



Implementasi dan Optimalisasi Metode Naive Bayes Dalam Sistem Deteksi Dini Penyakit Tiroid

Nurhasanah*, Nilovar Asyiah, Okta Irawati

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Pamulang, Tangerang Selatan

Jl. Raya Puspittek, Buaran, Kec. Pamulang, Kota Tangerang Selatan, Banten, Indonesia

Email: ^{1,*}dosen02834@unpam.ac.id, ²dosen02835@unpam.ac.id, ³dosen02610@unpam.ac.id

Email Penulis Korespondensi: dosen02834@unpam.ac.id

Submitted: 09/07/2025; Accepted: 31/07/2025; Published: 31/07/2025

Abstrak—Penelitian ini bertujuan untuk mengembangkan sistem deteksi dini penyakit tiroid menggunakan algoritma Naive Bayes. Dataset yang digunakan adalah Thyroid Disease Dataset dari UCI Machine Learning Repository, yang terdiri dari ribuan sampel data pasien. Sebelum digunakan dalam pelatihan model, data melalui tahap preprocessing seperti penanganan data hilang, normalisasi numerik, dan encoding data kategorikal. Proses klasifikasi dilakukan dengan menghitung nilai prior probability, likelihood, dan posterior probability untuk masing-masing kelas: normal, hipotiroid, dan hipertiroid. Sistem ini juga menyediakan persentase kemungkinan tiap kelas sebagai hasil akhir diagnosis otomatis. Akurasi sistem dihitung menggunakan metode Confusion Matrix, yang menghasilkan tingkat akurasi sebesar 98,01% pada data pengujian. Hasil ini menunjukkan bahwa pendekatan yang digunakan mampu memberikan klasifikasi yang efektif dan akurat dalam mendeteksi penyakit tiroid secara dini.

Kata Kunci: Naive Bayes; Deteksi Dini; Penyakit Tiroid; Confusion Matrix; Machine Learning

Abstract—This study aims to develop an early detection system for thyroid disease using the Naive Bayes algorithm. The dataset used is the Thyroid Disease Dataset from the UCI Machine Learning Repository, consisting of thousands of patient records. Prior to model training, the data undergoes preprocessing steps such as handling missing values, numerical normalization, and categorical encoding. The classification process involves calculating the prior probability, likelihood, and posterior probability for each class: normal, hypothyroid, and hyperthyroid. The system also presents the probability percentage for each class as an automated diagnosis result. Model accuracy is evaluated using a Confusion Matrix, achieving an accuracy score of 98.01% on the test data. These results indicate that the proposed approach can effectively and accurately classify thyroid conditions for early diagnosis purposes.

Keywords: Naive Bayes; Early Detection; Thyroid Disease; Confusion Matrix; Machine Learning

1. PENDAHULUAN

Penyakit tiroid merupakan salah satu gangguan endokrin yang berdampak signifikan terhadap keseimbangan metabolisme tubuh [1]. Gangguan ini dapat menimbulkan berbagai komplikasi serius seperti gangguan jantung, infertilitas, kelelahan kronis, bahkan gangguan psikologis seperti depresi apabila tidak dideteksi dan ditangani sejak dini [2]. Diagnosis dini terhadap penyakit tiroid menjadi kunci untuk meningkatkan kualitas hidup penderita, mempercepat pengobatan, dan menurunkan risiko komplikasi [3]. Namun, proses diagnosis konvensional yang dilakukan melalui interpretasi klinis dan uji laboratorium seperti pengukuran kadar hormon TSH, T3, dan T4 memerlukan waktu, biaya, dan keahlian medis yang tinggi [4]. Hal ini menjadi tantangan tersendiri di wilayah dengan keterbatasan fasilitas kesehatan seperti puskesmas atau klinik kecil.

Data dari Kementerian Kesehatan Republik Indonesia menunjukkan bahwa prevalensi hipotiroidisme meningkat sebesar 13,7% dalam kurun waktu lima tahun terakhir, menjadikan penyakit tiroid sebagai salah satu permasalahan kesehatan masyarakat yang memerlukan perhatian serius [5]. Di sisi lain, masih banyak kasus gangguan tiroid yang tidak terdiagnosis karena gejalanya yang samar dan menyerupai gangguan kesehatan lainnya [6]. Kondisi ini mendorong perlunya solusi alternatif berbasis teknologi, khususnya kecerdasan buatan (Artificial Intelligence/AI), untuk mempercepat dan mempermudah proses diagnosis penyakit tiroid [7].

Machine learning sebagai cabang dari AI telah banyak digunakan dalam dunia medis untuk membangun sistem pendukung keputusan klinis (clinical decision support system) [8]. Salah satu algoritma yang populer adalah Naive Bayes, yang dikenal sederhana namun efektif dalam melakukan klasifikasi pada data dengan dimensi besar [9]. Beberapa studi sebelumnya menunjukkan keberhasilan penerapan algoritma ini pada deteksi penyakit tiroid. Penelitian oleh Kumar et al. [10] menerapkan Support Vector Machine (SVM) namun hanya pada klasifikasi biner antara kondisi normal dan tidak normal. Singh dan Thakur [11] menggunakan Random Forest untuk klasifikasi serupa, namun tanpa penyesuaian pada distribusi kelas yang tidak seimbang. Sementara itu, Ahmed et al. [12] menggunakan dataset dari populasi Eropa yang memiliki perbedaan karakteristik dengan populasi Asia, sehingga hasilnya belum tentu dapat diadaptasi pada konteks lokal.

Selain keterbatasan pada jenis data dan cakupan klasifikasi, sebagian besar penelitian sebelumnya juga belum mengimplementasikan sistem secara utuh dalam bentuk aplikasi yang siap digunakan oleh pengguna akhir, seperti tenaga medis atau operator kesehatan [13]. Beberapa studi juga tidak memanfaatkan teknik preprocessing lanjutan seperti seleksi fitur [14], normalisasi data [15], atau penanganan data tidak seimbang [16]. Padahal, langkah-langkah ini sangat penting untuk meningkatkan kinerja model dalam mendeteksi kondisi spesifik seperti hipotiroid dan hipertiroid [17].



