

Sistem Pakar Diagnosis Penyakit Gigi dan Mulut Menggunakan Hybrid Certainty Factor dan K-NN

Herdiesel Santoso

Program Studi Sistem Informasi STMIK El Rahma Yogyakarta
e-mail: herdiesel.santoso@gmail.com

Abstrak

Penyakit gigi dan mulut merupakan salah satu permasalahan kesehatan yang sering terjadi di masyarakat dan memerlukan diagnosis yang tepat untuk penanganan yang optimal. Keterbatasan akses terhadap tenaga medis menyebabkan perlunya sistem pendukung keputusan yang mampu membantu proses diagnosis awal. Penelitian ini bertujuan untuk mengembangkan sistem pakar diagnosis penyakit gigi dan mulut menggunakan metode hybrid Certainty Factor (CF) dan k-Nearest Neighbors (k-NN). Metode CF digunakan untuk merepresentasikan pengetahuan pakar dalam bentuk aturan dengan nilai tingkat keyakinan, sedangkan k-NN digunakan untuk mengklasifikasikan penyakit berdasarkan kemiripan data kasus. Dataset yang digunakan dibangun berdasarkan gejala dan penyakit gigi dan mulut yang direpresentasikan dalam bentuk data biner. Pengujian dilakukan menggunakan confusion matrix, precision, recall, F1-score, serta k-fold cross validation untuk mengukur performa sistem. Hasil penelitian menunjukkan bahwa metode hybrid menghasilkan akurasi sebesar 88%, lebih tinggi dibandingkan metode CF sebesar 78% dan k-NN sebesar 82%. Selain itu, hasil evaluasi menunjukkan bahwa metode hybrid memiliki performa yang lebih stabil dan mampu meningkatkan kualitas diagnosis. Dengan demikian, sistem pakar yang dikembangkan mampu memberikan hasil diagnosis yang lebih akurat dan dapat digunakan sebagai alat bantu dalam deteksi dini penyakit gigi dan mulut.

Kata kunci— Sistem Pakar, Certainty Factor, k-Nearest Neighbors, Hybrid, Diagnosis Penyakit Gigi dan Mulut singkat.

1. PENDAHULUAN

Kesehatan gigi dan mulut memiliki peran penting dalam menunjang kualitas hidup. Namun, kesadaran masyarakat untuk melakukan pemeriksaan gigi secara rutin masih tergolong rendah. Di sisi lain, keterbatasan tenaga medis serta belum meratanya akses layanan kesehatan di beberapa wilayah menyebabkan proses diagnosis sering terlambat. Kondisi ini menunjukkan perlunya solusi yang dapat membantu proses diagnosis awal secara cepat, mudah diakses, dan tetap mempertimbangkan aspek klinis [1].

Pemanfaatan kecerdasan buatan menjadi salah satu pendekatan yang banyak digunakan untuk mendukung pengambilan keputusan di bidang kesehatan. Salah satu implementasinya adalah sistem pakar, yaitu sistem yang dirancang untuk meniru cara berpikir pakar dalam mendiagnosis suatu penyakit berdasarkan gejala yang dialami pasien [2]. Dalam sistem pakar, metode *Certainty Factor* (CF) sering digunakan karena mampu merepresentasikan tingkat keyakinan pakar terhadap hubungan antara gejala dan penyakit, seperti pada diagnosis penyakit gigi dan mulut [1] [3] [4]. Metode ini efektif dalam menangani ketidakpastian, namun hasilnya sangat bergantung pada pengetahuan pakar yang bersifat statis sehingga kurang adaptif terhadap variasi data baru [5]. Selain *Certainty Factor*, metode *k-Nearest Neighbors* (k-NN) merupakan algoritma klasifikasi berbasis kemiripan data yang banyak digunakan dalam berbagai studi diagnosis. Metode ini mampu mengenali pola dari data historis dan memberikan hasil klasifikasi yang cukup baik [6], [7]. Meskipun demikian, k-NN tidak mempertimbangkan pengetahuan pakar secara langsung, sehingga dalam beberapa kasus hasilnya kurang mencerminkan pertimbangan klinis.

