sangat besar, dapat mempengaruhi performa model dan menyebabkan waktu pembelajaran yang tinggi [17]. Oleh karena itu, teknik seleksi fitur menjadi solusi penting untuk mengeliminasi fitur yang tidak relevan dan meningkatkan akurasi model [18], [19], [20]. Salah satu teknik seleksi fitur yang telah diterapkan pada antropologi forensik adalah *Correlation-based Feature Selection* (CFS). Studi yang dilakukan oleh [21] menunjukkan bahwa kombinasi *Learning Vector Quantization 2* (LVQ 2) dengan CFS meningkatkan akurasi klasifikasi jenis kelamin berbasis tengkorak dari 77,05% menjadi 82,51%.

Beberapa penelitian lain juga menunjukkan kinerja seleksi fitur CFS dalam meningkatkan akurasi klasifikasi, baik dalam domain forensik maupun bidang lainnya. Penelitian yang dilakukan oleh [22] menggunakan CFS pada *Multilayer Perceptron Neural Networks* untuk prediksi pelanggan perbankan, menghasilkan akurasi tertinggi sebesar 80,5%. Selain itu, penelitian oleh [23] menunjukkan bahwa kombinasi CFS dengan berbagai algoritma klasifikasi, seperti *Sequential Minimal Optimization* (SMO), *Naïve Bayes*, *Multi-Layer Perceptron* (MLP), dan J48, meningkatkan akurasi dalam klasifikasi bentuk nodul kanker payudara menggunakan citra ultrasonografi.

Berbeda dengan penelitian sebelumnya, studi ini mengintegrasikan teknik seleksi fitur CFS dengan BPNN untuk memperbaiki akurasi klasifikasi jenis kelamin berdasarkan data kraniometri. Dengan mengimplementasikan CFS sebelum pelatihan BPNN, penelitian ini diharapkan mampu memperbaiki akurasi klasifikasi sekaligus mengurangi waktu proses, sehingga memberikan kontribusi pada pengembangan metode identifikasi forensik yang lebih cepat dan presisi.

II. METODE

Penelitian ini menerapkan metode seleksi fitur *Correlation-Based Feature Selection* (CFS) yang dipadukan dengan metode klasifikasi *Backpropagation Neural Network* (BPNN). Adapun Langkah-langkah dalam penelitian ini tersaji dalam Gambar 1.



Gambar 1. Tahapan penelitian menggunakan CFS dan BPNN

A. Pengumpulan Data

Pengumpulan data dilakukan menggunakan data sekunder yang diperoleh dari situs <https://web.utk.edu/~auerbach/HOWL.htm>, yang menyediakan dataset tulang tengkorak hasil kompilasi oleh Dr. William W. Howells. Dataset ini terdiri dari 2.524 data individu manusia yang berasal dari berbagai populasi dunia, terdiri atas 1.368 data berlabel *male* dan 1.156 data berlabel *female*. Data ini mewakili variasi morfologis dari tengkorak berdasarkan jenis kelamin. Dimensi kranimetri dalam dataset mencakup 85 fitur linier yang diperoleh melalui pengukuran langsung menggunakan kaliper. Pengukuran tersebut meliputi panjang, tali busur, *subtenses*, sudut, dan jari-jari tengkorak. Masing-masing fitur merupakan representasi numerik dari struktur morfometrik yang berbeda, seperti lebar orbital, panjang basis kranial, serta tinggi dan lebar wajah. Informasi detail mengenai fitur dan parameter yang digunakan dalam pengukuran disajikan dalam Tabel 1 dan Tabel 2.

TABEL 1
FITUR PARAMETER TULANG TENGGORAK

Kode	Fitur Parameter Tulang Tengkorak
GOL	Glabello-Occipital Length
NOL	Nasio-Occipital Length
BNL	Basion-Nasion Length
BBH	Basion-Bregma Height
XCB	Maximum Cranial Breadth
XFB	Maximum Frontal Breadth
ZYB	Bizygomatic Breadth
....	...
TBA	Thiobarbituric Acid

TABEL 2
PARAMETER PENGUKURAN TULANG TENGGORAK

ID	Sex	PopNum	Population	GOL	NOL	BNL	BBH	XCB	XFB	ZYB	...	TBA
1	M	1	NORSE	189	185	100	135	143	120	133	...	0
2	M	1	NORSE	182	178	102	139	145	120	137	...	0
3	M	1	NORSE	191	187	102	123	140	114	134	...	0
...
3188	F	24	ANDAMAN	160	160	89	121	129	106	117	...	156
3189	F	24	ANDAMAN	172	170	92	118	137	110	114	...	167
3190	F	24	ANDAMAN	153	153	88	116	130	105	115	...	158

Berdasarkan Tabel 2, ID tertinggi yang tercatat mencapai 3.190, sedangkan jumlah dataset yang digunakan sebanyak 2.524 sampel. Perbedaan ini disebabkan oleh hilangnya beberapa sampel dari sumber asli dataset, sehingga tidak semua ID dalam rentang tersebut memiliki data yang tersedia. Dengan demikian, jumlah sampel aktual lebih rendah dibandingkan dengan ID tertinggi yang tercatat.

B. Data Preprocessing

Tahap data *preprocessing* merupakan langkah yang sangat penting karena bertujuan untuk memproses data awal supaya data siap diolah oleh model. Proses ini dilakukan untuk meningkatkan kinerja model serta memastikan hasil yang akurat [24]. Tahap data *preprocessing* mencakup beberapa langkah sebagai berikut:

1) *Seleksi Data*: Langkah ini bertujuan untuk memilih fitur yang relevan guna menghindari redundansi atau duplikasi yang tidak diperlukan dalam pengolahan. Data yang telah diseleksi kemudian disimpan dalam *file* yang terpisah dari *database* operasional [25]. Pada penelitian ini, dilakukan penghapusan fitur ID dan *Population* dari

dataset. Penghapusan kedua fitur tersebut dilakukan karena ID hanya menjelaskan identifikasi unik untuk setiap data, sementara fitur *Population* hanya menjelaskan nama populasi yang telah dikodekan pada fitur *PopNum*. Selanjutnya, pemilihan fitur yang relevan akan dilakukan menggunakan *Correlation-based Feature selection* (CFS).

2) *Pembersihan Data*: Proses pembersihan data dilakukan guna mengatasi data yang hilang (*missing value*), *noise data*, serta memastikan konsistensi dan relevansi data [26]. Pada penelitian ini, dilakukan pemeriksaan terhadap duplikasi data dan data yang hilang. Jika ditemukan data yang duplikat dan data yang hilang, maka data tersebut akan dihapus guna memastikan kualitas dataset yang digunakan.