Penelitian ini bertujuan untuk mengembangkan sistem deteksi dini penyakit tiroid berbasis algoritma Naive Bayes yang telah dioptimalkan. Proses pengembangan dimulai dari pengumpulan data menggunakan Thyroid Disease Dataset dari UCI Machine Learning Repository yang memiliki klasifikasi multikelas (normal, hipotiroid, hipertiroid) [18]. Tahapan preprocessing meliputi penanganan missing values, normalisasi, transformasi data kategorikal, serta seleksi fitur menggunakan metode ANOVA F-test [19]. Untuk mengatasi ketidakseimbangan kelas, digunakan teknik Synthetic Minority Oversampling Technique (SMOTE) [20]. Model Naive Bayes yang digunakan adalah varian Gaussian Naive Bayes yang sesuai untuk fitur numerik kontinu [21].

Sistem ini kemudian diimplementasikan dalam bentuk aplikasi desktop berbasis Python yang dilengkapi antarmuka pengguna sederhana, serta mampu memberikan hasil deteksi berupa probabilitas klasifikasi setiap kategori tiroid. Performa sistem diuji menggunakan Confusion Matrix serta metrik akurasi, presisi, recall, dan F1-score. Hasil menunjukkan bahwa sistem mampu mencapai akurasi sebesar 98,01%, menunjukkan efektivitas model dalam mendeteksi kondisi tiroid secara tepat.

Kontribusi utama dari penelitian ini adalah pengembangan sistem diagnosis yang tidak hanya akurat secara statistik, tetapi juga dapat diterapkan langsung pada praktik klinis. Sistem ini berpotensi mempercepat waktu diagnosis dari 2–7 hari (pemeriksaan laboratorium konvensional) menjadi hanya dalam hitungan menit. Dengan demikian, solusi ini diharapkan dapat digunakan di fasilitas kesehatan primer sebagai alat bantu diagnosis awal, yang akan membantu mengurangi beban dokter dan memperluas akses layanan kesehatan yang lebih cepat dan akurat bagi masyarakat.

2. METODOLOGI PENELITIAN

2.1 Analisis Kebutuhan Pengguna Sistem (User)

Analisis kebutuhan pengguna sistem bertujuan untuk mengidentifikasi data yang diperlukan dalam sistem deteksi dini penyakit tiroid. Sistem ini dirancang berbasis desktop untuk memudahkan pengguna dalam proses input, pemeriksaan, dan penyimpanan data pasien secara terintegrasi. Kebutuhan sistem terbagi menjadi dua jenis utama, yaitu input data pasien dan input data pemeriksaan. Input data pasien meliputi ID Pasien (dengan format A001, A002, dan seterusnya), Nama Lengkap, Jenis Kelamin, Tempat dan Tanggal Lahir, Alamat, serta Nomor Handphone. Informasi ini dikumpulkan untuk identifikasi dan keperluan administrasi medis secara menyeluruh [22]. Setelah semua data dimasukkan oleh pengguna, sistem akan secara otomatis menyimpan informasi tersebut ke dalam basis data internal.

Selanjutnya, input pemeriksaan mencakup Kode Deteksi (format K001, K002, dst.), serta lima parameter uji laboratorium yang bersumber dari dataset Thyroid Disease, yaitu T3RU Test (nilai antara 65–144 berdasarkan RIA), Total Serum T4 (0.5–25.3), Total Serum T3 (0.2–10), Basal TSH (0.1–56.4), dan Maximal Absolute Difference of TSH (–0.7 hingga 56.3) [23]. Parameter-parameter ini diakui secara klinis sebagai indikator penting dalam mendeteksi kelainan fungsi tiroid. Setelah data pemeriksaan diinput, sistem memproses informasi tersebut menggunakan algoritma Gaussian Naive Bayes untuk menentukan klasifikasi kondisi tiroid pasien, apakah termasuk kategori Normal, Hipertiroid, atau Hipotiroid. Hasil klasifikasi ini akan ditampilkan kepada pengguna dan disimpan kembali ke dalam database sistem untuk kepentingan dokumentasi dan analisis selanjutnya.

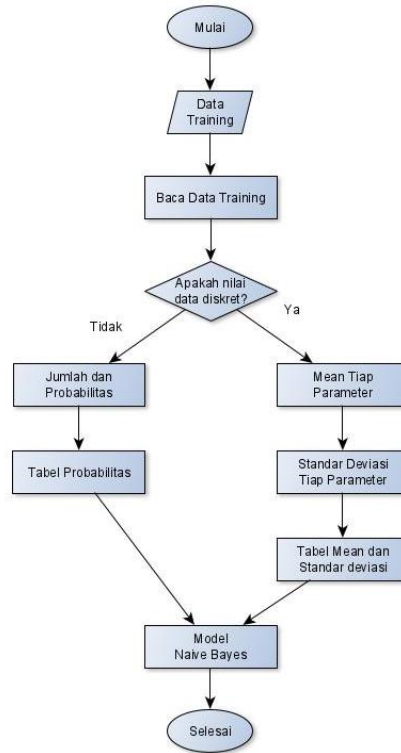
Langkah analisis kebutuhan pengguna ini sangat penting dalam membangun sistem yang tidak hanya fungsional, tetapi juga sesuai dengan kebutuhan praktik medis nyata, khususnya dalam membantu tenaga kesehatan melakukan deteksi awal secara cepat dan efisien di fasilitas pelayanan kesehatan dasar seperti puskesmas atau klinik swasta.

2.2 Pembuatan Rule Klasifikasi

Pada tahap implementasi perangkat lunak, sistem dirancang untuk menerapkan algoritma klasifikasi Naive Bayes dalam proses diagnosis penyakit tiroid. Algoritma ini bekerja dengan menghitung probabilitas posterior dari setiap kelas (Normal, Hipertiroid, dan Hipotiroid) berdasarkan data pemeriksaan yang telah dimasukkan oleh pengguna. Pembuatan rule klasifikasi diawali dengan pengumpulan data training dan preprocessing untuk memastikan data siap digunakan. Sistem kemudian menghasilkan rumusan probabilitas berdasarkan parameter uji laboratorium dan menerapkannya dalam fungsi distribusi Gaussian, sesuai dengan karakteristik Gaussian Naive Bayes [24].

