



Penerapan Information Gain Untuk Seleksi Fitur Pada Klasifikasi Jenis Kelamin Tulang Tengkorak Menggunakan Backpropagation

Nada Tsawaabul Khair, Iis Afrianty*, Fadhilah Syafria, Elvia Budianita, Siska Kurnia Gusti

Fakultas Sain dan Teknologi, Teknik Informatika, Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, Indonesia

Email: ¹12050120313@students.uin-suska.ac.id, ^{2*}iis.afrianty@uin-suska.ac.id, ³fadhilah.syafria@uin-suska.ac.id,

⁴elvia.budianita@uin-suska.ac.id, ⁵siskakurniagusti@uin-suska.ac.id

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

Abstrak—Antropologi forensik dan analisis tulang tengkorak merupakan bidang penting dalam identifikasi biologis individu, termasuk penentuan jenis kelamin. Penelitian ini bertujuan untuk meningkatkan akurasi klasifikasi jenis kelamin berdasarkan struktur tulang tengkorak dengan menggabungkan metode seleksi fitur Information Gain dan algoritma Backpropagation. Dataset yang digunakan adalah data kranimetri William W. Howells yang terdiri dari 2.524 sampel dengan 85 fitur pengukuran. Proses pra-pemrosesan mencakup seleksi data, pembersihan data, dan normalisasi. Seleksi fitur dilakukan menggunakan metode Information Gain dengan tiga nilai ambang batas (threshold) yaitu 0,01; 0,05; dan 0,1, yang menghasilkan 79, 46, dan 38 fitur terpilih. Pengujian model dilakukan menggunakan metode K-Fold Cross Validation dengan nilai K=10 dan K=20. Hasil menunjukkan bahwa akurasi tertinggi sebesar 93,91% diperoleh pada threshold 0,01 dengan arsitektur Backpropagation [79:119:1], learning rate 0,01, dan menggunakan K=20. Hasil ini membuktikan bahwa seleksi fitur menggunakan Information Gain mampu meningkatkan performa model backpropagation dengan mengurangi fitur yang tidak relevan serta meminimalisasi risiko overfitting.

Kata Kunci: Backpropagation; Information Gain; Seleksi Fitur; Klasifikasi Jenis Kelamin; Tulang Tengkorak

Abstract—Forensic anthropology and skull analysis play a crucial role in the biological identification of individuals, including sex determination. This study aims to improve the accuracy of gender classification based on skull structure by combining the Information Gain feature selection method with the Backpropagation algorithm. The dataset used is the craniometric data compiled by William W. Howells, consisting of 2,524 samples with 85 measurement features. The preprocessing stage includes data selection, data cleaning, and normalization. Feature selection was conducted using the Information Gain method with three threshold values: 0.01, 0.05, and 0.1, resulting in 79, 46, and 38 selected features, respectively. The model was evaluated using the K-Fold Cross Validation method with K=10 and K=20. The highest accuracy of 93.91% was achieved at the 0.01 threshold using the Backpropagation architecture [79:119:1], a learning rate of 0.01, and K=20. These results demonstrate that feature selection using Information Gain enhances the performance of the Backpropagation model by eliminating irrelevant features and minimizing the risk of overfitting.

Keywords: Backpropagation Neural Network; Feature Selection; Information Gain; Sex Classification; Skull.

1. PENDAHULUAN

Antropologi forensik adalah ilmu yang berfokus pada identifikasi kerangka manusia, terutama dengan cara menganalisis tulang untuk mengetahui profil biologis seseorang [1]. Dari sisa-sisa kerangka, para ahli dapat memperkirakan jenis kelamin, usia saat meninggal, ras, dan bentuk tubuh individu tersebut [2], [3]. Tulang juga bisa memberikan informasi tentang garis keturunan, jenis kelamin, tinggi badan, penyebab kematian, serta perkiraan waktu kematian [4]. Salah satu langkah awal dalam analisis forensik adalah menentukan jenis kelamin, karena ini menjadi dasar untuk perkiraan usia, garis keturunan, dan postur tubuh [2], [4], [5]. Identifikasi jenis kelamin membantu membuat perkiraan usia lebih akurat [6].

Ada dua metode utama dalam menentukan jenis kelamin dari tulang, yaitu metode morfologi dan osteometrik [7]. Metode osteometrik menggunakan pengukuran tulang, seperti berat badan, proporsi tubuh, serta bentuk kerangka, misalnya sudut dan panjang tulang kemaluan [8]. Sementara itu, metode morfologi lebih mengandalkan pengamatan langsung terhadap ciri-ciri visual tulang [5]. Bagian kerangka yang sering digunakan untuk menentukan jenis kelamin meliputi panggul, tengkorak [9], rahang bawah [10], bagian kranial [11], tulang paha [12], dan tibia [13]. Dari semua bagian tersebut, tengkorak menjadi pilihan terbaik setelah panggul, karena dapat menentukan jenis kelamin dengan akurasi hingga 90% [14], [15]. Namun, meskipun panggul lebih akurat, tulang ini lebih rapuh dan sulit disimpan [18]. Sebaliknya, tengkorak lebih kuat dan memiliki ciri khas yang lebih stabil dalam membedakan jenis kelamin [16], [17]. Penelitian tentang tulang tengkorak dengan menerapkan machine learning telah dilakukan sebelumnya dengan menerapkan beberapa metode, yaitu LVQ1, LVQ2, LVQ3, SVM, serta *Backpropagation*. Penelitian pertama [18] menggunakan metode LVQ1, LVQ2, dan LVQ3 dengan hasil akurasi LVQ 1 mendapatkan akurasi terbaik yaitu 91,39% dengan learning rate 0,1, 0,4, 0,7, 0,9. Penelitian kedua [15] menggunakan metode SVM (*Support Vector Machine*) dengan akurasi kernel linear memperoleh akurasi terbaik sebesar 88,14% dengan C=2. Untuk kernel RBF, akurasi terbaik sebesar 91,30%. Untuk kernel polinomial, akurasi terbaik sebesar 88,14%. Penelitian ketiga [19] menggunakan metode *Backpropagation* yang menghasilkan akurasi rata-rata 92,32% untuk satu hidden layer dan 90,74% untuk dua hidden layer.

Metode *Backpropagation* yang digunakan dalam penelitian tersebut menunjukkan performa unggul dalam klasifikasi tulang tengkorak. *Backpropagation* merupakan salah satu jenis Jaringan Syaraf Tiruan yang mampu secara otomatis mengenali pola-pola kompleks serta mengoptimalkan parameter model melalui proses berulang [20]. Secara struktural, *Backpropagation* terdiri dari sebuah perceptron berlapis yang menyesuaikan bobot terkait dengan neuron-neuron di lapisan tersembunyi [21]. Lapisan dalam *Backpropagation* terbagi menjadi tiga, yaitu lapisan masukan (*input*



layer), lapisan tersembunyi (*hidden layer*), dan lapisan keluaran (*output layer*) [22]. Proses dalam jaringan ini melibatkan fase maju (*feedforward*), fase mundur (*backpropagation*), serta penyesuaian bobot di antara tiap lapisan. Setiap fase berfungsi menangkap kesalahan (*error*) dan meningkatkan akurasi jaringan pada tahap berikutnya. Proses ini merupakan hasil seleksi fitur yang bertujuan untuk mempersempit atau mengurangi dimensi antar fitur [23], sesuai dengan implementasi dalam penelitian [19] yang mengklasifikasikan jenis kelamin berdasarkan tulang tengkorak menggunakan *Backpropagation*. Penelitian tersebut menunjukkan bahwa penerapan *Backpropagation* mampu membedakan tengkorak laki-laki dan perempuan dengan akurasi hingga 92,32% pada satu hidden layer dengan arsitektur [82:136:1], *learning rate* 0.01 serta *K-fold* =10 yang membuktikan bahwa algoritma ini efektif dalam memodelkan hubungan kompleks dalam data. Meskipun hasil yang diperoleh cukup tinggi, akurasi tersebut masih berpotensi untuk ditingkatkan melalui penerapan seleksi fitur yang tepat. Hal ini penting dilakukan karena data yang digunakan memiliki 86 fitur, yang berpotensi mengandung fitur yang tidak relevan.