Beberapa penelitian sebelumnya menunjukkan bahwa pendekatan berbasis metode tunggal memiliki keterbatasan dalam menghasilkan diagnosis yang optimal. Penelitian [1]

mengembangkan sistem pakar diagnosis penyakit gigi menggunakan metode *Certainty Factor* dan menghasilkan tingkat keyakinan yang cukup tinggi, namun sistem tersebut masih sangat bergantung pada aturan yang telah ditentukan. Seiring dengan perkembangan metode kecerdasan buatan, pendekatan hybrid yang menggabungkan *knowledge-based* dan *data-driven* mulai banyak digunakan karena mampu meningkatkan akurasi serta kemampuan generalisasi model dibandingkan metode tunggal [3]. Hal ini didukung oleh penelitian [8] yang mengkombinasikan *Certainty Factor* dengan *Modified k-Nearest Neighbor* dan menunjukkan peningkatan kinerja diagnosis secara signifikan. Selain itu, penelitian [9] yang mengintegrasikan *Certainty Factor* dengan *Fuzzy Logic* juga menunjukkan peningkatan akurasi dalam diagnosis penyakit *Monkeypox*. Lebih lanjut, hasil tinjauan sistematis pada penelitian [7] mengindikasikan bahwa pendekatan *hybrid* secara umum memberikan performa yang lebih baik dibandingkan metode tunggal, terutama dalam menangani kompleksitas dan ketidakpastian data medis.


Berdasarkan hasil penelitian tersebut, terlihat bahwa penggabungan metode berbasis pengetahuan dan berbasis data dapat meningkatkan kinerja sistem diagnosis. Namun, penerapan kombinasi metode *Certainty Factor* dan *k-Nearest Neighbors* pada domain penyakit gigi dan mulut masih terbatas. Padahal, kedua metode tersebut memiliki karakteristik yang saling melengkapi, dimana *Certainty Factor* mampu merepresentasikan keyakinan pakar, sedangkan k-NN mampu mengenali pola dari data kasus [8]. Oleh karena itu, penelitian ini mengembangkan sistem pakar diagnosis penyakit gigi dan mulut dengan menggabungkan metode *Certainty Factor* dan *k-Nearest Neighbors* dalam satu kerangka kerja serta mengevaluasi kinerja sistem menggunakan parameter *accuracy*, *precision*, *recall*, dan *F1-score*. Metode *Certainty Factor* digunakan untuk menghitung tingkat keyakinan berdasarkan gejala yang dipilih, sedangkan k-NN digunakan untuk menentukan kemiripan kasus berdasarkan data historis [6]. Hasil dari kedua metode kemudian dikombinasikan menggunakan skema pembobotan untuk menghasilkan diagnosis akhir yang lebih akurat dan stabil. Dengan pendekatan ini, sistem diharapkan tidak hanya merepresentasikan pengetahuan pakar, tetapi juga mampu beradaptasi terhadap variasi data, sehingga dapat menjadi alat bantu yang lebih efektif dalam proses diagnosis awal.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan sistem pakar berbasis metode hybrid yang menggabungkan *Certainty Factor* (CF) dan *k-Nearest Neighbors* (k-NN). Metode ini bertujuan untuk meningkatkan akurasi diagnosis penyakit gigi dan mulut dengan mengombinasikan pendekatan berbasis pengetahuan (*knowledge-based*) dan berbasis data [8][10]. Arsitektur sistem mengacu pada Gambar 1 yang terdiri dari proses akuisisi pengetahuan, perhitungan *Certainty Factor*, proses k-NN, kombinasi metode, hingga evaluasi sistem.

Akuisisi Pengetahuan Pakar

Akuisisi pengetahuan (*knowledge acquisition*) dilakukan untuk membangun basis pengetahuan sistem pakar diagnosis penyakit gigi dan mulut. Proses ini dilakukan melalui wawancara terstruktur dengan pakar, yaitu dokter gigi, serta didukung oleh literatur medis terkait. Hasil akuisisi pengetahuan mencakup tiga komponen utama, yaitu data penyakit, data gejala, dan hubungan antara gejala dan penyakit. Data penyakit terdiri atas 16 jenis penyakit gigi dan mulut, yang masing-masing diberikan kode untuk memudahkan proses pengolahan data dan disajikan pada Tabel 1. Data gejala terdiri atas 60 gejala yang diperoleh melalui konsultasi dengan pakar dan direpresentasikan menggunakan kode G01–G60 sebagaimana disajikan pada Tabel 2. Selanjutnya, hubungan antara gejala dan penyakit direpresentasikan dalam bentuk aturan (*rule-based*), di mana setiap penyakit memiliki kombinasi gejala tertentu yang digunakan sebagai dasar dalam proses diagnosis. Relasi antara gejala dan penyakit tersebut disajikan pada Tabel 3. Pemberian kode pada penyakit dan gejala memudahkan representasi pengetahuan dalam proses inferensi. Basis pengetahuan tersebut selanjutnya menjadi dasar pencocokan gejala dengan karakteristik masing-masing penyakit.