3) *Transformasi Data*: Langkah ini dilakukan untuk mengonversi data ke dalam format yang sesuai dengan model yang digunakan [27]. Bentuk data yang digunakan oleh model berupa data numerik, sehingga diperlukan transformasi pada data non-numerik. Pada penelitian ini, transformasi dilakukan pada fitur *Sex*, dimana *Male* dikonversi menjadi 1 dan *Female* dikonversi menjadi 0. Selain itu, pada tahap ini juga dilakukan normalisasi atau proses mengubah data agar data tidak memiliki jarak yang terlalu jauh (*outlayer*) antar data. Pada penelitian ini, normalisasi dilakukan menggunakan *Min-Max Normalization* dengan mengubah data menjadi skala antara 0 hingga 1. Persamaan (1) merupakan rumus yang digunakan untuk menghitung *Min-Max Normalization* [28].

$$x' = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (1)$$

Dimana x' adalah nilai yang sudah dinormalisasi, x_i adalah nilai asli dari suatu fitur, $\min(x)$ adalah nilai terendah dari suatu fitur, $\max(x)$ adalah nilai tertinggi dari suatu fitur

C. Correlation-based Feature selection

Correlation-based Feature Selection (CFS) menggunakan matriks korelasi untuk menilai hubungan antara fitur dan kelas target, sekaligus memastikan bahwa fitur-fitur yang dipilih tidak saling berkorelasi tinggi. Pada penelitian ini, untuk menghitung koefisien korelasi antara masing-masing fitur dan target dilakukan menggunakan *pearson correlation coefficient* dan selektor menggunakan *correlation attribute evaluation*. Adapun alur proses seleksi fitur menggunakan CFS sebagai berikut:

1. Persiapkan data yang memiliki fitur (X) dan target (Y).
2. Hitung matriks korelasi untuk mengukur hubungan antara setiap fitur dengan target serta hubungan antara setiap pasangan fitur. Matriks korelasi dihitung menggunakan *pearson correlation coefficient* pada Persamaan (2) [29].

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (2)$$

Dimana r adalah koefisien korelasi, x_i adalah nilai fitur ke- i , y_i adalah nilai target ke- i , \bar{x} adalah rata-rata fitur, \bar{y} adalah rata-rata target

3. Peringkatkan fitur berdasarkan koefisien korelasi dengan target.
4. Tetapkan nilai ambang batas (*threshold*) untuk menentukan fitur yang relevan.
5. Pilih fitur dengan *correlation attribute evaluation*, di mana fitur yang memiliki korelasi lebih tinggi dari nilai ambang batas dianggap sebagai fitur yang relevan dengan target.

D. K-fold Cross Validation

K-fold cross validation diterapkan untuk membagi data menjadi dua subset, yaitu dataset pelatihan dan dataset pengujian [30]. Salah satu keunggulan *k-fold cross-validation* adalah kemampuannya dalam meningkatkan estimasi kinerja model supaya meningkatkan kestabilan dan ketepatan. Hal ini dicapai dengan menentukan nilai rata-rata dari "k" iterasi, sehingga menghasilkan evaluasi yang lebih representatif dibandingkan dengan sekadar membagi data menjadi *training* dan *testing* secara langsung. Selain itu, metode ini juga efektif dalam mengurangi risiko *overfitting*, karena model dilatih dan diuji menggunakan berbagai kombinasi data, memungkinkan generalisasi yang lebih optimal terhadap data baru [31]. Nilai k sebesar 10 sering direkomendasikan sebagai nilai optimal untuk memperoleh estimasi performa yang baik dan terukur [32]. Oleh karena itu, penelitian ini menggunakan nilai k sebesar 10. Pada setiap iterasi, sembilan bagian data digunakan sebagai data pelatihan, sedangkan satu bagian sisanya digunakan sebagai data pengujian. Rincian mengenai jumlah data latih dan data uji pada setiap *fold* disajikan pada bagian Hasil dan Pembahasan.

E. Backpropagation Neural Network

Backpropagation Neural Network (BPNN) adalah metode pembelajaran yang diawasi dengan terdiri dari tiga bagian utama yaitu *input layer*, *hidden layer*, dan *output layer*, dimana bobot yang menghubungkan setiap *layer* mengalami perubahan selama proses pelatihan [33]. Proses klasifikasi menggunakan BPNN terdiri dari dua tahap, yaitu pelatihan (*training*) dan pengujian (*testing*). Pada tahap pelatihan, model dilatih menggunakan data latih untuk mempelajari pola dan menghasilkan bobot optimal. Sementara itu, pada tahap pengujian, model yang telah dilatih dievaluasi menggunakan data uji untuk mengukur kinerjanya.

1) *Pelatihan BPNN*: Tahap pelatihan BPNN melibatkan tiga tahap utama yaitu perambatan maju (*feedforward*), perambatan mundur (*backpropagation*) dan perubahan bobot. Adapun tahapan yang dilakukan pada proses pelatihan BPNN sebagai berikut [34]:

1. Input data latih yang telah dibagi menggunakan teknik *10-fold cross validation*.
2. Inisialisasi arsitektur jaringan BPNN. *Neuron* pada *input layer* mewakili seluruh fitur yang diperoleh setelah tahap pemilihan fitur dengan menerapkan metode *Correlation-based Feature Selection* (CFS). *Neuron* pada *hidden layer* ditentukan menggunakan Persamaan (3) [35]. *Neuron* pada *output layer* terdiri dari satu *neuron* yang menghasilkan nilai 1 atau 0, yang menunjukkan klasifikasi jenis kelamin.

$$i < m < 2i \quad (3)$$

Dimana m merupakan neuron *hidden* dan i merupakan neuron *input*

3. Inisialisasi parameter jaringan BPNN yang meliputi fungsi aktivasi sigmoid, maksimum *epoch* 1000, dan *learning rate* sebesar 0,01.
4. Inisialisasi nilai awal bobot dan bias menggunakan bilangan acak berukuran kecil.
5. Melakukan perambatan maju (*feedforward*)

Pada tahap ini, data dari *input layer* diteruskan ke *hidden layer* melalui bobot yang dihubungkan dengan setiap node menggunakan Persamaan (4)

$$z_in_j = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (4)$$

Dimana z_in_j adalah nilai masukan untuk *neuron hidden*, v_{0j} adalah bias untuk *neuron hidden* ke- j , x_i adalah nilai dari *neuron input* ke- i , v_{ij} adalah bobot antara *neuron input* ke *neuron hidden*. Selanjutnya, nilai tersebut diproses melalui fungsi aktivasi menggunakan Persamaan (5)

$$z_j = \frac{1}{1 + e^{-z_in_j}} \quad (5)$$

Dimana z_j adalah keluaran unit ke- j pada *hidden layer*, z_in_j adalah nilai masukan untuk *neuron hidden* Kemudian, *neuron* pada lapisan *output* menerima sinyal dari *neuron hidden* menggunakan Persamaan (6)

$$y_in_k = w_{0k} + \sum_{k=1}^n z_j w_{jk} \quad (6)$$

Dimana y_in_k adalah keluaran untuk *output* y_k , w_{0k} adalah bias untuk *neuron hidden* ke- k , z_j adalah keluaran dari *neuron hidden* ke- j , w_{jk} adalah bobot antara *neuron tersembunyi* ke *neuron output* Hasil tersebut kemudian diproses dengan fungsi aktivasi melalui Persamaan (7)

$$y_k = \frac{1}{1 + e^{-y_in_k}} \quad (7)$$

Dimana y_k adalah nilai keluaran dari unit ke- k pada *output layer*, y_in_k adalah keluaran untuk unit *output* y_k

6. Melakukan perambatan mundur (*backpropagation*)

Pada tahap ini dilakukan perhitungan terhadap selisih antara keluaran model dengan nilai target menggunakan Persamaan (8)

$$\delta_k = (t_k - y_k)y_k(1 - y_k) \quad (8)$$

Dimana δ_k adalah *error* pada *neuron output*, t_k adalah *target output* ke- k , y_k adalah keluaran dari unit ke- k . Setelah itu, perbarui bobot dan bias pada lapisan *output* berdasarkan Persamaan (9) dan Persamaan (10)