Tahapan seleksi fitur bertujuan untuk mengurangi kompleksitas fitur yang dikelola selama proses klasifikasi, sehingga dapat meminimalkan kesalahan pada output yang dihasilkan oleh jaringan dengan konsep multilayer [23]. Jika jumlah fitur terlalu banyak dan tidak relevan, hal ini dapat mempengaruhi efektivitas pengenalan pola pada tahap pemrosesan dengan metode yang digunakan [24]. Salah satu metode seleksi fitur adalah *Information Gain*. Metode ini digunakan karena dapat mengatasi fitur yang berlebihan atau redundan dengan mengurangi fitur yang tidak relevan, sehingga menyederhanakan dan mengurangi risiko overfitting, serta meningkatkan efisiensi dalam proses klasifikasi [25], [26].

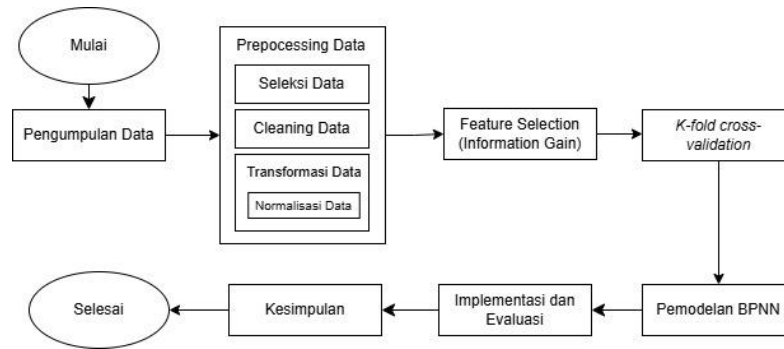
Penerapan seleksi fitur *Information Gain* telah dibuktikan keefektifannya dalam berbagai penelitian sebelumnya. Penelitian [26] menganalisis tingkat efektivitas klasifikasi ulasan pengguna aplikasi Discord menggunakan metode *Information Gain* dan *Naïve Bayes Classifier*. Penelitian ini menerapkan seleksi fitur *Information Gain* untuk meningkatkan akurasi klasifikasi dan memperoleh hasil tertinggi dengan akurasi 84%, precision 84%, recall 84%, dan f1-score 83% menggunakan 90% data training dan 10% data testing. Penelitian lainnya, yaitu penelitian yang membandingkan metode *K-Nearest Neighbor* (K-NN) dan Random Forest dengan seleksi fitur *Information Gain* dalam klasifikasi lama studi mahasiswa [27]. Penelitian ini membuktikan bahwa *Information Gain* efektif dalam menyaring fitur-fitur yang tidak relevan, sehingga mampu meningkatkan akurasi dalam proses klasifikasi. Berdasarkan hasil yang diperoleh, algoritma Random Forest berhasil mencapai akurasi sempurna sebesar 100%, sementara algoritma K-NN mencatat akurasi sebesar 86,67%. Temuan ini memperkuat peran seleksi fitur menggunakan *Information Gain* dalam mengoptimalkan kinerja model klasifikasi. Penelitian lanjutan difokuskan pada perbandingan kinerja akademik dengan menerapkan metode *neighbor weighted k-nearest neighbor* yang juga menggunakan seleksi fitur *Information Gain* [28]. Penelitian ini menunjukkan bahwa pemilihan fitur menggunakan algoritma *Information Gain* dapat mempermudah dalam menentukan fitur-fitur yang relevan untuk proses klasifikasi serta mampu memberikan hasil evaluasi yang lebih optimal dibandingkan dengan ketika tidak dilakukan seleksi fitur sama sekali.

Berdasarkan hasil dari ketiga penelitian tersebut, dapat disimpulkan bahwa penerapan metode seleksi fitur *Information Gain* secara signifikan mampu meningkatkan kinerja algoritma klasifikasi, baik pada *Random Forest*, *Naïve Bayes Classifier*, maupun *neighbor weighted k-nearest neighbor*. Peningkatan ini terlihat dari akurasi yang lebih tinggi serta pemahaman yang lebih mendalam terhadap fitur-fitur yang paling berpengaruh dalam proses klasifikasi. Hal tersebut yang kemudian melatarbelakangi ide dalam penelitian ini untuk menerapkan seleksi fitur *Information Gain* dalam klasifikasi tulang tengkorak berdasarkan jenis kelamin menggunakan metode *Backpropagation*. Penelitian ini menggunakan dataset *William White Howells Craniometric*, yang merupakan kumpulan data pengukuran tengkorak manusia yang dikumpulkan oleh Dr. William W. Howells antara tahun 1965 hingga 1980 (Auerbach, n.d.). Dataset tersebut terdiri dari 2.524 data dengan 86 fitur.

Tujuan dari penelitian ini adalah untuk menerapkan metode seleksi fitur *Information Gain* pada algoritma *Backpropagation* dalam proses klasifikasi jenis kelamin berdasarkan struktur tulang tengkorak, serta untuk mengetahui tingkat akurasi dari kombinasi kedua metode tersebut dalam melakukan klasifikasi. Penelitian ini diharapkan dapat memberikan kontribusi yang signifikan dalam bidang antropologi forensik, khususnya dalam pengembangan metode identifikasi jenis kelamin yang lebih akurat dan efisien. Dengan menggabungkan teknik klasifikasi *Backpropagation* dan seleksi fitur *Information Gain*, penelitian ini diharapkan mampu mempercepat proses identifikasi, meningkatkan akurasi hasil klasifikasi, serta memberikan dukungan ilmiah bagi proses penyelidikan kasus kriminal, penegakan hukum, dan pengungkapan identitas korban yang tidak dikenal.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan metode seleksi fitur *Information Gain* untuk memilih fitur-fitur paling relevan terhadap target klasifikasi. Fitur terpilih kemudian diproses menggunakan algoritma *Backpropagation* pada jaringan saraf tiruan untuk membangun model klasifikasi yang lebih akurat. Kombinasi kedua metode ini diharapkan mampu meningkatkan performa prediksi sekaligus mengurangi risiko overfitting. Adapun langkah-langkah tahapan pada penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1 Pengumpulan Data

Penelitian ini menggunakan data sekunder berupa dataset kranimetri yang dikumpulkan oleh Dr. William W.Howells dalam rentang waktu 1965 hingga 1980. Dataset tersebut diunduh dari situs <https://web.utk.edu/~auerbach/HOWL.htm> dan berisi 2.524 sampel tengkorak manusia, yang terdiri atas 1.368 individu berjenis kelamin laki-laki dan 1.156 perempuan. Terdapat 85 fitur pengukuran pada setiap sampel yang digunakan sebagai dasar dalam proses klasifikasi jenis kelamin (*Male* dan *Female*). Parameter yang dikodekan untuk setiap fitur tengkorak dan pengukuran tulang tengkorak pada masing-masing variabel akan dijelaskan pada Tabel 1 dan Tabel 2.

Tabel 1. Fitur Pengukuran Tulang Tengkorak

Kode	Fitur Parameter Tulang Tengkorak
GOL	Glabello-Occipital Length
BNL	Basion-Nasion Length
AUB	Biauricular breadth
PAC	Parietal Chord
NPH	Nasion-prosthion height
PAF	Parietal fraction
BBH	Basion-Bregma Height
XCB	Maximum Cranial Breadth
ZMB	Bimaxillary breadth
ZYB	Bizygomatic Breadth
...	...
TBA	Thiobarbituric acid

Tabel 1 menyajikan daftar fitur-fitur parameter pengukuran tulang tengkorak yang digunakan dalam proses klasifikasi. Setiap fitur diberi kode tertentu, seperti GOL untuk Glabello-Occipital Length, BNL untuk Basion-Nasion Length, dan seterusnya, yang merepresentasikan berbagai dimensi atau karakteristik morfologi tengkorak.