Gambar 1. Arsitektur Sistem Hybrid CF dan k-NN

Tabel 1. Data Penyakit

Kode	Penyakit	Istilah Lain
P01	Periodontitis	Penyakit Gusi
P02	Gingivitis	Radang Gusi
...	...	...
P16	Impaksi Gigi	Gigi Terpendam

Tabel 2. Data Gejala

Kode	Gejala
G01	Batuk
G02	Benjolan bertekstur kasar atau bersisik
G03	Benjolan di gusi tumbuh dengan cepat
...	...
G60	Timbul nanah di antara gigi dan gusi

Tabel 3. Rule Base Sistem Pakar

Kode Penyakit	Kombinasi Gejala
P01	G07, G12, G13, G14, G17, G18, G19, G32, G33, G34, G51
P02	G08, G10, G12, G13, G14, G16, G17, G33, G34, G37, G46, G60
P03	G05, G06, G08, G14, G17, G18, G19, G33, G34, G41, G48, G56, G59
...	...
P16	G21, G39, G42, G44, G58, G59

Sebagai contoh, penyakit *Periodontitis* (P01) direpresentasikan dengan beberapa gejala seperti G07, G12, G13, G14, G17, G18, G19, G32, G33, G34, dan G51. Selain itu, setiap relasi antara gejala dan penyakit diberikan nilai *Measure of Belief* (MB) dan *Measure of Disbelief* (MD) berdasarkan tingkat keyakinan pakar [11]. Nilai ini digunakan dalam perhitungan *Certainty Factor* untuk menentukan tingkat kepastian diagnosis. Seluruh pengetahuan yang diperoleh kemudian divalidasi kembali oleh pakar untuk memastikan kesesuaian dengan kondisi klinis [12]. Basis pengetahuan ini selanjutnya digunakan dalam proses inferensi menggunakan metode *Certainty Factor* dan dikombinasikan dengan metode *k-Nearest Neighbors* dalam sistem *hybrid*.

Perhitungan Certainty Factor

Penentuan nilai *Certainty Factor* (CF) pada penelitian ini dilakukan berdasarkan hasil wawancara dengan pakar, yaitu dokter gigi, yang memberikan tingkat keyakinan terhadap hubungan antara gejala dan penyakit [13], [14]. Nilai CF diberikan dalam rentang 0 hingga 1, dimana nilai yang semakin mendekati 1 menunjukkan tingkat keyakinan yang semakin tinggi. Penentuan nilai ini mengacu pada interpretasi *Certainty Factor* [15][5]. Secara keseluruhan, terdapat 144 pasangan gejala–penyakit yang digunakan sebagai basis pengetahuan dalam sistem disajikan pada Tabel 4.

Tabel 4. Contoh Nilai *Certainty Factor* dari Pakar

No	Kode Gejala	Kode Penyakit	Gejala	Nilai CF
1	G007	P01	Gigi goyang	0.90
2	G012	P01	Gusi berwarna merah	0.70
3	G014	P01	Gusi membengkak	0.60
...	...	...	...	...
144	G046	P02	Gigi tiruan tidak pas	0.90

Setiap gejala yang dipilih oleh pengguna memiliki tingkat keyakinan (CF_{user}) dalam rentang 0 hingga 1. Nilai tersebut dikombinasikan dengan nilai keyakinan pakar (CF_{pakar}) untuk menghasilkan nilai CF setiap gejala dengan persamaan (1) [1]. Nilai CF_{pakar} menunjukkan tingkat keyakinan pakar terhadap hubungan gejala dengan penyakit, sedangkan CF_{user} menunjukkan tingkat keyakinan pengguna terhadap gejala yang dialami.