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (9)$$

$$\Delta w_{0k} = \alpha \delta_k \quad (10)$$

Dimana Δw_{jk} adalah perubahan bobot dari *neuron hidden* ke *output*, Δw_{0k} adalah perubahan bias untuk *neuron hidden* ke- k , α adalah *learning rate*, δ_k adalah *error* pada *neuron output*, z_j adalah nilai keluaran dari *neuron hidden* ke- j . Selanjutnya hitung nilai *error* pada lapisan tersembunyi menggunakan Persamaan (11)

$$\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk} \quad (11)$$

Dimana δ_k adalah *error* pada *neuron output*, w_{jk} adalah bobot *neuron hidden* ke *neuron output*. Kemudian hasil yang diperoleh diterapkan pada fungsi aktivasi pada Persamaan (12)

$$\delta_j = \delta_{in_j} z_j (1 - z_j) \quad (12)$$

Dimana δ_j adalah *error* pada lapisan tersembunyi, δ_{in_j} adalah hasil akumulasi dari *layer* sebelumnya, z_j adalah keluaran dari *neuron hidden* ke- j . Bobot dan bias pada lapisan *hidden* kemudian diperbarui menggunakan Persamaan (13) dan Persamaan (14)

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (13)$$

$$\Delta v_{0j} = \alpha \delta_j \quad (14)$$

Dimana Δv_{ij} adalah perubahan bobot dari *neuron input* ke *neuron hidden*, Δv_{0j} adalah perubahan bias *neuron input* ke- j , α adalah *learning rate*, δ_j adalah *error* pada lapisan *hidden*, x_i adalah nilai dari *neuron input* ke- i

7. Melakukan perubahan bobot

Setelah perhitungan perambatan mundur, bobot diperbarui menggunakan Persamaan (15)

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (15)$$

Dimana w_{jk} adalah bobot antara *neuron hidden* dan *output*, Δw_{jk} adalah perubahan bobot *neuron hidden* ke *neuron output*. Selanjutnya perbarui bobot pada setiap node di *hidden layer* menggunakan Persamaan (16)

$$v_{jk}(\text{baru}) = v_{jk}(\text{lama}) + \Delta v_{jk} \quad (16)$$

Dimana v_{jk} adalah bobot antara *neuron input* dan *hidden*, Δv_{jk} adalah perubahan bobot *neuron input* ke *neuron hidden*

8. Periksa kondisi berhenti, pelatihan dihentikan jika kondisi terpenuhi yaitu ketika maksimum *epoch* tercapai atau *error* mencapai target.

2) *Pengujian BPNN*: Bobot baru yang didapatkan dari proses pelatihan BPNN akan digunakan pada tahap pengujian BPNN. Pengujian BPNN hanya dilakukan menggunakan tahap *feedforward* dengan menggunakan Persamaan (4) hingga Persamaan (7).

F. Evaluasi dan Pengujian Model

Pada penelitian ini, pengujian dilakukan terhadap *threshold* yang digunakan pada proses seleksi fitur, arsitektur jaringan *Backpropagation Neural Network* (BPNN) dan nilai *learning rate*. *Threshold* yang digunakan pada proses seleksi fitur adalah 0,1 dan 0,01. Jaringan BPNN yang digunakan terdiri dari tiga arsitektur dengan satu *hidden layer*. Jumlah *neuron* pada *hidden layer* disesuaikan dengan hasil seleksi fitur *Correlation-based Feature Selection* (CFS). Nilai *learning rate* yang diuji adalah 0,01 dan 0,001. *Learning rate* 0,01 dan 0,001 dipilih untuk membandingkan kecepatan dan kestabilan proses pelatihan. Nilai 0,01 memungkinkan konvergensi lebih cepat, sedangkan 0,001 digunakan untuk menghindari perubahan *error* yang tidak stabil pada data kompleks agar pelatihan lebih stabil. Selanjutnya evaluasi hasil pengujian dilakukan menggunakan *confusion matrix*, yaitu suatu tabel yang menyajikan keseluruhan jumlah data yang dikategorikan dengan benar maupun

salah. Penggunaan *confusion matrix* memudahkan dalam menilai tingkat ketepatan sebuah model klasifikasi [36]. *Confusion matrix* terdiri dari empat komponen utama yaitu *True Positive* (TP) mengindikasikan total data dengan label positif yang teridentifikasi secara benar, *True Negative* (TN) menunjukkan jumlah data berlabel negatif yang diklasifikasikan dengan tepat, *False Positive* (FP) merepresentasikan data yang sebenarnya positif tetapi salah diprediksi sebagai negatif, dan *False Negative* (FN) menunjukkan total data yang berlabel negatif tetapi salah dikategorikan sebagai positif. Ilustrasi *confusion matrix* dapat ditemukan pada Gambar 2.

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Gambar 2. Confusion matrix

Dari *confusion matrix*, sejumlah metrik evaluasi dapat dihitung seperti berikut [22]:

1) *Akurasi*: Perbandingan antara jumlah data yang dikategorikan dengan tepat terhadap keseluruhan data uji. Akurasi dapat dihitung menggunakan Persamaan (17)

$$akurasi = \frac{TN + TP}{TP + TN + FP + FN} \quad (17)$$

2) *Presisi*: Perbandingan jumlah prediksi positif yang benar terhadap seluruh prediksi positif yang dihasilkan oleh model. Presisi dapat dihitung menggunakan Persamaan (18)

$$presisi = \frac{TP}{TP + FP} \quad (18)$$

3) *Recall*: Perbandingan jumlah prediksi positif benar terhadap total data positif sesungguhnya. *Recall* dapat dihitung menggunakan Persamaan (19)

$$recall = \frac{TP}{TP + FN} \quad (19)$$

4) *F1 Score*: Rata-rata antara presisi dan *recall*. *F1 Score* dapat dihitung menggunakan Persamaan (20)

$$F1\ score = \frac{2 \times (presisi \times recall)}{presisi + recall} \quad (20)$$

III. HASIL DAN PEMBAHASAN

A. Pengumpulan Data

Penelitian ini menggunakan dataset yang terdiri dari 2.524 sampel dengan 85 fitur dan dua label kelas, yaitu *male* dan *female*. Seluruh tahapan penelitian, mulai dari pemrosesan data, pelatihan model dan pengujian model dilakukan di *Google Colab* dengan memanfaatkan bahasa pemrograman *Python*.

B. Preprocessing Data

1) *Seleksi Data*: Pada langkah ini, dilakukan penghapusan fitur *ID* dan *Population*, sehingga fitur yang tersisa berjumlah 83 fitur. Hasil dari seleksi data tersaji dalam Tabel 3.

TABEL 3
HASIL SELEKSI DATA

Sex	PopNum	GOL	NOL	BNL	BBH	XCB	XFB	ZYB	...	TBA
M	1	189	185	100	135	143	120	133	...	0
M	1	182	178	102	139	145	120	137	...	0
M	1	191	187	102	123	140	114	134	...	0
...
F	24	160	160	89	121	129	106	117	...	156
F	24	172	170	92	118	137	110	114	...	167
F	24	153	153	88	116	130	105	115	...	158

2) *Pembersihan Data*: Pada langkah ini, dilakukan pengecekan terhadap keberadaan duplikasi data dan data yang hilang (*missing value*). Hasil pengecekan menunjukkan bahwa tidak terdapat duplikasi data maupun data yang hilang yang tersaji dalam Gambar 3.

```
[ ] #Pembersihan Data
#cek data duplikat
df.duplicated().sum()

0

# Pembersihan Data
# Check for missing values
print("\nMissing values in each column:")
null_counts = df.isnull().sum()
print(null_counts)

# Menampilkan jumlah total missing values
total_missing = null_counts.sum()
print(f"\nTotal missing values: {total_missing}")

Missing values in each column:
Sex          0
PopNum       0
GOL          0
NOL          0
BNL          0
...
ROA          0
BSA          0
SBA          0
SLA          0
TBA          0
Length: 84, dtype: int64

Total missing values: 0
```

Gambar 3. Hasil pengecekan terhadap duplikasi data dan data yang hilang

3) *Transformasi Data*: Pada langkah ini, dilakukan transformasi pada fitur *Sex* dimana *Male* dikonversi menjadi 1 dan *Female* dikonversi menjadi 0. Hasil dari transformasi tersaji dalam Tabel 4.