Tabel 2. Pengukuran Tulang Tengkorak

CLASS	GOL	ZYB	AUB	RFA	OCA	...	TBA
M	189	133	119	0	117	...	0
M	182	137	125	0	119	...	0
M	191	134	125	0	111	...	0
M	178	129	121	0	111	...	0
F	159	117	106	61	132	...	154
F	156	113	102	63	133	...	151
...
F	160	117	112	60	131	...	156

Tabel 2 menampilkan data hasil pengukuran tulang tengkorak berdasarkan berbagai fitur yang telah ditentukan sebelumnya, seperti GOL (*Glabello-Occipital Length*), ZYB (*Bizygomatic Breadth*), AUB (*Biauricular Breadth*), dan lainnya. Setiap baris mewakili satu individu dengan label kelas (*CLASS*) yaitu **M** (laki-laki) atau **F** (perempuan), yang menunjukkan jenis kelamin subjek. Nilai-nilai numerik pada setiap kolom mencerminkan hasil pengukuran morfologi tengkorak yang digunakan sebagai data input dalam proses klasifikasi.

2.2 Data Preprocessing

Pada tahapan preprocessing akan dilakukan proses membersihkan, mengubah, dan mengatur ulang data agar sesuai dengan analisis atau pemodelan yang akan dilakukan. Tahap data *preprocessing* adalah sebagai berikut :



- Seleksi Data* : Langkah pertama adalah memilih fitur yang relevan agar data yang digunakan tidak mengandung informasi yang tidak perlu atau berulang. Dalam penelitian ini, fitur *ID* dan *Population* dihapus karena *ID* hanya menunjukkan nomor identitas data, sedangkan *Population* sudah diwakili oleh fitur *PopNum*. Setelah itu, dilakukan pemilihan fitur penting menggunakan metode *Information Gain*.
- Cleaning Data* : Tahap ini bertujuan untuk membersihkan data dari berbagai permasalahan seperti data yang hilang (missing values) dan data yang duplikat. Jika ditemukan data yang sama atau memiliki nilai kosong, maka data tersebut akan dihapus agar dataset yang digunakan menjadi lebih bersih dan akurat untuk proses analisis selanjutnya. Selain itu, juga dilakukan pemeriksaan terhadap data *outlier* menggunakan metode *Z-score* guna mengidentifikasi nilai-nilai ekstrem yang secara statistik menyimpang dari sebaran normal.
- Transformasi Data* : Transformasi data dilakukan untuk menyesuaikan format dan skala data sebelum digunakan dalam proses pemodelan. Salah satu tahap transformasi adalah *encoding* fitur kategorikal. Pada variabel *Sex*, dilakukan pengkodean di mana nilai “female” diubah menjadi 0 dan “male” menjadi 1. Selain itu, dilakukan proses normalisasi terhadap dataset menggunakan metode *min-max normalization* agar seluruh nilai pada variabel memiliki rentang antara 0 hingga 1. Min-Max Normalization dihitung menggunakan rumus yang ditunjukkan pada Persamaan 1.

$$X_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Dalam Persamaan 1, X merupakan nilai asli dari suatu fitur atau variabel, seperti hasil pengukuran panjang atau lebar pada tulang tengkorak. Selanjutnya, X_{min} adalah nilai minimum dari fitur tersebut di seluruh data, sedangkan X_{max} adalah nilai maksimumnya. Hasil dari proses ini adalah X_{norm} , yaitu nilai yang telah dinormalisasi.

2.3 Feature Selection Information Gain

Teknik seleksi fitur telah diterapkan secara luas di berbagai bidang, seperti klasifikasi teks, analisis genomik, deteksi intrusi, bioinformatika, dan lain sebagainya [23]. Salah satu metode seleksi fitur yang sering digunakan adalah Information Gain. Metode ini berfungsi untuk mengurangi jumlah fitur yang tidak relevan serta menurunkan dimensi data yang akan dianalisis [29]. Langkah – Langkah perhitungan Information Gain adalah sebagai berikut :

- Menghitung nilai entropy. Entropy adalah ukuran ketidakpastian kelas yang memanfaatkan kemungkinan peristiwa atau fitur tertentu.

$$Entropy(S) = - \sum_i^n p_i \log_2 p_i \quad (2)$$

- Melakukan Perhitungan *Information Gain* menggunakan Persamaan

$$Gain(S, A) = Entropy(S) - \sum_{values(A)} \frac{|S_v|}{|S|} Entropy(S_v) \quad (3)$$

Pada Persamaan 2 dan 3, $Gain(S, A)$ adalah ukuran efektivitas suatu fitur A dalam mengurangi ketidakpastian (entropy) pada data. $Entropy(S)$ menunjukkan total entropy sebelum pemisahan, sedangkan $Values(A)$ adalah himpunan nilai yang mungkin dimiliki oleh fitur A . $|S_v|$ menyatakan jumlah sampel dengan nilai v , dan $|S|$ adalah total seluruh sampel. $Entropy(S_v)$ merupakan entropy dari subset data dengan nilai fitur tertentu.

2.4 K-Fold Cross Validation

K-fold cross-validation merupakan salah satu metode evaluasi yang banyak digunakan dalam pengujian model machine learning, dengan tujuan menghasilkan estimasi kinerja model yang lebih akurat melalui pembagian dataset menjadi k bagian yang setara [30]. Dalam penerapannya, dataset dibagi menjadi k subset atau lipatan, di mana setiap subset secara bergiliran digunakan sebagai data validasi, sementara sisa $k-1$ subset lainnya dimanfaatkan untuk melatih model. Agar pola dalam data dapat dikenali, data tersebut harus terlebih dahulu melalui proses pembelajaran. Oleh karena itu, pemisahan data menjadi langkah yang penting dan diperlukan dalam tahapan ini. [31]. Tujuan dari proses ini adalah untuk menyempurnakan model klasifikasi sehingga dapat digunakan untuk menghasilkan prediksi yang lebih akurat. [31]. Dalam penelitian ini akan diterapkan metode *k-fold cross-validation* dengan jumlah lipatan (K) sebanyak 10 dan 20.

2.5 Pemodelan Backpropagation

Backpropagation merupakan algoritma pembelajaran terawasi (*supervised learning*) yang terdiri dari dua tahap utama, yaitu perambatan maju (*forward propagation*) dan perambatan mundur (*backward propagation*) [19]. Algoritma ini bekerja dengan melakukan pembaruan secara terus-menerus terhadap bobot dan bias untuk meminimalkan nilai kesalahan. Semakin kecil nilai kesalahan yang dihasilkan, maka semakin tinggi pula akurasi dari neural network yang dibangun. Langkah-langkah perhitungan algoritma *Backpropagation* adalah sebagai berikut:

- Inisialisasi parameter Neural Network (lapisan input, lapisan tersembunyi, lapisan output, dan laju pembelajaran). Jumlah dari lapisan tersembunyi dapat menggunakan Persamaan 4,

$$l < m < 2l \quad (4)$$

- Inisialisasi bobot dan bias dengan angka acak.
- Setiap node pada lapisan input menerima sinyal input dan diteruskan ke setiap node pada lapisan tersembunyi dengan menerapkan Persamaan 5,



$$h_i = \sum_{i=1}^n x_i W_i + b_{hi} \quad (5)$$

d. Setelah mendapatkan nilai h_i -nya, terapkan fungsi aktivasi sigmoid biner ke setiap nilai dengan Persamaan 6,

$$y_i = h_i + \frac{1}{1+e^{-h_i}} \quad (6)$$

e. Setiap nilai di node tersembunyi diteruskan ke setiap node di lapisan output menggunakan Persamaan 5.

f. Setelah mendapatkan nilai pada node output, terapkan fungsi aktivasi sigmoid biner pada setiap nilai dengan Persamaan 6 untuk mendapatkan nilai output.