Setelah seluruh parameter diperoleh, sistem menghitung probabilitas untuk masing-masing kelas diagnosis berdasarkan distribusi nilai dari dataset pelatihan. Hasil dari perhitungan ini akan menentukan keanggotaan data baru ke salah satu kelas tiroid. Proses pengambilan keputusan dilakukan dengan membandingkan nilai probabilitas tertinggi di antara ketiga kelas. Untuk memastikan transparansi proses klasifikasi, sistem juga menyimpan nilai probabilitas yang dihasilkan agar dapat ditinjau kembali jika diperlukan.

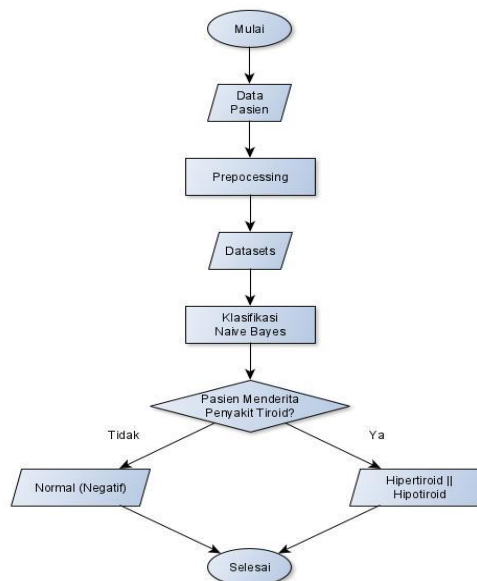
Proses ini diilustrasikan dalam Gambar 1. Pembuatan Rule Klasifikasi, yang memperlihatkan alur kerja sistem mulai dari input data pemeriksaan, perhitungan probabilitas berdasarkan distribusi Gaussian, hingga output berupa hasil klasifikasi kondisi tiroid pasien. Gambar tersebut menjelaskan bagaimana data pasien diproses melalui algoritma hingga sistem mampu menentukan hasil diagnosis secara otomatis dan efisien.



Gambar 1. Pembuatan Rule Klasifikasi

2.3 Rancangan Cara Sistem

Setelah data dari pasien berhasil diinput dan disimpan, sistem memanfaatkan algoritma Gaussian Naive Bayes untuk melakukan proses klasifikasi berdasarkan lima parameter uji laboratorium. Setiap data pasien dihitung probabilitasnya terhadap tiga kelas diagnosis (Normal, Hipertiroid, dan Hipotiroid) menggunakan distribusi Gaussian. Hasil klasifikasi ini menjadi dasar pengambilan keputusan sistem dalam mendeteksi kemungkinan jenis gangguan tiroid yang dialami pasien. Proses klasifikasi ini berjalan secara otomatis dan cepat sehingga memudahkan tenaga medis dalam membuat diagnosis awal. Proses ini divisualisasikan dalam Gambar 2. Proses Deteksi dengan Klasifikasi Naive Bayes yang menggambarkan alur dari input data, perhitungan probabilitas, hingga keluaran hasil klasifikasi sebagai diagnosis akhir pasien [25].



Gambar 1. Proses Deteksi Dengan Klasifikasi Naive Bayes

2.4 Thyroid Disease Datasets

Penelitian ini menggunakan Thyroid Disease Datasets yang bersumber dari UCI Machine Learning Repository. Dataset ini berisi 215 data pasien, terdiri dari 151 data untuk pelatihan (training data) dan 64 data untuk pengujian



(testing data). Dataset mencakup lima atribut utama yaitu: T3RU Test, Total Serum T4, Total Serum T3, Basal TSH, dan Maximal Absolute Difference of TSH [26]. Atribut-atribut ini dipilih karena merupakan indikator penting dalam diagnosis gangguan fungsi tiroid menurut literatur klinis.

Setiap atribut dalam dataset tersebut diolah dengan preprocessing sebelum digunakan dalam model Naive Bayes. Data kemudian dihitung rata-rata (mean), deviasi standar, dan probabilitas distribusi Gaussian untuk setiap kelas diagnosis. Proses ini menghasilkan nilai prior, likelihood, dan posterior probability untuk menentukan klasifikasi penyakit. Implementasi akurat dari metode ini memerlukan validasi menggunakan Confusion Matrix untuk mengevaluasi kinerja klasifikasi.

Dengan penggunaan dataset ini, sistem diharapkan dapat menghasilkan klasifikasi penyakit tiroid secara otomatis dengan akurasi tinggi dalam waktu yang lebih efisien dibandingkan dengan metode konvensional.

1. Contoh Kasus

Sebagai bagian dari pengujian sistem, dilakukan simulasi kasus berdasarkan nilai-nilai uji laboratorium pasien yang disajikan pada Tabel 1. Contoh Kasus. Data tersebut terdiri dari lima atribut penting yang digunakan dalam proses klasifikasi, yaitu T3RU Test dengan nilai 139, Total Serum T4 sebesar 16.4, Total Serum T3 sebesar 3.8, Basal TSH sebesar 1.1, dan Maximal Absolute Difference of TSH sebesar -0.2. Nilai-nilai ini kemudian diproses menggunakan algoritma Gaussian Naive Bayes untuk menghitung probabilitas terhadap masing-masing kelas diagnosis. Hasil dari perhitungan ini menunjukkan distribusi kemungkinan pasien tergolong dalam kondisi Normal, Hipertiroid, atau Hipotiroid berdasarkan nilai-nilai statistik yang telah ditentukan sebelumnya. Dengan demikian, Tabel 1 menjadi ilustrasi nyata penggunaan data aktual dalam mendeteksi gangguan tiroid secara otomatis dan berbasis sistem.