TABEL 4
HASIL TRANSFORMASI DATA PADA FITUR SEX

Sex	PopNum	GOL	NOL	BNL	BBH	XCB	XFB	ZYB	...	TBA
1	1	189	185	100	135	143	120	133	...	0
1	1	182	178	102	139	145	120	137	...	0
1	1	191	187	102	123	140	114	134	...	0
...
0	24	160	160	89	121	129	106	117	...	156
0	24	172	170	92	118	137	110	114	...	167
0	24	153	153	88	116	130	105	115	...	158

Selanjutnya, dilakukan normalisasi untuk memastikan seluruh data terletak dalam rentang yang sama yaitu dari 0 hingga 1. Proses normalisasi diterapkan untuk seluruh fitur kecuali kelas yaitu *Sex*. Hasil normalisasi yang dihitung menggunakan persamaan (1) data ditampilkan pada Tabel 5.

TABEL 5
HASIL NORMALISASI DATA

Sex	PopNum	GOL	NOL	BNL	BBH	XCB	XFB	ZYB	...	TBA
1	0	0,6909	0,6938	0,4594	0,5833	0,5294	0,5	0,5283	...	0
1	0	0,5636	0,5510	0,5135	0,6666	0,5686	0,5	0,6037	...	0
1	0	0,7272	0,7346	0,5135	0,3333	0,4705	0,38	0,5471	...	0
...
0	0,7931	0,1636	0,1836	0,1621	0,2916	0,2549	0,22	0,2264	...	0,8813
0	0,7931	0,3818	0,3877	0,2432	0,2291	0,4117	0,3	0,1698	...	0,9435
0	0,7931	0,0363	0,0408	0,1351	0,1875	0,2745	0,2	0,1886	...	0,8926

C. Correlation-based Feature Selection

Seleksi fitur dilakukan dengan menghitung korelasi antara setiap fitur dan target menggunakan *pearson correlation coefficient* pada Persamaan (2). Hasil perhitungan koefisien korelasi yang telah diurutkan berdasarkan tingkat keterkaitannya dengan target ditampilkan pada Tabel 6.

TABEL 6
HASIL PERHITUNGAN KOEFISIEN KORELASI UNTUK SEMUA FITUR

No	Fitur	Koefisien Korelasi	No	Fitur	Koefisien Korelasi
1	ZYB	0,611964	43	PAF	0,234797
2	JUB	0,592574	44	FRA	0,229258
3	MDH	0,546812	45	DKB	0,225336
4	GOL	0,510446	46	OCC	0,221918
5	FMB	0,505368	47	NDS	0,221706
6	ZMB	0,492463	48	SSS	0,204639
7	MDB	0,490153	49	SIS	0,202681
8	NOL	0,482993	50	PAS	0,192977
9	XML	0,477645	51	STB	0,190286
10	MAB	0,472692	52	NAS	0,187965
11	EKB	0,471429	53	OCF	0,171815
12	NAR	0,467284	54	BAR	0,135124
13	SOS	0,464924	55	OCS	0,135124
14	AUB	0,456465	56	OBH	0,129992
15	BNL	0,454710	57	BAA	0,124508
16	BBH	0,440208	58	BRR	0,113988
17	GLS	0,438358	59	OSR	0,112126
18	FRC	0,432319	60	LAR	0,105086
19	SSR	0,428763	61	BSA	0,084295
20	VRR	0,422895	62	SLA	0,083354
21	AVR	0,413644	63	RPA	0,078590
22	DKR	0,410510	64	SBA	0,076313
23	NLH	0,407801	65	RFA	0,074606
24	NPH	0,404381	66	BRA	0,074582
25	PRR	0,396714	67	TBA	0,072723
26	ASB	0,385830	68	ROA	0,067247
27	FMR	0,383205	69	PopNum	0,065810
28	FRF	0,381618	70	DKA	0,048765
29	WCB	0,381452	71	DKS	0,045034
30	ZOR	0,373927	72	PRA	0,044715
31	EKR	0,371899	73	NBA	0,005343
32	OBH	0,366074	74	SSA	0,004412
33	PAC	0,361261	75	FRS	-0,004782
34	ZMR	0,356341	76	WNB	-0,006584
35	IML	0,347209	77	PAA	-0,028450
36	XCB	0,340279	78	OCA	-0,035412
37	FOL	0,337494	79	NFA	-0,039471
38	BPL	0,336499	80	BBA	-0,068878
39	XFB	0,336157	81	NDA	-0,077244
40	WMH	0,317293	82	NAA	-0,124315
41	MLS	0,284454	83	SIA	-0,223621
42	NLB	0,244976			

Pemilihan fitur dilakukan menggunakan *correlation attribute evaluation* berdasarkan nilai *threshold*, yang menentukan seberapa kuat hubungan antara setiap fitur dengan target klasifikasi. Semakin tinggi nilai *threshold*, semakin ketat seleksi fitur yang dilakukan, sehingga hanya fitur dengan korelasi lebih tinggi yang dipertahankan. Berdasarkan nilai koefisien korelasi, jumlah fitur yang terpilih dengan *threshold* 0,01 adalah 72 fitur, sedangkan dengan *threshold* 0,1 hanya 60 fitur. Peningkatan nilai *threshold* menyebabkan jumlah fitur yang terpilih semakin sedikit, namun fitur-fitur tersebut memiliki relevansi yang lebih tinggi terhadap target. Fitur yang telah terpilih kemudian digunakan sebagai *input* pada BPNN dalam proses klasifikasi untuk mengevaluasi pengaruh seleksi fitur terhadap performa model.

D. Pembagian Data


Teknik yang digunakan untuk pembagian data adalah *10-fold cross-validation*, di mana data dibagi menjadi 10 bagian yang seimbang. Pada setiap iterasi, 9 bagian dimanfaatkan sebagai data pelatihan, sedangkan 1 bagian lainnya digunakan sebagai data pengujian. Proses ini berlangsung secara bergantian hingga setiap bagian telah berperan sebagai data uji satu kali, memastikan bahwa seluruh dataset digunakan baik untuk pelatihan maupun pengujian. Rincian pembagian data untuk setiap *fold* disajikan pada Tabel 7.

TABEL 7
RINCIAN PEMBAGIAN DATA PADA SETIAP FOLD

	Fold									
	1	2	3	4	5	6	7	8	9	10
Data Latih	2271	2271	2271	2271	2272	2272	2272	2272	2272	2272
Data Uji	253	253	253	253	252	252	252	252	252	252
Total	2524	2524	2524	2524	2524	2524	2524	2524	2524	2524

E. Backpropagation Neural Network

Penelitian ini menggunakan metode klasifikasi *Backpropagation Neural Network* (BPNN). Model dikembangkan dengan tiga arsitektur berbeda, masing-masing memiliki satu *hidden layer* untuk mengevaluasi konfigurasi terbaik. *Input* yang digunakan berasal dari fitur yang terpilih melalui seleksi fitur, sedangkan jumlah *neuron* pada *hidden layer* ditetapkan sesuai dengan Persamaan (3) dengan mengambil tiga skenario, yaitu nilai terdekat, nilai tengah, dan nilai tertinggi. Salah satu arsitektur BPNN yang digunakan ditampilkan pada Gambar 4.