g. Hitung turunan dari nilai kesalahan pada y_i menggunakan metode entropi silang biner dengan Persamaan 7,

$$ce = -\frac{1}{n} \left(\sum_{i=1}^n (t_i \times \log(y_i)) + ((1 - t_i) \times \log(1 - y_i)) \right) \quad (7)$$

h. Hitung turunan dari nilai kesalahan pada setiap output (y_i) menggunakan Persamaan 8,

$$\frac{\partial E_i}{\partial y_i} = -1 \times \left(t_i \times \frac{1}{y_i} \right) + (1 - t_i) + \left(\frac{1}{1-y_i} \right) \quad (8)$$

i. Hitung turunan dari setiap o_i menggunakan persamaan turunan sigmoid biner dengan Persamaan 9,

$$\frac{\partial y_i}{\partial o_i} = f(o_i) \times (1 - f(o_i)) \quad (9)$$

j. Hitung perubahan bobot V_{ho} dan bias b_{oi} dengan menggunakan Persamaan 10 untuk perhitungan bobot dan Persamaan 11 untuk perhitungan bias :

$$\delta V_{ho} = \frac{\partial E_i}{\partial o_i} = \frac{\partial E_i}{\partial y_i} \times \frac{\partial y_i}{\partial o_i} = Z_i \quad (10)$$

$$\delta b_{oi} = \frac{\partial E_i}{\partial o_i} = \frac{\partial E_i}{\partial y_i} \times \frac{\partial y_i}{\partial o_i} \quad (11)$$

k. Hitung nilai bobot V_{ho} dan bias b_{oi} yang baru.

l. Hitung turunan dari setiap node tersembunyi menggunakan persamaan turunan sigmoid biner dengan Persamaan 9

m. Hitung nilai kesalahan untuk setiap node tersembunyi.

n. Hitung perubahan bobot dan bias yang menghubungkan lapisan input dengan lapisan tersembunyi dengan mengalikan hasil yang diperoleh dari langkah 12 dan 13 menggunakan Persamaan 10 untuk perhitungan bobot dan Persamaan 11 untuk perhitungan bias.

Setelah proses pembaruan bobot selesai dilakukan, algoritma akan kembali ke tahap *forward propagation* dan terus berjalan hingga mencapai jumlah *epoch* maksimum. *Epoch* sendiri merujuk pada satu siklus penuh pelatihan di mana seluruh data pelatihan telah diproses oleh jaringan saraf dan kemudian dimulai kembali untuk siklus berikutnya. Dengan kata lain, satu *epoch* berarti seluruh dataset pelatihan telah digunakan sekali dalam proses pelatihan jaringan. Umumnya, seiring dengan bertambahnya jumlah *epoch*, nilai kesalahan (*error*) dari pelatihan akan menurun secara bertahap hingga mencapai titik konvergensi, yaitu kondisi di mana perubahan nilai error menjadi sangat kecil atau stabil.

2.6 Implementasi dan Evaluasi

Implementasi merupakan tahap penting dalam proses penelitian, di mana desain sistem yang telah dirancang direalisasikan secara teknis dan sistematis berdasarkan dokumen resmi. Dalam penelitian ini, implementasi dilakukan untuk menerapkan algoritma *Backpropagation* yang telah dikombinasikan dengan metode seleksi fitur *Information Gain*. Implementasi dilakukan menggunakan bahasa pemrograman *Python* dengan platform *Google Colab*. Spesifikasi ini dipilih untuk memastikan proses pengujian dan pelatihan model dapat berjalan secara efisien dan optimal.

Tahap evaluasi ini bertujuan untuk menilai kinerja model yang telah dibangun. Salah satu metode yang umum digunakan untuk mengukur tingkat akurasi algoritma adalah *Confusion Matrix*. Adapun beberapa langkah evaluasi yang dilakukan melalui confusion matrix adalah sebagai berikut:

a. Akurasi

Akurasi adalah persentase dari prediksi yang benar terhadap keseluruhan data. Dengan Persamaan berikut:

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (12)$$

Persamaan 12, meliputi True Positive (TP) yang merupakan jumlah prediksi yang benar ketika model mengklasifikasikan data sebagai positif sesuai dengan kenyataannya. True Negative (TN) menunjukkan jumlah prediksi yang tepat saat model mengidentifikasi data sebagai negatif dan memang benar negatif. Sementara itu, False Positive (FP) terjadi ketika model secara keliru memprediksi data sebagai positif padahal seharusnya negatif. Sebaliknya, False Negative (FN) merupakan kesalahan prediksi di mana model mengklasifikasikan data sebagai negatif padahal sebenarnya data tersebut positif. Keempat istilah ini digunakan untuk mengevaluasi kinerja model klasifikasi.

b. Precision



Precision mengukur proporsi prediksi positif yang benar dari semua prediksi positif yang dibuat oleh model. Dengan Persamaan berikut:

$$Precision = \frac{TP}{TP+FP} \quad (13)$$

c. Recall

Mengukur proporsi prediksi positif yang benar dari semua kasus positif yang sebenarnya. Dengan Persamaan berikut:

$$Recall = \frac{TP}{TP+FN} \quad (14)$$

d. F1-Score

F1-Score merupakan rata-rata harmonis antara precision dan recall. Dengan Persamaan berikut:

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision+Recall} \quad (15)$$

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Dataset terdiri dari 2.524 data tulang tengkorak, terdiri atas 1.368 laki-laki dan 1.156 perempuan, dengan 85 fitur pengukuran yang digunakan sebagai dasar klasifikasi jenis kelamin (*Male* dan *Female*).

3.2 Data Preprocessing

- a. *Seleksi Data* : Pada langkah ini, dilakukan penghapusan tiga variabel yang terletak pada kolom pertama, ketiga, dan keempat, yaitu “ID”, “PopNum”, dan “Population” karena hanya berupa indeks yang tidak digunakan dalam pengolahan data. Setelah penghapusan, jumlah fitur berkurang dari 86 menjadi 83, yang terdiri dari 82 variabel fitur dan 1 variabel label. Hasil dari seleksi data ditampilkan pada Gambar 2.

	Sex	GOL	NOL	BNL	BBH	XCB	XFB	ZYB	AUB	WCB	...	FRA	PAA	OCA	RFA	RPA	ROA	BSA	SBA	SLA	TBA
0	M	189	185	100	135	143	120	133	119	70	...	134	133	117	0	0	0	0	0	0	0
1	M	182	178	102	139	145	120	137	125	66	...	128	134	119	0	0	0	0	0	0	0
2	M	191	187	102	123	140	114	134	125	74	...	129	137	111	0	0	0	0	0	0	0
3	M	191	188	100	127	141	123	135	127	71	...	128	135	108	0	0	0	0	0	0	0
4	M	178	177	97	128	138	117	129	121	69	...	133	130	111	0	0	0	0	0	0	0

5 rows x 83 columns

Gambar 2. Hasil Seleksi Data

- b. *Cleaning Data* : Pada tahap ini, dilakukan pemeriksaan untuk memastikan apakah terdapat data yang duplikat atau data yang hilang (*missing value*). Berdasarkan hasil pemeriksaan, tidak ditemukan adanya data duplikat maupun data yang hilang sesuai Gambar 3 .

```

Missing values in each column:
Sex      0
GOL      0
NOL      0
BNL      0
BBH      0
..
ROA      0
BSA      0
SBA      0
SLA      0
TBA      0
Length: 83, dtype: int64
Total missing values: 0

```

Gambar 3. Hasil Cleaning Data

Selain itu, telah dilakukan deteksi *outlier* menggunakan metode *Z-score* dan ditemukan total sebanyak 547 data yang tergolong sebagai *outlier*. Namun, dalam penelitian ini, data *outlier* tersebut tidak dihapus atau dihilangkan, melainkan tetap disertakan dalam proses analisis. Keputusan ini diambil untuk menjaga keutuhan data asli serta mempertahankan representasi variasi biologis alami pada struktur tulang tengkorak, yang justru dapat memberikan informasi penting dalam proses klasifikasi jenis kelamin.