Tabel 1. Contoh Kasus

Attribute Name	Range
T3RU Test	139
Total Serum T4	16.4
Total Serum T3	3.8
Basal TSH	1.1
Maximal Absolute Difference of TSH	-0.2

a. Memisahkan 3 Class menjadi C1 untuk "Normal", C2 untuk "Hipertiroid", dan C3 untuk "Hipotiroid".

b. Mencari Prior Probability:

1) T3RU Test

a) $\bar{x} C1 = \frac{x1+x2+x3+\dots+xn}{n} = 110.885714285714$

b) $\bar{x} C2 = \frac{x1+x2+x3+\dots+xn}{n} = 93.56$

c) $\bar{x} C3 = \frac{x1+x2+x3+\dots+xn}{n} = 124$

2) Total Serum T4

a) $\bar{x} C1 = \frac{x1+x2+x3+\dots+xn}{n} = 9.40095238095238$

b) $\bar{x} C2 = \frac{x1+x2+x3+\dots+xn}{n} = 18.148$

c) $\bar{x} C3 = \frac{x1+x2+x3+\dots+xn}{n} = 3.36666666666667$

3) Total Serum T3

a) $\bar{x} C1 = \frac{x1+x2+x3+\dots+xn}{n} = 1.85809523809524$

b) $\bar{x} C2 = \frac{x1+x2+x3+\dots+xn}{n} = 4.684$

c) $\bar{x} C3 = \frac{x1+x2+x3+\dots+xn}{n} = 1.10952380952381$

4) Basal TSH

a) $\bar{x} C1 = \frac{x1+x2+x3+\dots+xn}{n} = 1.36857142857143$

b) $\bar{x} C2 = \frac{x1+x2+x3+\dots+xn}{n} = 0.948$

c) $\bar{x} C3 = \frac{x1+x2+x3+\dots+xn}{n} = 13.7047619047619$

5) Maximal absolute difference of TSH value

a) $\bar{x} C1 = \frac{x1+x2+x3+\dots+xn}{n} = 2.46095238095238$

b) $\bar{x} C2 = \frac{x1+x2+x3+\dots+xn}{n} = -0.052$

c) $\bar{x} C3 = \frac{x1+x2+x3+\dots+xn}{n} = 18.747619047619$

c. Mencari Standart Deviasi:

1) T3RU Test

$$a) \mu C1 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 8.2710271496284$$

$$b) \mu C2 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 18.6839503317687$$

$$c) \mu C3 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 8.71779788708135$$

2) Total Serum T4

$$a) \mu C1 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 1.95032025171485$$

$$b) \mu C2 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 4.05206943013896$$

$$c) \mu C3 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 1.79118210501706$$

3) Total Serum T3

$$a) \mu C1 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 0.432741918197864$$

$$b) \mu C2 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 2.41982781756609$$

$$c) \mu C3 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 0.614739588691636$$

4) Basal TSH

$$a) \mu C1 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 0.541421612643386$$

$$b) \mu C2 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 0.448255879307047$$

$$c) \mu C3 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 12.0337640075945$$

5) Maximal absolute difference of TSH value

$$a) \mu C1 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 2.03590346784982$$

$$b) \mu C2 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 0.26944387170615$$

$$c) \mu C3 = \sqrt{\frac{\sum_{i=1}^n (x1-\mu)^2}{n-1}} = 17.0707240340771$$

d. Mencari Distribusi Gaussian:

1) T3RU Test

$$a) f(C1) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 0.000429642524376435$$

$$b) f(C2) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 0.00479411309261196$$

$$c) f(C3) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 0.0307432065174933$$

2) Total Serum T4

$$a) f(C1) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 0.000456282825222516$$

$$b) f(C2) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 0.180540544672533$$

$$c) f(C3) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 9.48895163205804E-13$$

3) Total Serum T3

$$a) f(C1) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 0.0000257029206106873$$

$$b) f(C2) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 0.239856236025007$$

$$c) f(C3) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 0.0000352436767870279$$

4) Basal TSH

$$a) f(C1) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 0.479316880748057$$

$$b) f(C2) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 0.562459626504902$$

$$c) f(C3) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 0.0664322059490306$$

5) Maximal absolute difference of TSH value

$$a) f(C1) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 0.118985799081407$$

$$b) f(C2) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 0.660805226381294$$

$$c) f(C3) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = 0.0521404261315183$$

e. Mencari probabilitas setiap kelas:

1) Probabilitas Deteksi dengan hasil Normal berdasarkan perkalian antara 5 Likelihood Probability dari setiap atribut dan nilai Prior Probability setiap kelas adalah 2.2446265E-13.

2) Probabilitas Deteksi dengan hasil Hipertiroid berdasarkan perkalian antara 5 Likelihood Probability dari setiap atribut dan nilai Prior Probability setiap kelas adalah 1.4350813E-5.

3) Probabilitas Deteksi dengan hasil Hipotiroid berdasarkan perkalian antara 5 Likelihood Probability dari setiap atribut dan nilai Prior Probability setiap kelas adalah 5.5635843E-22.

Akhirnya diketahui hasil deteksi dengan membandingkan hasil probabilitas setiap kelas $C1 = 2.2446265E-13$, $C2 = 1.4350813E-5$ dan $C3 = 5.5635843E-22$. Sehingga hasil deteksi adalah C2 atau ‘Hipertiroid’, karena C2 lebih besar dari C1 dan C3.

2. Confusion Matrix

Confusion Matrix digunakan sebagai alat evaluasi untuk mengukur efektivitas model klasifikasi dalam sistem deteksi dini penyakit tiroid. Pada tahap ini, sistem diuji dengan menggunakan 151 data pelatihan untuk membandingkan hasil klasifikasi prediksi terhadap kelas sebenarnya. Dalam implementasinya, hasil deteksi sistem (kelas prediksi) dibandingkan dengan data referensi (kelas sebenarnya), dan disusun dalam Tabel 2. Confusion Matrix Data Training

Tabel 2. Confusion Matrix Data Training

		Kelas Prediksi		
		Normal	Hyper	Hypo
Kelas Sebenarnya	Normal	104	0	1
	Hyper	1	24	0
	Hypo	1	0	20
	TP	FN	FP	TN

Berdasarkan Tabel 2, diperoleh nilai True Positive (TP) sebanyak 104, True Negative (TN) sebanyak 44, False Positive (FP) sebanyak 2, dan False Negative (FN) sebanyak 1. Nilai-nilai ini menjadi dasar dalam menghitung akurasi sistem, yang dilakukan dengan rumus:

$$Akurasi = \frac{TP+TN}{TP+FN+FP+TN} \times 100\% = \frac{104+44}{104+1+2+44} = \frac{148}{151} = 98.0132\%$$

Kesimpulan yang diperoleh yaitu, dari 151 data training diperoleh akurasi kecocokan kelas target terhadap kelas prediksi dengan Naïve Bayes sebesar 98%.