$$CF_{gejala} = CF_{pakar} \times CF_{user} \quad (1)$$

Apabila dalam satu aturan terdapat lebih dari satu gejala, nilai CF masing-masing gejala dikombinasikan secara bertahap menggunakan Persamaan (2). Pada persamaan tersebut, CF_1 merupakan nilai CF sebelumnya dan CF_2 merupakan nilai CF gejala berikutnya. Proses kombinasi dilakukan secara iteratif hingga seluruh gejala yang sesuai dengan aturan diproses. Nilai CF akhir menunjukkan tingkat keyakinan terhadap suatu diagnosis, sedangkan nilai CF tertinggi digunakan sebagai hasil diagnosis utama.

$$CF_{combine} = CF_1 + CF_2 \times (1 - CF_1) \quad (2)$$

Sebagai contoh, pengguna memilih gejala G13 (gusi lunak) dengan $CF_{user} = 0,4$, G16 (gusi menyusut) dengan $CF_{user} = 0,7$, dan G37 (maloklusi) dengan $CF_{user} = 0,8$. Untuk penyakit Gingivitis (P02), nilai CF_{pakar} masing-masing gejala adalah 0,5, 0,3, dan 0,4. Berdasarkan Persamaan (1), diperoleh $CF_1 = 0,20$, $CF_2 = 0,21$, dan $CF_3 = 0,32$. Selanjutnya, menggunakan Persamaan (2), diperoleh $CF_{combine1} = 0,368$ dan $CF_{combine2} = 0,570$. Dengan demikian, nilai CF akhir untuk Gingivitis (P02) adalah 0,57 atau 57%.

Pengumpulan Data Kasus dan Preprocessing Data.

Data kasus digunakan sebagai data latih dalam metode *k-Nearest Neighbors* (k-NN). Data ini diperoleh dari rekam medis yang relevan dengan diagnosis penyakit gigi dan mulut. Dataset terdiri dari 60 kasus dengan distribusi kelas yang relatif seimbang, dimana setiap kelas memiliki proporsi minimal 10%. Keterbatasan jumlah data disebabkan oleh keterbatasan akses terhadap rekam medis yang terverifikasi. Oleh karena itu, digunakan teknik *k-fold cross validation* untuk memaksimalkan pemanfaatan data serta mengurangi bias evaluasi. Data yang digunakan telah disesuaikan dengan daftar gejala dan penyakit yang digunakan dalam sistem melalui tahap *Preprocessing Data*. Sebelum digunakan dalam penelitian, seluruh data kasus telah melalui proses validasi oleh pakar dokter gigi untuk memastikan kesesuaian antara gejala, diagnosis, dan label penyakit yang digunakan. Proses validasi ini dilakukan untuk meningkatkan validitas dan reliabilitas dataset dalam mendukung pengembangan sistem pakar.

Tabel 5. Distribusi Dataset Berdasarkan Kelas Penyakit

Kode Penyakit	Nama Penyakit	Jumlah Kasus
P01	Periodontitis	5
P02	Gingivitis	6
P03	Abses Gigi	5
P04	Glossitis	4
P05	Stomatitis	4
P06	Kanker Mulut	3
P07	...	...
P16	Impaksi Gigi	2
Total		60

Berdasarkan Tabel 5 distribusi dataset, jumlah kasus pada setiap kelas penyakit tidak sepenuhnya seimbang. Kondisi ini mencerminkan karakteristik data rekam medis yang tersedia, dimana beberapa penyakit memiliki jumlah kasus lebih banyak dibandingkan penyakit lainnya. Untuk mengurangi bias akibat distribusi kelas yang tidak merata, penelitian ini menggunakan teknik *k-fold cross validation* sehingga setiap data memiliki kesempatan yang sama untuk

digunakan sebagai data latih dan data uji [6]. Data yang digunakan telah disesuaikan dengan daftar gejala dan penyakit melalui tahap *preprocessing*, yang meliputi pembersihan data (*data cleaning*), penghapusan duplikasi, serta eliminasi data yang tidak lengkap. Setiap data kasus direpresentasikan dalam bentuk vektor gejala biner, dimana nilai 1 menunjukkan keberadaan gejala dan 0 menunjukkan ketidakhadiran gejala [3].