- c. *Transformasi Data*: Pada langkah ini, dilakukan transformasi pada fitur Sex dimana Male dikonversi menjadi 1 dan Female dikonversi menjadi 0. Selanjutnya, proses normalisasi yang diterapkan pada seluruh fitur kecuali kelas sex, dengan menggunakan Persamaan 1. Dengan hasil yang ditampilkan pada Gambar 4.



```

Sex      GOL      NOL      BNL      BBH      XCB      XFB      ZYB \
0 1 0.690909 0.693878 0.459459 0.583333 0.529412 0.50 0.528302
1 1 0.563636 0.551020 0.513514 0.666667 0.568627 0.50 0.603774
2 1 0.727273 0.734694 0.513514 0.333333 0.470588 0.38 0.547170
3 1 0.727273 0.755102 0.459459 0.416667 0.490196 0.56 0.566038
4 1 0.490909 0.530612 0.378378 0.437500 0.431373 0.44 0.452830

      AUB      WCB      ...      FRA      PAA      OCA      RFA      RPA      ROA      BSA      SBA \
0 0.411765 0.40625 ... 0.645161 0.44 0.375 0.0 0.0 0.0 0.0 0.0
1 0.529412 0.28125 ... 0.451613 0.48 0.425 0.0 0.0 0.0 0.0 0.0
2 0.529412 0.53125 ... 0.483871 0.60 0.225 0.0 0.0 0.0 0.0 0.0
3 0.568627 0.43750 ... 0.451613 0.52 0.150 0.0 0.0 0.0 0.0 0.0
4 0.450980 0.37500 ... 0.612903 0.32 0.225 0.0 0.0 0.0 0.0 0.0

      SLA      TBA
0 0.0 0.0
1 0.0 0.0
2 0.0 0.0
3 0.0 0.0
4 0.0 0.0
    
```

Gambar 4. Hasil Normalisasi Data

Hasil pada Gambar 4 memperlihatkan bahwa seluruh nilai fitur telah berada dalam rentang 0 hingga 1, menandakan bahwa proses normalisasi berhasil dilakukan. Normalisasi ini bertujuan untuk menyamakan skala antar fitur sehingga tidak ada fitur yang mendominasi perhitungan jarak dalam proses klasifikasi.

3.3 Information Gain

Seleksi fitur *Information Gain* dimulai dengan menghitung nilai *entropy* fitur *sex* menggunakan Persamaan 2. Hasil dari perhitungan ditampilkan pada Gambar 5.

Entropy of Sex: 0.9949049393031937

Gambar 5. Hasil Perhitungan Entropy

Setelah didapatkan nilai *entropy*, kemudian dilanjutkan dengan perhitungan *Information Gain* menggunakan Persamaan 3. Output yang dihasilkan dari seleksi fitur berupa nilai dari masing-masing fitur yang telah dievaluasi. Hasil perhitungan *Information Gain* tersaji pada Tabel 3 serta pada Tabel 4 tersaji urutan nilai *Information Gain* dari yang tertinggi.

Tabel 3. Hasil Perhitungan Information Gain

Feature	Information Gain	Feature	Information Gain
ASB	0,127848271	NLB	0,048992675
AUB	0,184492768	NLH	0,14379941
AVR	0,143916119	NOL	0,205257669
BAA	0,015448905	NPH	0,145542502
BAR	0,037480992	OBB	0,107799445
BBA	0,008719277	OBH	0,019757622
BBH	0,170530935	OCA	0,012147055
BNL	0,176754638	OCC	0,045435106
BPL	0,1009411	OCF	0,033228754
BRA	0,010451491	OCS	0,020676415
BRR	0,127734752	OSR	0,052135431
BSA	0,027382948	PAA	0,003205368
DKA	0,019172631	PAC	0,112220115
DKB	0,044552043	PAF	0,055527797
DKR	0,143044725	PAS	0,032198941
DKS	0,010468085	PRA	0,010856414
EKB	0,190466594	PRR	0,13582375
EKR	0,113758117	RFA	0,008085378
FMB	0,223080269	ROA	0,019510076
FMR	0,123460568	RPA	0,012758596
FOL	0,091566523	SBA	0,010726108
FRA	0,047850312	SIA	0,078313929
FRC	0,160686958	SIS	0,049989087
FRF	0,121628305	SLA	0,012496673
FRS	0,011918792	SOS	0,179671486
GLS	0,158686562	SSA	0,011866532
GOL	0,232582141	SSR	0,157058959
IML	0,098739429	SSS	0,040835354
JUB	0,322660278	STB	0,044645066



Feature	Information Gain	Feature	Information Gain
LAR	0,068972508	TBA	0,018431562
MAB	0,18658099	VRR	0,154433423
MDB	0,207877794	WCB	0,122412331
MDH	0,264109654	WMH	0,081576882
MLS	0,063742844	WNB	0,048661034
NAA	0,016873142	XCB	0,10999366
NAR	0,189654618	XFB	0,108968846
NAS	0,034223996	XML	0,193243595
NBA	0,01200173	ZMB	0,212248253
NDA	0,035569887	ZMR	0,110233769
NDS	0,043294906	ZOR	0,115164838
NFA	0,01125423	ZYB	0,354120049

Tabel 3 menampilkan hasil perhitungan Information Gain untuk setiap fitur yang digunakan dalam penelitian. Nilai Information Gain ini mencerminkan sejauh mana masing-masing fitur berkontribusi dalam mengurangi ketidakpastian (entropy) terhadap klasifikasi data. Semakin tinggi nilai Information Gain suatu fitur, semakin besar perannya dalam proses pemisahan kelas secara akurat.

Tabel 4. Perangkingan Hasil Perhitungan Information Gain

No	Feature	Information Gain	No	Feature	Information Gain
1	ZYB	0,3541	42	SIA	0,0783
2	JUB	0,3227	43	LAR	0,069
3	MDH	0,2641	44	MLS	0,0637
4	GOL	0,2326	45	PAF	0,0555
5	FMB	0,2231	46	OSR	0,0521
6	ZMB	0,2122	47	SIS	0,05
7	MDB	0,2079	48	NLB	0,049
8	NOL	0,2053	49	WNB	0,0487
9	XML	0,1932	50	FRA	0,0479
10	EKB	0,1905	51	OCC	0,0454
11	NAR	0,1897	52	STB	0,0446
12	MAB	0,1866	53	DKB	0,0446
13	AUB	0,1845	54	NDS	0,0433
14	SOS	0,1797	55	SSS	0,0408
15	BNL	0,1768	56	BAR	0,0375
16	BBH	0,1705	57	NDA	0,0356
17	FRC	0,1607	58	NAS	0,0342
18	GLS	0,1587	59	OCF	0,0332
19	SSR	0,1571	60	PAS	0,0322
20	VRR	0,1544	61	BSA	0,0274
21	NPH	0,1455	62	OCS	0,0207
22	AVR	0,1439	63	OBH	0,0198
23	NLH	0,1438	64	ROA	0,0195
24	DKR	0,143	65	DKA	0,0192
25	PRR	0,1358	66	TBA	0,0184
26	ASB	0,1278	67	NAA	0,0169
27	BRR	0,1277	68	BAA	0,0154
28	FMR	0,1235	69	RPA	0,0128
29	WCB	0,1224	70	SLA	0,0125
30	FRF	0,1216	71	OCA	0,0121
31	ZOR	0,1152	72	NBA	0,012
32	EKR	0,1138	73	FRS	0,0119
33	PAC	0,1122	74	SSA	0,0119
34	ZMR	0,1102	75	NFA	0,0113
35	XCB	0,11	76	PRA	0,0109
36	XFB	0,109	77	SBA	0,0107
37	OBB	0,1078	78	DKS	0,0105
38	BPL	0,1009	79	BRA	0,0105
39	IML	0,0987	80	BBA	0,0087
40	FOL	0,0916	81	RFA	0,0081



No	Feature	Information Gain	No	Feature	Information Gain
41	WMH	0,0816	82	PAA	0,0032