3. HASIL DAN PEMBAHASAN

3.1 Hasil

Pada bagian ini akan dibahas mengenai hasil penelitian yang dimulai dari implementasi antarmuka, pembahasan pada hasil, dan pengujian sistem.

3.1.1 Implementasi Antarmuka

Antarmuka adalah tampilan atau interface sebagai layanan yang disediakan sistem operasi sebagai sarana interaksi antara pengguna dengan sistem operasi, dalam hal ini adalah perancangan sistem deteksi dini penyakit tiroid.

1. Implementasi Antarmuka Menu Login

Menu Login merupakan tampilan awal yang muncul setelah pengguna membuka aplikasi sistem deteksi penyakit tiroid. Pada menu ini, pengguna diwajibkan untuk memasukkan username dan password sebagai bagian dari proses autentikasi sebelum mengakses fitur-fitur sistem lainnya. Proses login ini dirancang untuk menjaga keamanan data dan memastikan bahwa hanya pengguna yang berwenang yang dapat mengakses sistem. Setelah informasi login diketikkan, pengguna dapat menekan tombol Login, dan jika data yang dimasukkan sesuai, maka sistem akan mengarahkan pengguna ke Menu Utama. Tampilan antarmuka menu login dapat dilihat pada Gambar 3. Antarmuka Menu Login.

**Gambar 3.** Antarmuka Menu Login

2. Implementasi Antarmuka Menu Utama

Setelah berhasil melakukan login, pengguna akan diarahkan ke Menu Utama, yang menjadi pusat navigasi dari seluruh fitur aplikasi. Pada menu ini terdapat lima buah tombol navigasi yang terdiri atas: Input Pasien, Input Pemeriksaan, Deteksi Tiroid, Data Pasien, dan Logout. Masing-masing tombol ini memiliki fungsi khusus dan akan membawa pengguna ke halaman terkait sesuai kebutuhan. Antarmuka Menu Utama dirancang secara sederhana namun fungsional, dengan tujuan agar mudah dipahami dan digunakan oleh tenaga medis maupun operator sistem. Tampilan antarmukanya ditunjukkan pada Gambar 4. Antarmuka Menu Utama.

**Gambar 4.** Antarmuka Menu Utama

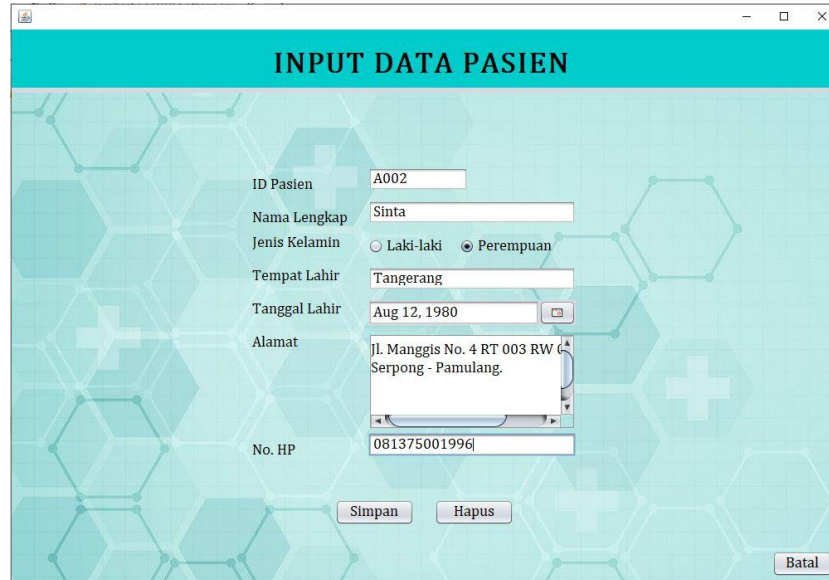
3. Implementasi Antarmuka Menu Deteksi

Salah satu fitur utama yang dapat diakses dari Menu Utama adalah menu Input Data Pasien. Saat pengguna memilih menu ini, sistem akan menampilkan formulir untuk memasukkan data pasien secara lengkap, yang meliputi ID Pasien, Nama Lengkap, Jenis Kelamin, Tempat Lahir, Tanggal Lahir, Alamat, dan Nomor Handphone. Seluruh data ini penting sebagai identifikasi awal dan basis data untuk proses pemeriksaan lebih lanjut. Dengan sistem input yang sistematis, kesalahan dalam pencatatan dapat diminimalkan dan efisiensi kerja dapat ditingkatkan. Tampilan antarmuka dari menu ini disajikan pada Gambar 5. Antarmuka Menu Input Pasien.

**Gambar 5.** Antarmuka Menu Deteksi

4. Implementasi Antarmuka Menu Input Pasien

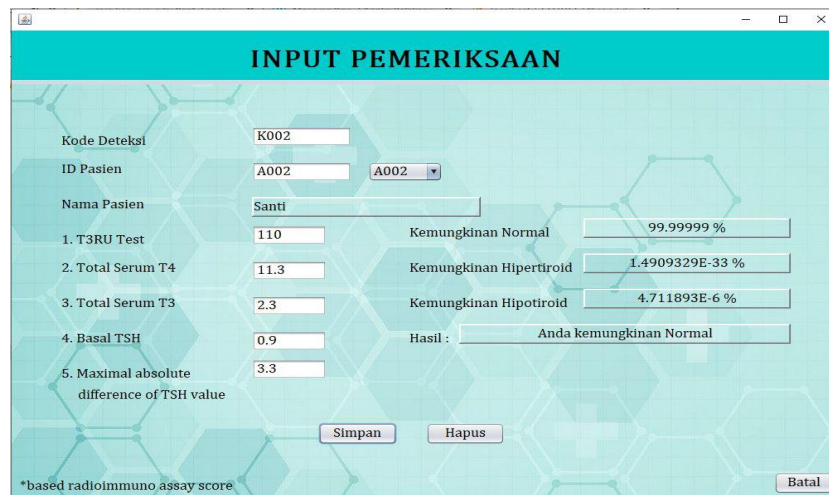
Setelah mengisi data pada formulir, pengguna dapat menyimpan informasi dengan menekan tombol simpan. Data yang telah dimasukkan kemudian akan langsung tersimpan ke dalam database internal sistem. Hal ini memudahkan proses penelusuran riwayat pasien apabila dibutuhkan di kemudian hari, serta mempercepat proses pemeriksaan dan diagnosa. Tampilan formulir input pasien ditampilkan kembali secara rinci dalam Gambar 6. Antarmuka Input Data Pasien.