Gambar 4. Arsitektur BPNN

Gambar 4 menunjukkan arsitektur BPNN yang dibangun berdasarkan hasil seleksi fitur dengan *threshold* 0,01. Arsitektur BPNN tersebut terdiri dari 72 *neuron* pada *input layer*, 95 *neuron* pada *hidden layer*, dan 1 *neuron* pada *output layer*. Parameter BPNN yang digunakan meliputi fungsi aktivasi sigmoid, *learning rate* (0,01 dan 0,001), serta maksimum *epoch* sebesar 1000. Proses pelatihan BPNN dilakukan menggunakan Persamaan (4) hingga Persamaan (16), sementara pengujian menggunakan Persamaan (4) hingga Persamaan (7).


F. Evaluasi dan Pengujian Model

Pengujian dilakukan terhadap tiga skenario yaitu tanpa seleksi fitur, menggunakan seleksi fitur *Correlation-based Feature selection* (CFS) dengan *threshold* 0,1 dan menggunakan seleksi fitur *Correlation-based Feature selection* (CFS) dengan *threshold* 0,01. *Learning rate* yang digunakan dalam pengujian yaitu 0,01 dan 0,001. Pada skenario tanpa CFS, arsitektur BPNN yang digunakan terdiri dari tiga konfigurasi berbeda dengan struktur *input layer*, *hidden layer*, dan *output layer*, yaitu [83; 110; 1], [83; 137; 1], dan [83; 164; 1]. Setiap *learning rate* diuji pada masing-masing arsitektur untuk mengevaluasi performa model. Evaluasi performa model dihitung berdasarkan beberapa metrik yaitu akurasi, presisi, *recall*, dan *F1 score* yang diperoleh menggunakan Persamaan (17) hingga Persamaan (20). Hasil pengujian tanpa CFS disajikan pada Tabel 8.

TABEL 8
HASIL PENGUJIAN BPNN TANPA CFS

Learning rate	Arstiketur BPNN	Akurasi (%)	Presisi (%)	Recall (%)	F1 Score (%)
0.01	[83; 110; 1]	90,08	91	90	90
	[83; 137; 1]	90,08	91	90	90
	[83; 164; 1]	90,87	91	91	91
0.001	[83; 110; 1]	90,87	91	91	91
	[83; 137; 1]	91,27	91	91	91
	[83; 164; 1]	92,06	92	92	92
Rata-Rata		90,87	91,17	90,83	90,83

Tabel 8 menunjukkan bahwa hasil pengujian BPNN tanpa CFS mencapai akurasi tertinggi sebesar 92,06% pada konfigurasi *learning rate* 0,001 dengan arsitektur BPNN [83; 164; 1]. Hasil pengujian BPNN tanpa CFS akan direpresentasikan pada grafik dalam Gambar 5.



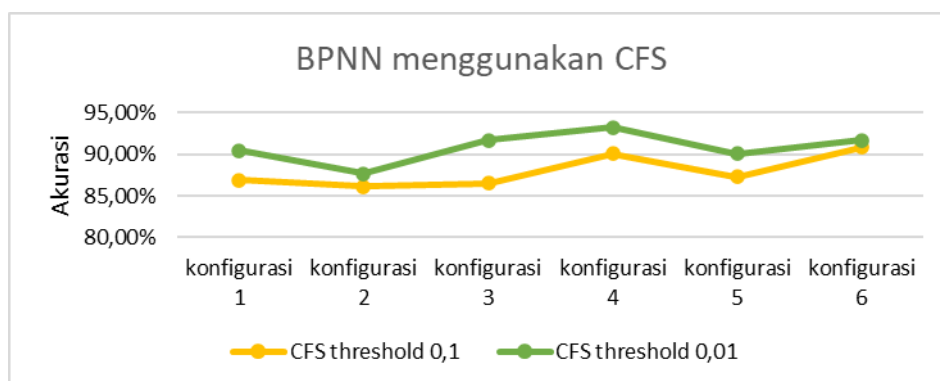
Gambar 5. Hasil pengujian BPNN tanpa CFS

Kemudian dilakukan pengujian terhadap skenario menggunakan CFS dengan *threshold* 0,1, seleksi fitur menghasilkan 60 fitur dengan tiga konfigurasi arsitektur BPNN, yaitu [60; 81; 1], [60; 99; 1], dan [60; 118; 1]. Sementara itu, pada skenario menggunakan CFS dengan *threshold* 0,01, seleksi fitur menghasilkan 72 fitur dengan tiga konfigurasi arsitektur BPNN, yaitu [72; 95; 1], [72; 119; 1], dan [72; 142; 1]. Hasil pengujian dari kedua skenario dengan seleksi fitur dibandingkan untuk mengevaluasi dampaknya terhadap performa model. Hasil pengujian BPNN dengan CFS pada dua *threshold* ditampilkan pada Tabel 9.

TABEL 9
HASIL PENGUJIAN BPNN MENGGUNAKAN CFS

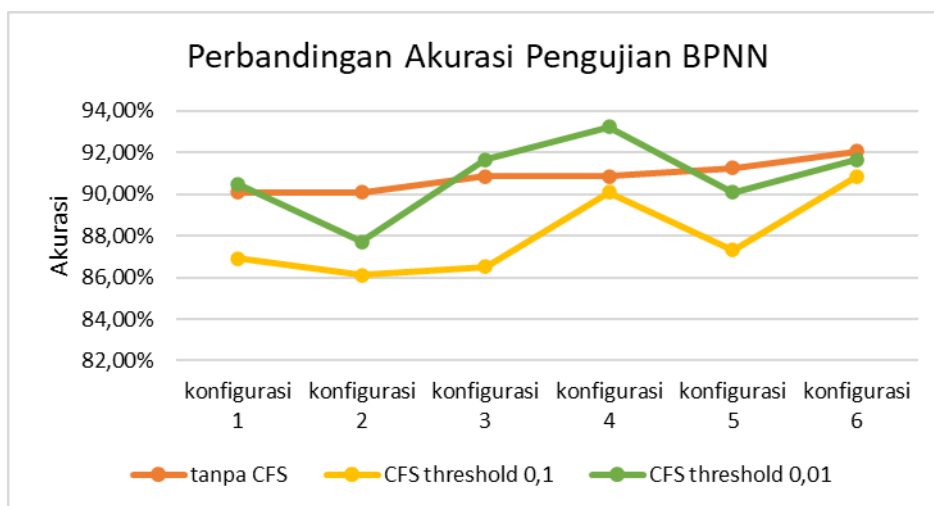
Threshold	Learning rate	Arsitektur BPNN	Akurasi (%)	Presisi (%)	Recall (%)	F1 Score (%)
0.1	0.01	[60; 81; 1]	86,90	88	87	87
		[60; 99; 1]	86,11	87	86	86
		[60; 118; 1]	86,51	87	87	87
	0.001	[60; 81; 1]	90,08	90	90	90
		[60; 99; 1]	87,30	88	87	87
		[60; 118; 1]	90,87	91	91	91
Rata-Rata			87,96	88,50	88	88
0.01	0.01	[72; 95; 1]	90,48	90	90	90
		[72; 119; 1]	87,70	89	88	88
		[72; 142; 1]	91,67	92	92	92
	0.001	[72; 95; 1]	93,25	93	93	93
		[72; 119; 1]	90,08	90	90	90
		[72; 142; 1]	91,67	92	92	92
Rata-Rata			90,81	91	90,83	90,83

Tabel 9 menunjukkan bahwa didapatkan akurasi tertinggi menggunakan CFS sebesar 93,25% pada *threshold* 0,01 dengan konfigurasi *learning rate* 0,001 dan arsitektur BPNN [72; 95; 1]. Hasil pengujian BPNN menggunakan CFS akan direpresentasikan pada grafik dalam Gambar 6.