Tabel 4 menyajikan urutan fitur berdasarkan nilai Information Gain dari yang tertinggi hingga terendah. Berdasarkan nilai tersebut, dilakukan pemilihan fitur dengan mempertimbangkan seberapa besar peran fitur tersebut dalam mengurangi ketidakpastian (*entropy*) data. Semakin tinggi nilai *Information Gain* yang dimiliki suatu fitur, maka semakin relevan dan signifikan fitur tersebut dalam mendukung proses klasifikasi. Untuk menentukan fitur mana saja yang akan dipertahankan, digunakan ambang batas (*threshold*). Dengan menggunakan *threshold* pertama sebesar 0,01, maka fitur-fitur yang memiliki nilai *Information Gain* di bawah angka tersebut dianggap kurang relevan untuk digunakan dalam pemodelan. Terdapat tiga fitur yang memiliki nilai di bawah ambang batas minimal (*threshold*) 0,01, yaitu BBA (*Basion-Bregma Height*) sebesar 0,0087, RFA (*Right Frontomolare Orbitale*) sebesar 0,0081, dan PAA (*Prosthion-Alveolon Length*) sebesar 0,0032. Nilai yang rendah ini menunjukkan bahwa ketiga fitur tersebut tidak memberikan informasi yang cukup penting dalam membedakan jenis kelamin berdasarkan bentuk atau ukuran tulang tengkorak. Fitur BBA mengukur tinggi tengkorak dari bawah ke atas, tetapi dalam data yang digunakan, perbedaan tinggi ini tidak terlalu jelas antara laki-laki dan perempuan. RFA mengukur bagian kanan atas wajah dekat mata, namun hasilnya tidak konsisten atau cukup berbeda antarjenis kelamin. Sedangkan PAA mengukur panjang bagian depan rahang atas, yang juga tidak terlalu berpengaruh dalam membedakan jenis kelamin. Karena kontribusinya kecil, ketiga fitur ini dianggap tidak efektif dan tidak digunakan dalam pemodelan. Selanjutnya penggunaan *threshold* 0.05 menghasilkan 46 fitur, dan 0.1 menghasilkan 38 fitur. Hanya fitur-fitur yang memiliki nilai *Information Gain* di atas ambang batas tersebut yang dipilih untuk digunakan dalam pembangunan model klasifikasi. Pendekatan ini bertujuan untuk meningkatkan akurasi model sekaligus mengurangi kompleksitas dan overfitting.

3.4 Pembagian Data

Teknik yang digunakan untuk pembagian data adalah *10-fold cross-validation* dan *20-fold cross-validation*. Di mana saat $K=10$, digunakan 2.272 data sebagai data pelatihan untuk melatih model, dan 252 data digunakan sebagai data pengujian guna mengevaluasi performa model setelah proses pelatihan. Sementara itu, pada saat menggunakan $K=20$, sebanyak 2.398 data dimanfaatkan sebagai data pelatihan, dan 126 data sisanya digunakan untuk pengujian model. Selanjutnya mendeklarasikan Feature Vector dan Target Variable sesuai fitur terbaik berdasarkan *threshold* yang sudah ditentukan. Hasil deklarasi dan pembagian data sesuai Tabel 5 dan Tabel 6.

Tabel 5. Hasil pembagian data sesuai $K=10$


	Threshold		
	0.01	0.05	0.1
x_train	(2272, 79)	(2272, 46)	(2272, 38)
x_test	(252, 79)	(252, 46)	(252, 38)

Tabel 6. Hasil pembagian data sesuai $K=20$

	Threshold		
	0.01	0.05	0.1
x_train	(2398, 79)	(2398, 46)	(2398, 38)
x_test	(126, 79)	(126, 46)	(126, 38)

3.5 Backpropagation

Backpropagation secara luas diakui karena efektivitasnya dalam melatih jaringan saraf dengan banyak lapisan (*multi-layer neural networks*), serta menjadi dasar utama bagi berbagai penerapan di bidang kecerdasan buatan. Struktur jaringan *Backpropagation* ditampilkan pada Gambar 6.



Gambar 6. Arsitektur Jaringan Backpropagation dengan 1 Hidden Layer



Gambar 6 menunjukkan arsitektur *Backpropagation* yang dibangun berdasarkan hasil seleksi fitur *Information Gain* dengan *threshold* 0.01. Arsitektur *Backpropagation* tersebut terdiri dari 79 neuron pada input layer, 119 neuron pada hidden layer, dan 1 neuron pada output layer. Parameter *Backpropagation* yang digunakan meliputi fungsi aktivasi sigmoid, learning rate (0.1, 0.01, dan 0.001), serta maksimum *epoch* sebesar 1000. Proses pelatihan *Backpropagation* dilakukan sebanyak tiga kali percobaan untuk setiap satu kali pengujian. Sistem akan menghasilkan tiga nilai akurasi yang berbeda, kemudian menghitung dan menampilkan rata-rata dari ketiga akurasi tersebut sebagai output akhir.

3.6 Evaluasi dan Pengujian

Pengujian dilakukan terhadap tiga skenario, yaitu: Seleksi fitur *Information Gain* dengan *threshold* 0.01, 0.05, dan 0.1. Learning rate yang digunakan dalam pengujian adalah 0.1, 0.01 dan 0.001. Pada skenario seleksi fitur *Information Gain* dengan *threshold* 0.01, arsitektur *Backpropagation* yang digunakan terdiri dari tiga konfigurasi berbeda yang mencakup struktur input layer, hidden layer, dan output layer. 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 12 sampai Persamaan 15. Hasil Pengujian seleksi fitur *Information Gain* menggunakan $K=10$ disajikan pada Tabel 7 dan $K=20$ disajikan pada Tabel 8.

Tabel 7. Hasil Pengujian seleksi fitur Information Gain $K=10$

No	Treshold Information Gain	Learning Rate	Arsitektur BPNN 1 Hidden Layer	Accuracy Rata- Rata
1	0.01	0.1	79:80:1	90,48
2		0.01		89,68
3		0.001		90,48
4		0.1	79:119:1	90,08
5		0.01		91,27
6		0.001		91,27
7		0.1	79:157:1	90,87
8		0.01		90,48
9		0.001		90,48
10	0.05	0.1	46:47:1	90,08
11		0.01		89,68
12		0.001		90,87
13		0.1	46:69:1	92,06
14		0.01		90,48
15		0.001		91,27
16		0.1	46:91:1	90,87
17		0.01		91,27
18		0.001		91,67
19	0.1	0.1	38:39:1	89,68
20		0.01		90,87
21		0.001		89,29
22		0.1	38:57:1	89,29
23		0.01		89,29
24		0.001		88,49
25		0.1	38:75:1	89,29
26		0.01		89,29
27		0.001		89,29

Tabel 7 menunjukkan bahwa akurasi tertinggi diperoleh dengan menggunakan seleksi fitur *Information Gain* sebesar 92,06% pada *threshold* 0,05, dengan konfigurasi *learning rate* 0,1 dan arsitektur *Backpropagation* [46:69:1].

Tabel 8. Hasil Pengujian seleksi fitur Information Gain $K=20$

No	Treshold Information Gain	Learning Rate	Arsitektur BPNN 1 Hidden Layer	Accuracy Rata- Rata
1	0.01	0.1	79:80:1	93,12
2		0.01		93,38
3		0.001		92,06
4		0.1	79:119:1	92,59
5		0.01		93,91
6		0.001		92,06
7		0.1	79:157:1	93,39




No	Threshold Information Gain	Learning Rate	Arsitektur BPNN 1 Hidden Layer	Accuracy Rata-Rata
8		0.01		92,33
9		0.001		92,86
10	0.05	0.1	46:47:1	92,33
11		0.01		90,48
12		0.001		92,59
13		0.1	46:69:1	92,86
14		0.01		87,83
15		0.001		89,95
16		0.1	46:91:1	91,74
17		0.01		89,68
18		0.001		90,48
19	0.1	0.1	38:39:1	75,40
20		0.01		90,21
21		0.001		90,74
22		0.1	38:57:1	91,80
23		0.01		90,21
24		0.001		91,53
25		0.1	38:75:1	74,60
26		0.01		89,15
27		0.001		89,15

Tabel 8 menunjukkan bahwa akurasi tertinggi diperoleh sebesar 93,91% pada *threshold* 0.01, dengan konfigurasi *learning rate* 0.01 dan arsitektur *Backpropagation* [79:119:1]. Variasi akurasi yang terlihat dalam setiap skenario menunjukkan bahwa performa model dipengaruhi oleh kombinasi arsitektur dan learning rate yang digunakan. Semakin tepat pemilihan jumlah neuron pada setiap layer dan nilai learning rate yang sesuai, maka semakin optimal pula hasil klasifikasi yang diperoleh. Hal ini mengindikasikan bahwa tuning parameter seperti *threshold* seleksi fitur, jumlah neuron pada hidden layer, dan learning rate memiliki peran penting dalam meningkatkan akurasi model *Backpropagation*.