Gambar 6. Antarmuka Input Data Pasien

5. Implementasi Antarmuka Menu Input Pemeriksaan

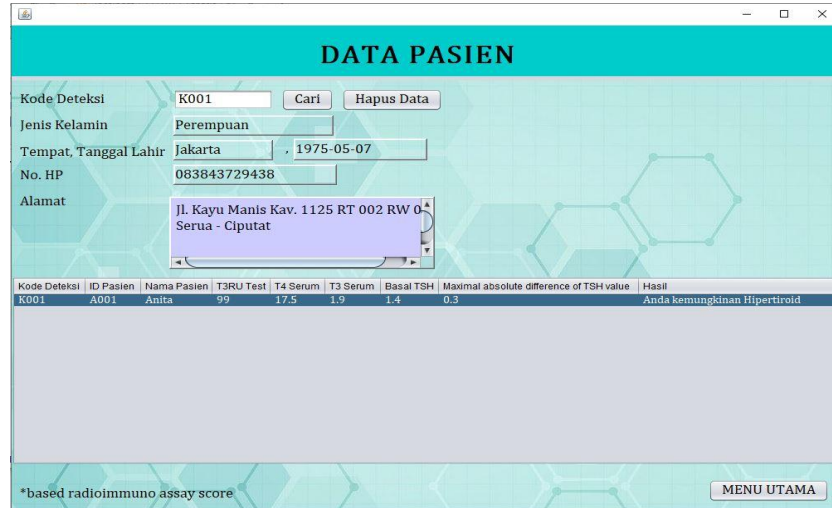
Antarmuka berikut menampilkan Menu Input Pemeriksaan, yaitu halaman yang diakses setelah pengguna memilih opsi pemeriksaan pada menu utama. Pada menu ini, pengguna dapat mengisi formulir yang berkaitan dengan hasil uji laboratorium pasien, seperti T3RU Test, Total Serum T4, Total Serum T3, Basal TSH, dan Maximal Absolute Difference of TSH. Formulir ini dirancang untuk memastikan data pemeriksaan dimasukkan secara lengkap dan sistematis, sehingga sistem dapat mengolah informasi tersebut menggunakan algoritma klasifikasi Naïve Bayes. Selain itu, antarmuka ini dirancang dengan layout yang intuitif agar memudahkan pengguna dalam melakukan input data tanpa mengalami kebingungan. Setiap field memiliki placeholder dan label yang jelas agar meminimalkan risiko kesalahan dalam pengisian data. Setelah data dimasukkan, pengguna cukup mengklik tombol "Simpan" untuk memproses data ke tahap klasifikasi dan menyimpannya ke dalam basis data aplikasi. Gambar 7 memperlihatkan tampilan antarmuka Menu Input Pemeriksaan secara keseluruhan.



Gambar 7. Antarmuka Input Pemeriksaan

6. Implementasi Antarmuka Menu Data Pasien

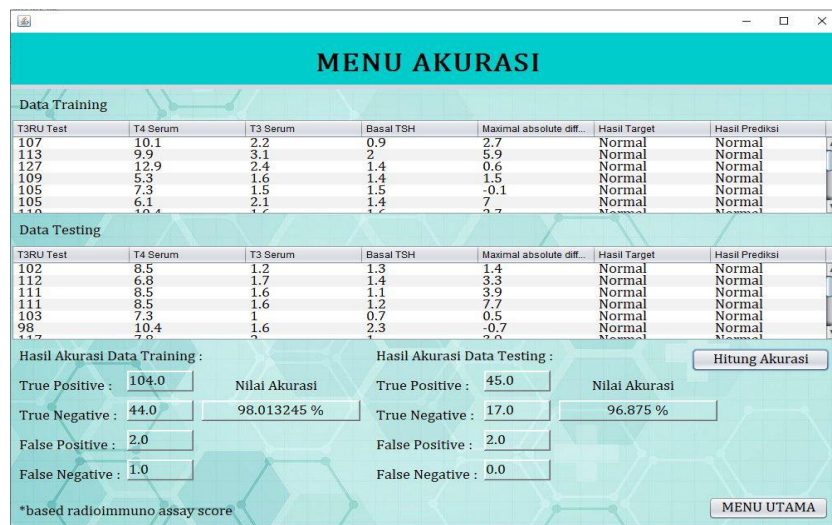
Menu Data Pasien menampilkan daftar seluruh pasien yang telah melakukan pemeriksaan melalui sistem. Antarmuka ini menyajikan informasi hasil input pasien secara rapi dan terstruktur, yang mencakup identitas pasien beserta hasil pemeriksaannya. Fitur ini memudahkan pengguna dalam melakukan pencarian, pemantauan, dan pengelolaan data pasien untuk keperluan diagnosis lanjutan ataupun dokumentasi medis. Tampilan ini dilengkapi dengan fitur pencarian berdasarkan ID atau nama pasien untuk mempermudah navigasi data. Selain itu, terdapat tombol aksi seperti "Edit" dan "Hapus" yang memungkinkan pengelolaan data secara real-time. Tampilan antarmuka ini dirancang responsif agar dapat digunakan secara optimal di berbagai ukuran layar desktop. Gambar 8 menunjukkan tampilan lengkap dari Menu Data Pasien dalam aplikasi.



Gambar 8. Antarmuka Menu Data Pasien

7. Implementasi Antarmuka Menu Akurasi

Antarmuka berikut menampilkan Menu Akurasi, yaitu halaman yang menyajikan data kelas training dan data kelas testing yang digunakan sebagai dasar perhitungan efektivitas klasifikasi menggunakan algoritma Naïve Bayes. Pada menu ini, sistem menyajikan data hasil klasifikasi yang dibandingkan dengan kelas sebenarnya dalam bentuk tabel, sehingga memudahkan pengguna untuk mengevaluasi kinerja algoritma yang digunakan. Halaman ini juga dilengkapi dengan tampilan yang sederhana dan informatif agar mudah dipahami oleh pengguna non-teknis. Selain itu, menu ini menyediakan ringkasan hasil akurasi dalam bentuk persentase agar pengguna dapat langsung memahami efektivitas sistem. Gambar 9 memperlihatkan antarmuka Menu Akurasi secara menyeluruh.