Gambar 6. Hasil pengujian BPNN menggunakan CFS

Gambar 6 menunjukkan bahwa penggunaan CFS dengan *threshold* 0,1 tidak memberikan peningkatan akurasi dibandingkan BPNN tanpa seleksi fitur. Sebaliknya, CFS dengan *threshold* 0,01 mampu meningkatkan akurasi menjadi 93,25% pada konfigurasi *learning rate* 0,001 dan arsitektur BPNN [72; 95; 1]. Sementara itu, akurasi tertinggi pada BPNN tanpa CFS adalah 92,06%. Hasil ini menunjukkan bahwa penggunaan CFS dengan *threshold* 0,01 mampu meningkatkan akurasi sebesar 1,19%, membuktikan bahwa seleksi fitur dapat meningkatkan performa model klasifikasi. Perbandingan akurasi antara BPNN tanpa CFS dan BPNN dengan CFS ditampilkan pada Gambar 7.




Gambar 7. Perbandingan akurasi pengujian BPNN


Gambar 7 menyajikan perbandingan akurasi pengujian klasifikasi tulang tengkorak berdasarkan jenis kelamin dengan tiga skenario yaitu tanpa CFS, CFS dengan *threshold* 0,1, dan CFS dengan *threshold* 0,01. Setiap skenario diuji dengan enam konfigurasi yang diperoleh dari kombinasi *learning rate* (0,01 dan 0,001) serta tiga arsitektur BPNN seperti yang disajikan pada Tabel 8 dan Tabel 9. Hasil pengujian menunjukkan bahwa seleksi fitur dengan *threshold* 0,01 cenderung menghasilkan akurasi lebih tinggi dibandingkan dengan *threshold* 0,1 maupun tanpa CFS. Pada beberapa konfigurasi, penggunaan CFS *threshold* 0,1 justru menurunkan akurasi dibandingkan dengan skenario lainnya. Hal ini menunjukkan bahwa *threshold* 0,1 lebih ketat dalam memilih fitur, sehingga fitur-fitur yang sebenarnya masih memiliki kontribusi terhadap klasifikasi ikut tereliminasi. Sebaliknya, *threshold* 0,01 mampu mempertahankan lebih banyak fitur yang masih relevan terhadap target, sehingga mampu memberikan *input* yang lebih baik untuk proses pelatihan model. Dengan demikian, keberhasilan seleksi fitur tidak hanya ditentukan oleh seberapa banyak fitur dikurangi, tetapi oleh relevansi dan kualitas fitur yang dipertahankan terhadap target dan hubungan antarfitur yang tidak saling redundan.

Variasi akurasi yang terlihat dalam setiap skenario menunjukkan bahwa performa model dipengaruhi oleh kombinasi arsitektur dan *learning rate* yang digunakan. Pada skenario tanpa CFS, akurasi tertinggi diperoleh pada arsitektur BPNN dengan jumlah *neuron hidden layer* tertinggi. Sementara pada skenario menggunakan CFS, akurasi tertinggi justru diperoleh pada arsitektur BPNN dengan jumlah *neuron hidden layer* terendah. Temuan ini menunjukkan bahwa setelah seleksi fitur mengeliminasi fitur-fitur yang tidak relevan, model klasifikasi tidak memerlukan struktur jaringan yang kompleks atau jumlah *neuron* yang tinggi untuk mencapai akurasi optimal. Selain itu, pemilihan arsitektur yang tepat memiliki peran penting dalam meningkatkan performa klasifikasi.

Evaluasi dilakukan setelah pengujian menggunakan *confusion matrix* untuk menganalisis jumlah prediksi yang benar dan salah. Hasil pengujian tanpa CFS dengan akurasi tertinggi menunjukkan bahwa model berhasil mengklasifikasikan 120 data kelas *female* dengan benar (*True Positive*) dan 112 data kelas *male* dengan benar (*True Negative*). Namun, terdapat 8 data kelas *female* yang salah diklasifikasikan sebagai *male* (*False Positive*) serta 12 data kelas *male* yang salah diklasifikasikan sebagai *female* (*False Negative*). Sementara itu, hasil pengujian menggunakan CFS dengan akurasi tertinggi menunjukkan bahwa model berhasil mengklasifikasikan 120 data kelas *female* dengan benar (*True Positive*) dan 115 data kelas *male* dengan benar (*True Negative*). Namun, terdapat 8 data kelas *female* yang salah diklasifikasikan sebagai *male* (*False Positive*) serta 9 data kelas *male* yang salah diklasifikasikan sebagai *female* (*False Negative*). Secara keseluruhan, hasil ini mengindikasikan bahwa model menunjukkan kinerja yang baik dalam mengklasifikasikan jenis kelamin berdasarkan karakteristik tulang tengkorak. Hasil *confusion matrix* tersebut disajikan pada Gambar 8.



(a)



(b)

Gambar 8. Perbandingan hasil confusion matrix dengan akurasi tertinggi pada pengujian BPNN (a) tanpa CFS dan (b) menggunakan CFS

Hasil penelitian ini menunjukkan bahwa penerapan CFS dengan *threshold* 0,01 berhasil meningkatkan akurasi klasifikasi jenis kelamin berdasarkan tulang tengkorak hingga 93,25%. Temuan ini membuktikan bahwa CFS dapat menyederhanakan *input* data tanpa mengurangi akurasi. Hal ini sangat relevan dalam situasi nyata ketika data yang tersedia terbatas atau tidak lengkap. Dengan memanfaatkan fitur-fitur paling informatif, proses identifikasi tetap dapat dilakukan dengan andal. Temuan ini sejalan dengan penelitian oleh [21] yang mengombinasikan CFS dengan LVQ 2 dan menunjukkan hasil bahwa seleksi fitur dapat meningkatkan performa model klasifikasi dalam data biologis. Selain itu, penelitian oleh [8] yang menggunakan BPNN tanpa seleksi fitur memperoleh akurasi 92,32%, sementara kombinasi BPNN dengan CFS dalam penelitian ini dapat meningkatkan akurasi menjadi 93,25%. Hasil ini menunjukkan pengaruh seleksi fitur dalam meningkatkan performa model klasifikasi.

Model ini menunjukkan performa klasifikasi yang baik, namun terdapat potensi *overfitting* yang perlu diperhatikan. Potensi *overfitting* ini disebabkan oleh keterbatasan dataset yang berasal dari satu sumber dengan jumlah sampel yang terbatas. *Overfitting* terjadi ketika model terlalu menyesuaikan diri dengan data pelatihan sehingga performa pada data uji menurun. Oleh karena itu, untuk meningkatkan generalisasi model, diperlukan pengujian lebih lanjut menggunakan dataset yang lebih besar dan beragam untuk memastikan bahwa model dapat digeneralisasi dengan baik. Meskipun demikian, hasil penelitian ini tetap menunjukkan potensi besar dalam pengembangan sistem identifikasi forensik otomatis berbasis AI, yang dapat mempercepat proses identifikasi jenis kelamin berdasarkan data kranimetri, terutama dalam situasi di mana hanya sisa-sisa tengkorak yang ditemukan. Implementasi model ini dapat membantu ahli forensik menganalisis bukti dengan lebih efisien, mengurangi ketergantungan pada metode manual, serta meningkatkan kecepatan dan ketepatan identifikasi individu yang belum teridentifikasi. Dengan akurasi yang tinggi dan penggunaan seleksi fitur yang efektif, model ini dapat diintegrasikan ke dalam platform *forensic rapid-response* untuk mempercepat dan meningkatkan keakuratan proses identifikasi jenis kelamin dalam situasi darurat, khususnya ketika hanya sisa-sisa tulang tengkorak yang tersedia.