Evaluasi dilakukan setelah tahap pengujian dengan menggunakan *confusion matrix* guna menganalisis tingkat ketepatan dan kesalahan prediksi model. Berdasarkan hasil pengujian dengan penerapan seleksi fitur Information Gain pada konfigurasi dengan akurasi tertinggi, model mampu mengklasifikasikan secara tepat sebanyak 67 data pada kelas female (True Positive) dan 47 data pada kelas male (True Negative). Namun demikian, masih terdapat 1 data pada kelas female yang diklasifikasikan secara keliru sebagai male (False Positive), serta 11 data pada kelas male yang salah diklasifikasikan sebagai female (False Negative). Secara keseluruhan, temuan ini menunjukkan bahwa model memiliki performa yang cukup baik dalam melakukan klasifikasi jenis kelamin berdasarkan karakteristik tulang tengkorak. Hasil *confusion matrix* dapat dilihat pada .

Tabel 9. Hasil *confusion matrix* dengan akurasi tertinggi pada pengujian *Backpropagation*



Hasil penelitian ini menunjukkan bahwa akurasi tertinggi diperoleh sebesar 93,91% pada *threshold* 0,01 dengan konfigurasi *learning rate* 0,01. Temuan ini mengindikasikan bahwa kombinasi antara pemilihan fitur yang tepat melalui *Information Gain* dan pengaturan parameter model yang optimal, khususnya pembagian data dan *learning rate*, dapat secara signifikan meningkatkan performa klasifikasi jenis kelamin berdasarkan karakteristik morfologis tulang tengkorak. Hasil ini sesuai dengan temuan dalam penelitian [19] yang menggunakan *Backpropagation* tanpa seleksi fitur memperoleh akurasi 92,32%, sementara kombinasi *Backpropagation* dengan seleksi fitur *information gain* dalam penelitian ini dapat meningkatkan akurasi menjadi 93,91%. Hasil ini menunjukkan pengaruh seleksi fitur dalam meningkatkan performa model klasifikasi.



4. KESIMPULAN

Penelitian ini bertujuan untuk meningkatkan akurasi klasifikasi jenis kelamin berdasarkan struktur tulang tengkorak dengan menerapkan metode *Information Gain* sebagai seleksi fitur dan algoritma *Backpropagation*. Dataset yang digunakan merupakan data kranimetri William W. Howells yang terdiri dari 2.524 sampel dengan 85 fitur pengukuran. Setelah tahap pra-processing, dilakukan seleksi fitur menggunakan *Information Gain* dengan tiga ambang batas (threshold) yaitu : 0.01, 0.05, dan 0.1. Masing-masing threshold menghasilkan 79, 46, dan 38 fitur terpilih. Pengujian dilakukan menggunakan metode *K-Fold Cross Validation* dengan nilai K=10 dan K=20. Arsitektur *Backpropagation* terdiri dari satu hidden layer, dengan beberapa konfigurasi jumlah neuron. Model diuji dengan kombinasi tiga nilai *learning rate* (0.1, 0.01, 0.001) untuk masing-masing threshold. Hasil pengujian menunjukkan bahwa akurasi tertinggi sebesar 93,91% diperoleh pada threshold 0,01 dengan arsitektur [79:119:1] dan *learning rate* 0,01 menggunakan K=20. Temuan ini membuktikan bahwa penerapan *Information Gain* efektif dalam meningkatkan performa klasifikasi dengan mengeliminasi fitur-fitur yang tidak relevan, sekaligus menekan risiko *overfitting*. Hasil ini sesuai dengan temuan dalam penelitian Kadarman et al. (2024) yang menggunakan *Backpropagation* tanpa seleksi fitur dan memperoleh akurasi sebesar 92,32%, sementara kombinasi *Backpropagation* dengan seleksi fitur *Information Gain* dalam penelitian ini dapat meningkatkan akurasi menjadi 93,91%. Variasi hasil akurasi antar skenario juga menunjukkan bahwa performa model sangat dipengaruhi oleh kombinasi antara arsitektur jaringan dan parameter *learning rate*. Selain itu, penelitian ini juga menemukan bahwa akurasi model dapat menurun jika fitur yang masih relevan tereliminasi akibat threshold yang terlalu tinggi. Namun, perlu diperhatikan bahwa penelitian ini hanya menggunakan metode seleksi fitur berbasis hubungan linier. Oleh karena itu, penelitian selanjutnya disarankan untuk mencoba menggunakan algoritma klasifikasi lain seperti Random Forest atau K-Nearest Neighbor agar bisa dibandingkan dengan hasil dari *Backpropagation*. Selain itu, penelitian juga dapat ditingkatkan dengan menambahkan proses optimasi seperti *Grid Search* atau algoritma Genetika untuk menemukan kombinasi parameter terbaik. Akan lebih baik juga jika model diuji menggunakan dataset dari populasi berbeda agar hasilnya bisa digunakan secara lebih luas dan tidak hanya terbatas pada satu jenis data. Untuk penelitian selanjutnya, disarankan juga agar dilakukan eksperimen perbandingan antara model dengan dan tanpa data outlier, guna mengetahui sejauh mana keberadaan data ekstrem ini mempengaruhi performa klasifikasi. Pendekatan ini juga dapat membantu dalam memahami peran variasi biologis alami yang tercermin dari nilai-nilai ekstrem dalam data kranimetri.