Gambar 9. Antarmuka Menu Akurasi

Berdasarkan tampilan pada gambar tersebut, diperoleh hasil akurasi dari data training sebesar 98%, sedangkan akurasi dari data testing mencapai 97%, menunjukkan performa klasifikasi sistem yang sangat baik. Nilai ini dihitung menggunakan metode Confusion Matrix, yang merupakan salah satu pendekatan evaluasi yang umum digunakan dalam bidang machine learning. Performa akurasi yang tinggi ini menunjukkan bahwa sistem mampu mendeteksi kondisi tiroid secara efektif dengan tingkat kesalahan yang sangat rendah. Evaluasi ini penting untuk menjamin bahwa hasil diagnosis yang diberikan sistem dapat diandalkan dalam konteks medis.

8. Implementasi Antarmuka Menu Tentang Aplikasi

Antarmuka berikut menampilkan Menu Tentang Aplikasi, yaitu halaman yang berfungsi untuk memberikan informasi singkat mengenai aplikasi yang sedang digunakan. Pada halaman ini ditampilkan sebuah kotak dialog yang berisi deskripsi aplikasi, tujuan pengembangan, serta informasi dasar seperti nama aplikasi dan teknologi yang digunakan dalam pengembangannya. Fitur ini membantu pengguna memahami konteks dan fungsi utama dari sistem. Selain itu, menu ini juga memberikan informasi tambahan terkait hak cipta dan nama pengembang sistem. Informasi ini berguna untuk memberikan kejelasan terhadap pihak-pihak yang terlibat

dalam pengembangan dan tujuan aplikasi. Gambar 10 memperlihatkan tampilan antarmuka Menu Tentang Aplikasi.



Gambar 10. Antarmuka Menu Tentang

3.2 Pembahasan

Berdasarkan sistem yang telah dibuat, dilakukan pengujian terhadap salah satu contoh kasus untuk memastikan bahwa proses klasifikasi berjalan dengan baik sesuai dengan algoritma yang digunakan. Contoh kasus ini menggunakan data pasien dengan lima atribut hasil pemeriksaan laboratorium yang telah dimasukkan ke dalam sistem, yaitu nilai T3RU Test, Total Serum T4, Total Serum T3, Basal TSH, dan Maximal Absolute Difference of TSH. Kelima atribut tersebut kemudian diproses menggunakan perhitungan probabilitas Gaussian Naïve Bayes untuk menentukan klasifikasi kondisi tiroid pasien.

Proses ini melibatkan pencarian nilai prior probability dari setiap kelas, perhitungan likelihood berdasarkan masing-masing atribut, hingga akhirnya diperoleh nilai posterior probability. Kelas dengan nilai probabilitas tertinggi akan menjadi hasil akhir diagnosis. Proses ini juga memastikan bahwa setiap variabel input memiliki kontribusi terhadap hasil akhir klasifikasi.

Gambar 11. Contoh Kasus Pemeriksaan menunjukkan bagaimana sistem menginput data pasien dan menghasilkan klasifikasi otomatis berdasarkan nilai-nilai medis yang diinput. Visualisasi ini menggambarkan secara menyeluruh jalannya proses klasifikasi dari awal hingga akhir dalam implementasi nyata di sistem.



Gambar 11. Contoh Kasus Pemeriksaan

Pada contoh kasus diketahui :
Kode Deteksi

: K003



ID Pasien	: A003
Nama Pasien	: Mirna
T3RU Test	: 118
Total Serum T4	: 6.5
Total Serum T3	: 1.3
Basal TSH	: 1.7
Maximal absolute difference of TSH value	: 11.5

Setelah dilakukan perhitungan menggunakan algoritma Naïve Bayes berdasarkan Thyroid Disease Datasets dan dari contoh kasus tersebut dapat dihasilkan:

Kemungkinan Normal : 0.38%

Kemungkinan Hipertiroid : 0.00%

Kemungkinan Hipotiroid : 99.62%

Akhirnya diketahui hasil deteksi dengan membandingkan hasil probabilitas setiap kelas Normal, Hipertiroid, dan Hipotiroid. Sehingga hasil deteksi adalah Kemungkinan Hipotiroid, karena kelas Hipotiroid lebih besar dari kelas Normal dan kelas Hipertiroid.

4. KESIMPULAN

Berdasarkan hasil penelitian, pengujian, implementasi, dan pembahasan yang telah dilakukan, dapat disimpulkan bahwa penerapan metode Naïve Bayes dalam sistem deteksi dini penyakit tiroid menunjukkan kinerja yang efektif dan akurat. Proses perancangan sistem dimulai dari pemilihan dataset Thyroid Disease sebagai sumber data utama yang berisi informasi medis pasien dengan berbagai kondisi tiroid. Dataset ini perlu melalui tahapan preprocessing yang meliputi pembersihan data, penanganan nilai hilang, dan normalisasi untuk memastikan kualitas dan konsistensi data sebelum diterapkan ke dalam proses klasifikasi. Setelah proses tersebut dilakukan, metode Naïve Bayes diterapkan dengan mengikuti langkah-langkah perhitungan prior probability, likelihood probability untuk masing-masing atribut, dan posterior probability guna menentukan klasifikasi akhir terhadap kondisi pasien tergolong normal, hipertiroid, atau hipotiroid. Sistem dirancang untuk menampilkan hasil prediksi disertai dengan nilai probabilitas untuk masing-masing kemungkinan diagnosis, di mana nilai tertinggi akan diambil sebagai hasil deteksi. Selanjutnya, pengujian akurasi sistem dilakukan dengan metode Confusion Matrix untuk mengevaluasi performa klasifikasi. Berdasarkan pengujian tersebut, sistem berhasil mencapai tingkat akurasi sebesar 98,01%, yang menunjukkan bahwa model mampu memberikan hasil klasifikasi dengan tingkat kesalahan yang sangat rendah. Angka ini memperkuat efektivitas penggunaan metode Naïve Bayes dalam mendeteksi penyakit tiroid secara otomatis dan cepat. Dengan demikian, sistem yang dikembangkan pada penelitian ini berpotensi untuk digunakan sebagai alat bantu diagnosis awal bagi tenaga medis, khususnya di fasilitas layanan kesehatan yang membutuhkan solusi efisien dan akurat dalam mendeteksi gangguan tiroid. Selain itu, penelitian ini juga memberikan kontribusi dalam pemanfaatan teknologi pembelajaran mesin pada bidang medis, serta membuka peluang untuk pengembangan lebih lanjut dalam hal integrasi data citra medis atau penggabungan dengan sistem rekam medis elektronik di masa mendatang.