IV. SIMPULAN

Penelitian ini bertujuan untuk meningkatkan akurasi pada proses klasifikasi jenis kelamin berdasarkan tulang tengkorak dengan menerapkan *Correlation-Based Feature Selection* (CFS) dan *Backpropagation Neural Network* (BPNN). Penggunaan CFS dengan *pearson correlation coefficient* pada *threshold* 0,1 menghasilkan 60 fitur terpilih, sedangkan *threshold* 0,01 menghasilkan 72 fitur. Pengujian dilakukan terhadap tiga skenario yaitu tanpa CFS, menggunakan CFS *threshold* 0,1 dan menggunakan CFS *threshold* 0,01. Hasil menunjukkan bahwa seleksi fitur dengan *threshold* 0,01 cenderung memberikan akurasi lebih tinggi dibandingkan dengan *threshold* 0,1 maupun tanpa CFS, sementara pada beberapa konfigurasi, penggunaan CFS *threshold* 0,1 justru menurunkan akurasi. Hal ini disebabkan oleh CFS *threshold* 0,1 lebih ketat dalam memilih fitur, sehingga dapat menghilangkan fitur yang masih relevan. Sebaliknya, *threshold* 0,01 mampu mempertahankan fitur informatif yang mendukung proses klasifikasi. Penggunaan CFS dengan *threshold* 0,01 mampu meningkatkan akurasi klasifikasi dari 92,06% menjadi 93,25% pada konfigurasi *learning rate* 0,001 dan arsitektur BPNN [72; 95;1]. Temuan ini membuktikan bahwa seleksi fitur dapat meningkatkan performa model dengan menentukan fitur yang lebih relevan. Selain itu, variasi akurasi pada setiap skenario menunjukkan bahwa performa model dipengaruhi oleh kombinasi arsitektur dan *learning rate* yang digunakan. Pada skenario tanpa CFS, akurasi tertinggi diperoleh pada arsitektur BPNN dengan jumlah *neuron hidden layer* tertinggi. Sementara pada skenario menggunakan CFS, akurasi tertinggi diperoleh pada arsitektur BPNN dengan jumlah *neuron hidden layer* terendah. Hal ini menunjukkan bahwa pemilihan arsitektur yang tepat dapat mempengaruhi tingkat akurasi model. Model ini menunjukkan performa klasifikasi yang baik, sehingga penelitian ini membuka peluang pengembangan sistem identifikasi forensik otomatis berbasis *cloud*, yang dapat mempercepat dan meningkatkan akurasi proses klasifikasi dalam situasi darurat melalui integrasi model ke dalam platform *forensic rapid-response* berbasis AI. Namun, perlu diperhatikan potensi *overfitting* karena keterbatasan dataset yang digunakan. Oleh karena itu, diperlukan pengujian lebih lanjut dengan dataset yang lebih besar dan beragam untuk memastikan model dapat digeneralisasi dengan baik. Selain itu, penelitian ini hanya menggunakan metode seleksi fitur yang berbasis hubungan linear. Oleh karena itu, penelitian selanjutnya dapat mengeksplorasi metode seleksi fitur yang dapat menangkap hubungan non-linear, seperti *Mutual Information* atau *Recursive Feature Elimination* (RFE).

UCAPAN TERIMAKASIH

Peneliti mengucapkan terima kasih kepada Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Sultan Syarif Kasim Riau atas kesempatan yang diberikan dalam melaksanakan penelitian ini. Peneliti juga menyampaikan rasa terima kasih kepada Ibu Iis Afrianty, S.T., M.Sc. atas nasihat dan tuntunan yang sangat berarti selama proses penelitian. Selain itu, peneliti juga mengungkapkan terima kasih yang mendalam kepada orang tua atas doa, bantuan, dan semangat yang tanpa batas dalam menyelesaikan penelitian ini.

DAFTAR PUSTAKA

- [1] G. Mason and H. Yusuf, "Physics and Geology as a crime solving science," *Criminology*, pp. 2162–2175, 2024, [Online]. Available: <https://jicnusantara.com/index.php/jicn>
- [2] D. Novitasari, I. Istiqomah, and R. Rizaldy, "Identifikasi Antropologi Forensik Pada Investigasi Kasus Temuan Rangka Manusia-Case Series," *Lambung Mangkurat Med. Semin.*, vol. 4, no. 1, pp. 81–86, 2023.
- [3] L. Prasetyawati, T. H. Yuliawati, and K. E. Purwantari, "Determinasi Jenis Kelamin Menggunakan Parameter Morfologi dan Morfometrik pada Mandibula," *Lambung Mangkurat Med.*, vol. 4, no. 1, p. 469, 2023.
- [4] T. Suryadi, M. J. Ramadhanif, R. P. Sari, and F. Kamila, "Identifikasi jenazah Yang Ditemukan di Pinggir Pantai," *Indones. J. Leg. forensic Sci.*, vol. 11, no. 2, pp. 112–121, 2021.
- [5] W. Yang, M. Zhou, P. Zhang, G. Geng, X. Liu, and H. Zhang, "Skull Sex Estimation Based on Wavelet Transform and Fourier Transform," *Biomed Res. Int.*, vol. 2020, 2020, doi: 10.1155/2020/8608209.
- [6] S. S. Rahayu, I. Afrianty, E. Budianita, and F. Syafria, "Klasifikasi Tulang Tengkorak Berdasarkan Jenis Kelamin dalam Antropologi Forensik Menggunakan Metode Support Vector Machine," *INOVTEK Polbeng - Seri Inform.*, vol. 9, no. 1, pp. 243–256, 2024, doi: 10.35314/isi.v9i1.4046.
- [7] Arthy, R. Goel, and M. Sreenivas, "Determination of sex by osteometry of third metatarsal," *Indian J. Forensic Med. Toxicol.*, vol. 14, no. 3, pp. 1–6, 2020, doi: 10.37506/ijfnt.v14i3.10315.
- [8] M. Kadarman, I. Afrianty, E. Budianita, and F. Syafria, "Classification of Human Skull Bones on Gender Using Backpropagation in Forensic Anthropology," vol. 5, no. 3, pp. 619–625, 2024.
- [9] F. Curate, "The Estimation of Sex of Human Skeletal Remains in the Portuguese Identified Collections : History and Prospects The Estimation of Sex of Human Skeletal Remains in the Portuguese Identified Collections : History and Prospects," no. March, 2022, doi: 10.3390/forensicsci2010021.
- [10] K. Krishan, T. Kanchan, S. Kaur, N. Baryah, and S. R.K, "A review of sex estimation techniques during examination of skeletal remains in forensic anthropology casework," *Forensic Sci. Int.*, 2016.
- [11] D. Nasein, M. H. Adiya, I. Afrianty, N. A. Ali, A. A. Samah, and Y. Rahayu, "Determination of Sex and Race in Forensic