Dalam penelitian ini, sistem menerima input gejala dari pengguna dalam bentuk tingkat keyakinan (*certainty level*) dengan rentang nilai [0,1]. Nilai tersebut digunakan pada metode *Certainty Factor* (CF) untuk merepresentasikan derajat keyakinan pengguna terhadap kemunculan suatu gejala [1], [4]. Pada metode *k-Nearest Neighbors* (k-NN), nilai input pengguna tidak dikonversi menjadi biner, tetapi dipertahankan dalam bentuk kontinu. Dengan demikian, data latih direpresentasikan dalam bentuk biner (0 atau 1), sedangkan data uji direpresentasikan dalam bentuk kontinu pada rentang 0–1. Pendekatan ini digunakan untuk mempertahankan informasi tingkat keyakinan pengguna tanpa melakukan diskretisasi [8], [16]. Perhitungan jarak antara data uji dan data latih dilakukan menggunakan *Euclidean Distance* berdasarkan selisih nilai setiap fitur gejala. Karena data latih dan data uji berada pada rentang nilai yang sama, yaitu 0–1, tidak dilakukan normalisasi tambahan sebelum proses perhitungan jarak. Data kasus yang telah melalui tahap *preprocessing* disajikan pada **Tabel 6**.

Tabel 6. Representasi Data Kasus

No	G01	G02	G03	G04	G05	...	G60	Penyakit
1	0	0	1	0	0	...	1	P001
2	0	1	0	0	1	...	0	P002
3	1	0	0	0	0	...	0	P003
..	...	...	...	...	...	...	...	P002
60	0	0	0	0	1	...	0	P009

Metode *k-Nearest Neighbors* (k-NN)

Metode *k-Nearest Neighbors* (k-NN) merupakan algoritma klasifikasi berbasis kemiripan data. Data uji diklasifikasikan berdasarkan kedekatannya dengan data latih [6]. Pada penelitian ini, kedekatan antara data uji dan data latih dihitung menggunakan *Euclidean Distance* sebagaimana ditunjukkan pada Persamaan (3).

$$d = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3)$$

Pada Persamaan (3), x_i merupakan nilai fitur ke- i pada data uji, y_i merupakan nilai fitur ke- i pada data latih, sedangkan n merupakan jumlah fitur. Setelah jarak dihitung, sistem akan memilih sejumlah k data dengan jarak terdekat sebagai tetangga terdekat. Kelas dari data uji ditentukan berdasarkan jumlah voting terbanyak dari tetangga tersebut [6].

Setelah nilai jarak antara data uji dan data latih dihitung menggunakan rumus Euclidean Distance, sistem akan memilih sejumlah k data dengan jarak terdekat sebagai tetangga terdekat. Kelas dari data uji kemudian ditentukan berdasarkan jumlah *voting* terbanyak dari tetangga tersebut, sehingga data akan diklasifikasikan ke dalam kelas yang paling dominan. Penentuan nilai k dalam penelitian ini tidak dilakukan secara langsung tetapi melalui proses pengujian terhadap beberapa nilai, yaitu $k = 3, 5$, dan 7 .

Tabel 7. Hasil Pengujian Nilai k pada k-NN

No	Nilai k	Akurasi
1	3	82%
2	5	80%
3	7	75%

Hasil pengujian nilai k dapat dilihat pada Tabel 7, dimana nilai $k = 3$ menghasilkan akurasi sebesar 82%, lebih tinggi dibandingkan $k = 5$ sebesar 80% dan $k = 7$ sebesar 75%. Dengan demikian, nilai $k = 3$ dipilih karena mampu memberikan hasil klasifikasi yang paling optimal pada dataset yang digunakan dalam penelitian ini.

Kombinasi Metode Hybrid Certainty Factor dan k-Nearest Neighbors

Metode hybrid pada penelitian ini menggabungkan metode *Certainty Factor* (CF) dan *k-Nearest Neighbors* (k-NN) untuk meningkatkan akurasi diagnosis penyakit gigi dan mulut. Pendekatan ini sejalan dengan perkembangan sistem pendukung keputusan medis modern yang mengintegrasikan rule-based reasoning dengan machine learning untuk meningkatkan akurasi dan interpretabilitas diagnosis [16]. Metode CF digunakan untuk merepresentasikan tingkat keyakinan berdasarkan pengetahuan pakar, sedangkan metode k-NN digunakan untuk mengukur kemiripan data berdasarkan kasus sebelumnya. Nilai akhir diagnosis diperoleh dengan mengkombinasikan hasil dari kedua metode menggunakan skema pembobotan, dinyatakan dengan persamaan (4).