REFERENCES

- [1] M. S. A. Khan et al., "Thyroid dysfunctions and their health implications: A review," *Clinica Chimica Acta*, vol. 505, pp. 190–194, 2020. DOI: 10.1016/j.cca.2020.06.003.
- [2] J. Vanderpump, "The epidemiology of thyroid disease," *British Medical Bulletin*, vol. 99, no. 1, pp. 39–51, 2011. DOI: 10.1093/bmb/ldr006.
- [3] B. Demers and H. Spencer, "Laboratory medicine practice guidelines for thyroid function tests," *Clin. Chem.*, vol. 48, no. 3, pp. 506–508, 2012. DOI: 10.1373/clinchem.2012.174034.
- [4] N. Hollowell et al., "Serum TSH, T4, and thyroid antibodies in the United States population," *J. Clin. Endocrinol. Metab.*, vol. 87, no. 2, pp. 489–499, 2002. DOI: 10.1210/jcem.87.2.8182.
- [5] Kementerian Kesehatan RI, *Riset Kesehatan Dasar (Riskesdas) 2018*, Jakarta: Badan Litbangkes, 2018.
- [6] R. Sahay and V. Nagesh, "Hypothyroidism: detection and treatment," *Journal of Clinical Research*, vol. 3, no. 2, pp. 14–18, 2017.
- [7] D. Dean et al., "Artificial intelligence applications in health care practice," *J. Clin. Med.*, vol. 8, no. 5, 2019. DOI: 10.3390/jcm8050675.
- [8] M. Topol, "High-performance medicine: the convergence of human and artificial intelligence," *Nature Medicine*, vol. 25, pp. 44–56, 2019. DOI: 10.1038/s41591-018-0300-7.
- [9] R. Kohavi, "A study of cross-validation and bootstrap for accuracy estimation and model selection," in *IJCAI*, 1995, pp. 1137–1143.
- [10] S. Kumar et al., "Machine Learning for Thyroid Disease Diagnosis," *Procedia Computer Science*, vol. 167, pp. 2290–2297, 2020. DOI: 10.1016/j.procs.2020.03.319.
- [11] R. Singh and A. Thakur, "Performance analysis of classification algorithms for thyroid disease detection," *IJCA*, vol. 178, no. 7, pp. 12–16, 2019.
- [12] A. Ahmed et al., "Comparative analysis of machine learning algorithms for thyroid disease detection," *IJRTE*, vol. 8, no. 1, pp. 345–350, 2019.



- [13] M. Ahmed and B. Naeem, “Smart diagnosis system using data mining techniques,” *Int. J. Adv. Comput. Sci.*, vol. 8, no. 4, pp. 78–85, 2018.
- [14] H. Abdar et al., “A new machine learning method for diagnosis of liver disease: SVM optimized by whale optimization algorithm,” *J. Biomed. Inform.*, vol. 94, p. 103199, 2019. DOI: 10.1016/j.jbi.2019.103199.
- [15] F. Al-Dhief et al., “Review on heart disease detection using machine learning and data mining techniques,” *J. Telecommun. Electron. Comput. Eng.*, vol. 10, no. 1–6, pp. 35–40, 2018.
- [16] R. Mohapatra and R. Padhy, “Thyroid disease detection using machine learning classification techniques,” *Procedia Computer Science*, vol. 167, pp. 1614–1623, 2020. DOI: 10.1016/j.procs.2020.03.299.
- [17] G. Ditzler et al., “Learning in nonstationary environments: A survey,” *IEEE Comput. Intell. Mag.*, vol. 10, no. 4, pp. 12–25, 2015. DOI: 10.1109/MCI.2015.2418532.
- [18] D. Dua and C. Graff, “UCI Machine Learning Repository: Thyroid Disease Dataset,” University of California, Irvine, 2020.
- [19] L. Yu and H. Liu, “Feature selection for high-dimensional data: A fast correlation-based filter solution,” in *ICML*, 2003, pp. 856–863.
- [20] N. V. Chawla et al., “SMOTE: Synthetic Minority Over-sampling Technique,” *J. Artif. Intell. Res.*, vol. 16, pp. 321–357, 2002. DOI: 10.1613/jair.953.
- [21] K. P. Murphy, “Naive Bayes classifiers,” in *Machine Learning: A Probabilistic Perspective*, MIT Press, 2012, pp. 225–229.
- [22] B. S. Islam, F. Hoque, and M. A. Rahman, “An Expert System to Diagnose Thyroid Disease Using Rule-Based Reasoning and Naïve Bayes Classifier,” *J. Comput. Commun.*, vol. 10, no. 7, pp. 1–12, 2022. DOI: 10.4236/jcc.2022.107001.
- [23] I. Dutta, S. Dey, and S. Ghosh, “Diagnosis of thyroid disease using machine learning algorithms,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 4, pp. 65–71, 2022.
- [24] Y. S. Siregar and A. R. Prabowo, “Naive Bayes Classifier for Thyroid Disease Diagnosis: Implementation and Analysis,” *Indonesian J. Electr. Eng. Comput. Sci.*, vol. 28, no. 2, pp. 356–362, 2022. DOI: 10.11591/ijeecs.v28.i2.pp356-362.
- [25] M. S. Raza, A. Hasan, and M. Khan, “Application of Gaussian Naive Bayes in Predictive Healthcare Systems,” *J. Healthcare Eng.*, vol. 2021, Article ID 1147109, 2021. DOI: 10.1155/2021/1147109.
- [26] D. Dua and C. Graff, “UCI Machine Learning Repository: Thyroid Disease Data Set,” University of California, Irvine, School of ICS, 2020.