- Anthropology: A Comparison of Artificial Neural network and Support Vector Machine,” *Int. Conf. Comput. Informatics Eng.*, pp. 51–55, 2021.
- [12] P. Mesejo, R. Martos, Ó. Ibáñez, J. Novo, and M. Ortega, “A Survey on artificial intelligence techniques for biomedical image analysis in skeleton-based forensic human identification,” *Appl. Sci.*, vol. 10, no. 14, 2020, doi: 10.3390/app10144703.
- [13] A. H. Bukhamseen *et al.*, “The Use of Orthopedic Surgical Impants for Forensic Identification: An Overview,” *Acta Biomed.*, vol. 93, no. 3, 2022, doi: 10.23750/abm.v93i3.12471.
- [14] D. Febiyanti, N. Amalita, D. Permana, and T. Octavia Mukhti, “Backpropagation Neural Network Application in Predicting The Stock Price of PT Bank Rakyat Indonesia Tbk,” *UNP J. Stat. Data Sci.*, vol. 1, no. 5, pp. 441–448, 2023, doi: 10.24036/ujsds/vol1-iss5/113.
- [15] W. Yang, X. Liu, K. Wang, J. Hu, G. Geng, and J. Feng, “Sex determination of three-dimensional skull based on improved backpropagation neural network,” *Comput. Math. Methods Med.*, vol. 2019, 2019, doi: 10.1155/2019/9163547.
- [16] N. L. Hairuddin, L. M. Yusuf, and M. S. Othman, “Gender classification on skeletal remains: Efficiency of metaheuristic algorithm method and optimized back propagation neural network,” *J. Inf. Commun. Technol.*, vol. 19, no. 2, pp. 251–277, 2020, doi: 10.32890/jict2020.19.2.5.
- [17] G. Lukhaya Pritalia, “Analisis Komparatif Algoritme Machine Learning dan Penanganan Imbalanced Data pada Klasifikasi Kualitas Air Layak Minum,” *KONSTELASI Konvergensi Teknol. dan Sist. Inf.*, vol. 2, no. 1, pp. 43–55, 2022, doi: 10.24002/konstelasi.v2i1.5630.
- [18] Y. Harni, I. Afrianty, S. Sanjaya, R. Abdullah, F. Yanto, and F. Syafria, “Performance Analysis of LVQ 1 Using Feature Selection Gain Ratio for Sex Classification in Forensic Anthropology,” *Build. Informatics, Technol. Sci.*, vol. 5, no. 1, 2023, doi: 10.47065/bits.v5i1.3625.
- [19] A. Rahmadayan and M. Mustakim, “Seleksi Fitur pada Supervised Learning: Klasifikasi Prestasi Belajar Mahasiswa Saat dan Pasca Pandemi COVID-19,” *J. Nas. Teknol. dan Sist. Inf.*, vol. 9, no. 1, pp. 21–32, 2023, doi: 10.25077/teknosi.v9i1.2023.21-32.
- [20] N. C. Ramadhan, H. H. H. T. Rohana, and A. M. Siregar, “Optimasi Algoritma Machine Learning Menggunakan Seleksi Fitur Xgboost Untuk Klasifikasi Kanker Payudara,” *TIN Terap. Inform. Nasant.*, vol. 5, no. 2, pp. 162–171, 2024, doi: 10.47065/tin.v5i2.5408.
- [21] S. Aditya GD, I. Afrianty, and S. Sanjaya, “Perbandingan performasi dengan Metode Correlation Based Feature Selection pada LVQ 2,” *J. INSTEK (Informatika Sains dan Teknol.)*, vol. 8, pp. 170–179, 2023.
- [22] A. N. Puteri, A. Arizal, and A. D. Achmad, “Feature Selection Correlation-Based pada Prediksi Nasabah Bank Telemarketing untuk Deposito,” *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 20, no. 2, pp. 335–342, 2021, doi: 10.30812/matrik.v20i2.1183.
- [23] H. K. Nurul Yusufiyah and J. P. Gya Nur Rochman, “Efektivitas Penggunaan Seleksi Ciri CFS pada Klasifikasi Ciri Bentuk Nodul Kanker Payudara dengan Citra Ultrasonografi,” *Phys. Educ. Res. J.*, vol. 3, no. 1, pp. 11–18, 2021, doi: 10.21580/perj.2021.3.1.6667.
- [24] M. Alden, N. Anargya, W. Ghozi, and F. A. Rafrastara, “Optimizing IoV Attack Detection using Random Under Sampling Techniques,” vol. 10, no. 1, pp. 11–19, 2025, doi: 10.30591/jpit.v10i1.8034.
- [25] Y. Irawan, “Penerapan data mining untuk evaluasi data penjualan menggunakan metode clustering dan algoritma hirarki divisive,” pp. 13–20.
- [26] M. H. Adiya and Y. Desnelita, “Penerapan Algoritma K-Means Untuk Clustering Data Obat-Obatan Pada RSUD Pekanbaru,” *J. Nas. Teknol. dan Sist. Inf.*, vol. 01, pp. 17–24, 2019.
- [27] F. Alghifari and D. Juardi, “Penerapan Data Mining Pada Penjualan Makanan Dan Minuman Menggunakan Metode Algoritma Naïve Bayes,” 2021.
- [28] P. P. Alloreng, A. Erna, and M. Bagussahrir, “Analisis Performa Normalisasi Data untuk Klasifikasi K-Nearest Neighbor pada Dataset Penyakit,” vol. 9, no. 3, pp. 178–191, 2024.
- [29] D. Burgund, S. Nikolovski, D. Galić, and N. Maravić, “Pearson Correlation in Determination of Quality of Current Transformers,” *Sensors*, vol. 23, no. 5, 2023, doi: 10.3390/s23052704.
- [30] R. N. Irawan, K. M. Hindrayani, and M. Idhom, “Penerapan Cross Validation sebagai Analisis Sentimen Pelayanan Publik Kereta Api Lokal Daop 8 Menggunakan Metode Multinomial Naïve Bayes,” *G-Tech J. Teknol. Terap.*, vol. 8, no. 2, pp. 954–963, 2024, doi: 10.33379/gtech.v8i2.4117.
- [31] W. Wijiyanto, A. I. Pradana, S. Sopingi, and V. Atina, “Teknik K-Fold Cross Validation untuk Mengevaluasi Kinerja Mahasiswa,” *J. Algoritm.*, vol. 21, no. 1, pp. 239–248, 2024, doi: 10.33364/algoritma/v.21-1.1618.
- [32] P. Romadloni, B. Adhi Kusuma, and W. Maulana Baihaqi, “Komparasi Metode Pembelajaran Mesin Untuk Implementasi Pengambilan Keputusan Dalam Menentukan Promosi Jabatan Karyawan,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 6, no. 2, pp. 622–628, 2022, doi: 10.36040/jati.v6i2.5238.
- [33] M. W. Al Wajieh, “Klasifikasi Jenis Kelengkeng Berdasarkan Morfologi Daun Dengan Ekstraksi Ciri RGB, GLCM, dan Bentuk Menggunakan Metode BPNN,” *J. Apl. Teknol. Inf. dan Manaj.*, vol. 4, no. 2, pp. 183–193, 2023, doi: 10.31102/jatim.v4i2.2341.
- [34] Z. Zulastrri, I. Afrianty, E. Budianita, and F. Syafria, “Penerapan Neural Network dengan Menggunakan Algoritma Backpropagation pada Prediksi Putusan Perceraian,” *Build. Informatics, Technol. Sci.*, vol. 4, no. 3, pp. 1188–1195, 2022, doi: 10.47065/bits.v4i3.2437.
- [35] M. Azhima, I. Afrianty, E. Budianita, and S. Kurnia Gusti, “KLIK: Kajian Ilmiah Informatika dan Komputer Penerapan Metode Backpropagation Neural Network untuk Klasifikasi Penyakit Stroke,” *Media Online*, vol. 4, no. 6, pp. 3013–3021, 2024, doi: 10.30865/klik.v4i6.1956.
- [36] R. Nurhidayat and K. E. Dewi, “Penerapan Algoritma K-Nearest Neighbor Dan Fitur Ekstraksi N-Gram Dalam Analisis Sentimen Berbasis Aspek,” *Komputa J. Ilm. Komput. dan Inform.*, vol. 12, no. 1, pp. 91–100, 2023, doi: 10.34010/komputa.v12i1.9458.