REFERENCES

- [1] A. M. Christensen, N. V. Passalacqua, and E. J. Bartelink, "Introduction to forensic anthropology," *Forensic Anthropol.*, pp. 1–31, 2019, doi: 10.1016/B978-0-12-815734-3.00001-4.
- [2] 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/ijfimt.v14i3.10315.
- [3] E. Nikita and P. Nikitas, "On the use of machine learning algorithms in forensic anthropology," *Leg. Med.*, vol. 47, Nov. 2020, doi: 10.1016/J.LEGALMED.2020.101771.
- [4] Y. Harni, I. Afrianty, S. Sanjaya, R. Abdillah, 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, pp. 211–218–211–218, Jun. 2023, doi: 10.47065/BITS.V5I1.3625.
- [5] I. Afrianty, D. Nasien, and H. Haron, "Performance Analysis of Support Vector Machine in Sex Classification of The Sacrum Bone in Forensic Anthropology," *J. Tek. Inform.*, vol. 15, no. 1, pp. 63–72, Jun. 2022, doi: 10.15408/JTI.V15I1.25254.
- [6] D. H. Ubelaker and H. Khosrowshahi, "Estimation of Age in Forensic Anthropology: Historical Perspective and Recent Methodological Advances," *Forensic Sci. Res.*, vol. 4, no. 1, pp. 1–9, Jan. 2019, doi: 10.1080/20961790.2018.1549711.
- [7] 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, Mar. 2020, doi: 10.32890/JICT2020.19.2.5.
- [8] Haeril, Sulaeman, and M. Akbar Syafruddin, "Profil indeks massa tubuh atlet cabang bela diri Komite Olahraga Nasional Indonesia Kota Makassar," *J. Sport Sci.*, vol. 12, no. 2, pp. 90–98, 2022, doi: 10.17977/um057v12i2p90-98.
- [9] N. Techataweewan, J. T. Hefner, L. Freas, N. Surachotmongkhon, R. Benchawattananon, and N. Tayles, "Metric sexual dimorphism of the skull in Thailand," *Forensic Sci. Int. Reports*, vol. 4, Nov. 2021, doi: 10.1016/J.FSIR.2021.100236.
- [10] S. Braun, A. F. Ridel, E. N. L'Abbé, C. E. Theye, and A. C. Oetlér, "Repeatability of a morphoscopic sex estimation technique for the mental eminence on micro-focus X-ray computed tomography models," *Forensic Imaging*, vol. 28, p. 200500, Mar. 2022, doi: 10.1016/J.FRI.2022.200500.
- [11] D. H. Toneva, S. Y. Nikolova, G. P. Agre, D. K. Zlatareva, V. G. Hadjidekov, and N. E. Lazarov, "Data mining for sex estimation based on cranial measurements," *Forensic Sci. Int.*, vol. 315, Oct. 2020, doi: 10.1016/j.forsciint.2020.110441.
- [12] J. Tetteh, A. K. Appiah, C. S. Abaidoo, and C. Adjei-Antwi, "The forensic use of percutaneous femur length in height and sex estimation among Ghanaians," *Forensic Sci. Int. Reports*, vol. 4, p. 100234, Nov. 2021, doi: 10.1016/J.FSIR.2021.100234.
- [13] M. K. Misiani, T. Amuti, S. Darbar, P. Mandela, E. Maranga, and M. Obimbo, "Sex determination from dimensions of distal tibiae in adult Kenyans: A discriminant function analysis," *Transl. Res. Anat.*, vol. 20, p. 100075, Sep. 2020, doi: 10.1016/J.TRIA.2020.100075.
- [14] D. Toneva, S. Nikolova, G. Agre, D. Zlatareva, V. Hadjidekov, and N. Lazarov, "Machine learning approaches for sex estimation using cranial measurements," *Int. J. Legal Med.*, vol. 135, no. 3, pp. 951–966, May 2021, doi: 10.1007/S00414-020-02460-4.
- [15] S. Sri Rahayu et al., "Klasifikasi Tulang Tengkorak Berdasarkan Jenis Kelamin dalam Antropologi Forensik Menggunakan Metode Support Vector Machine," *INOVTEK Polbeng - Seri Inform.*, vol. 9, no. 1, p. 2024, Jun. 2024, doi: 10.35314/ISI.V9I1.4046.
- [16] F. Curate, "The Estimation of Sex of Human Skeletal Remains in the Portuguese Identified Collections: History and Prospects,"



- Forensic Sci.*, vol. 2, no. 1, pp. 272–286, Mar. 2022, doi: 10.3390/FORENSICSCI2010021.
- [17] 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.
- [18] Darmila, “Evaluasi Perbandingan Performansi Lvq 1, Lvq 2, Dan Lvq 3 Dalam Klasifikasi Jenis Kelamin Menggunakan Tulang Tengkorak,” *J. instek (informatika sains dan Teknol.*, vol. 7, pp. 344–353, 2022, [Online]. Available: <http://journal.uin-alauddin.ac.id/index.php/instek/index>
- [19] M. Kadarman, I. Afrianty, E. Budianita, and F. Syafria, “Klasifikasi Tulang Tengkorak Manusia Berdasarkan Jenis Kelamin Menggunakan Backpropagation Pada Antropologi Forensik,” *J. CoSciTech (Computer Sci. Inf. Technol.*, vol. 5, no. 3, pp. 619–625, Dec. 2024, doi: 10.37859/COSCITECH.V5I3.8235.
- [20] A. Herdiansah, R. I. Borman, D. Nurnaningsih, A. A. J. Sinlae, and R. R. Al Hakim, “Klasifikasi Citra Daun Herbal Dengan Menggunakan Backpropagation Neural Networks Berdasarkan Ekstraksi Ciri Bentuk,” *JURIKOM (Jurnal Ris. Komputer)*, vol. 9, no. 2, p. 388, Apr. 2022, doi: 10.30865/JURIKOM.V9I2.4066.
- [21] A. Gunawan, S. Thamrin, Y. D. Kuntjoro, and A. M. Idris, “Backpropagation Neural Network (BPNN) Algorithm for Predicting Wind Speed Patterns in East Nusa Tenggara,” *Trends Renew. Energy*, vol. 8, no. 2, pp. 107–118, Apr. 2022, doi: 10.17737/TRE.2022.8.2.00143.
- [22] D. S. Al-Azzawi, “Application and evaluation of the neural network in gearbox,” *TELKOMNIKA (Telecommunication Comput. Electron. Control.*, vol. 18, no. 1, pp. 19–29, Feb. 2020, doi: 10.12928/TELKOMNIKA.V18I1.13760.
- [23] F. N. Fajriyan, M. Ahsan, and W. Harianto, “Komparasi Tingkat Akurasi Information Gain Dan Gain Ratio Pada Metode K-Nearest Neighbor,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 6, no. 1, pp. 386–391, Apr. 2022, doi: 10.36040/JATI.V6I1.4694.
- [24] D. Setiawan, A. Nugraha, and A. Luthfiarta, “Komparasi Teknik Feature Selection Dalam Klasifikasi Serangan IoT Menggunakan Algoritma Decision Tree,” *J. Media Inform. Budidarma*, vol. 8, no. 1, p. 83, 2024, doi: 10.30865/mib.v8i1.6987.
- [25] T. Azhima Yoga Siswa and W. Joko Pranoto, “Implementasi Seleksi Fitur Information Gain Ratio Pada Algoritma Random Forest Untuk Model Data Klasifikasi Pembayaran Kuliah,” *Din. Inform. J. Ilm. Teknol. Inf.*, vol. 15, pp. 41–49, 2023, doi: 10.35315/INFORMATIKA.V15I1.9465.
- [26] S. N. Salsabila, B. N. Sari, and R. Mayasari, “Klasifikasi Ulasan Pengguna Aplikasi Discord Menggunakan Metode Information Gain Dan Naïve Bayes Classifier,” *INFOTECH J.*, vol. 9, no. 2, pp. 383–392, Jul. 2023, doi: 10.31949/INFOTECH.V9I2.6277.
- [27] I. K. Hasan, R. Resmawan, and J. Ibrahim, “Perbandingan K-Nearest Neighbor dan Random Forest dengan Seleksi Fitur Information Gain untuk Klasifikasi Lama Studi Mahasiswa,” *Indones. J. Appl. Stat.*, vol. 5, no. 1, pp. 58–66, May 2022, doi: 10.13057/IJAS.V5I1.58056.
- [28] R. A. Azizah, F. A. Bachtiar, and S. Adinugroho, “Klasifikasi Kinerja Akademik Siswa Menggunakan Neighbor Weighted K-Nearest Neighbor Dengan Seleksi Fitur Information Gain,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 3, pp. 605–614, 2022, doi: 10.25126/jtiik.202295751.
- [29] P. a Bagaskara, N. Y. Setiawan, and A. R. . . Perdanakusuma, “Analisis dan Perbaikan Proses Bisnis dengan Menggunakan Metode Business Process Improvement (BPI) Pada PT. Andynni Chitta Sejahtera,” ... *Tek. Inf. dan ...*, vol. 3, no. 8, pp. 7635–7641, 2019, [Online]. Available: <http://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/5928>
- [30] H. Azis, P. Purnawansyah, F. Fattah, and I. P. Putri, “Performa Klasifikasi K-NN dan Cross Validation Pada Data Pasien Pengidap Penyakit Jantung,” *Ilk. J. Ilm.*, vol. 12, no. 2, pp. 81–86, 2020, doi: 10.33096/ilkom.v12i2.507.81-86.
- [31] W. Wijiyanto, A. I. Pradana, S. Sopingi, and V. Atina, “Teknik K-Fold Cross Validation untuk Mengevaluasi Kinerja Mahasiswa,” *J. Algoritma*, vol. 21, no. 1, pp. 239–248, 2024, doi: 10.33364/algoritma/v.21-1.1618.