(4)

$$Final = (\alpha \times CF) + (\beta \times k - NN)$$

Pada persamaan 4, α (*alpha*) dan β (*beta*) merupakan bobot kontribusi masing-masing metode, dimana $\alpha + \beta = 1$. Penentuan nilai bobot α dan β tidak dilakukan secara langsung, tetapi melalui proses pengujian beberapa kombinasi bobot yaitu (0,5:0,5), (0,6:0,4), dan (0,7:0,3), untuk memperoleh performa terbaik. Pengujian ini dilakukan dengan membandingkan nilai akurasi dari setiap kombinasi bobot yang digunakan.

Evaluasi Kinerja Model

Evaluasi dilakukan untuk mengukur kinerja sistem dalam melakukan klasifikasi penyakit gigi dan mulut. Pengujian dilakukan dengan membandingkan hasil prediksi sistem dengan data aktual menggunakan *confusion matrix* [10]. *Confusion matrix* digunakan untuk menggambarkan jumlah data yang diklasifikasikan dengan benar maupun salah ke dalam setiap kelas. Berdasarkan *confusion matrix*, diperoleh empat komponen utama, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Selanjutnya, kinerja model diukur menggunakan metrik *precision*, *recall*, dan *F1-score* [17]. Selain itu, penelitian ini juga menggunakan teknik k-fold cross validation untuk menguji konsistensi performa model pada beberapa pembagian data. Dalam setiap fold, proses pemilihan nilai k pada metode k-NN dan penentuan kombinasi bobot hybrid dilakukan hanya menggunakan data latih pada fold tersebut. Data uji pada fold yang bersangkutan tidak digunakan dalam proses pemilihan parameter, sehingga dapat mengurangi risiko bias evaluasi dan memberikan estimasi performa model yang lebih objektif.

3. HASIL DAN PEMBAHASAN

Hasil Implementasi Sistem

Sistem pakar diagnosis penyakit gigi dan mulut dikembangkan menggunakan pendekatan *hybrid* yang menggabungkan metode *Certainty Factor* (CF) dan *k-Nearest Neighbors* (k-NN). Sistem menerima input berupa gejala yang dipilih oleh pengguna, kemudian menghitung tingkat keyakinan menggunakan metode CF serta melakukan klasifikasi berbasis kemiripan menggunakan k-NN. Output sistem berupa: Daftar kemungkinan penyakit, Nilai tingkat keyakinan (*confidence*), Diagnosis akhir berdasarkan metode *hybrid*.

Hasil Perhitungan Certainty Factor (CF)

Perhitungan CF dilakukan berdasarkan nilai *Measure of Belief* (MB) dan *Measure of Disbelief* (MD) dari pakar, serta nilai keyakinan pengguna (CF user). Contoh perhitungan telah

dilakukan pada beberapa penyakit, seperti *Periodontitis* (P01), *Gingivitis* (P02), dan *Halitosis* (P09). Hasil perhitungan CF ditunjukkan pada Tabel 8.

Tabel 8. Hasil Perhitungan *Certainty Factor*

No	Penyakit	Nilai CF
1	Gingivitis (P02)	0.57
2	Periodontitis (P01)	0.50
3	Halitosis (P09)	0.40

Berdasarkan Tabel 8, penyakit *Gingivitis* (P02) memiliki nilai CF tertinggi sebesar 0.57, sehingga menjadi diagnosis utama jika hanya menggunakan metode CF. Nilai ini menunjukkan bahwa tingkat keyakinan terhadap diagnosis cukup kuat berdasarkan aturan dan bobot pakar. Namun, metode CF memiliki keterbatasan karena sangat bergantung pada *rule base* yang telah didefinisikan.

Hasil Perhitungan k-Nearest Neighbors (k-NN)

Metode k-NN digunakan untuk mengklasifikasikan penyakit berdasarkan kemiripan dengan data kasus sebelumnya. Dataset dibangun dari 60 data kasus penyakit gigi dan mulut dalam bentuk representasi biner. Contoh hasil klasifikasi k-NN ditunjukkan pada Tabel 9.

Tabel 9. Hasil Klasifikasi k-NN

No	Penyakit	Voting	Nilai
1	Gingivitis (P02)	2	0.66
2	Periodontitis (P01)	1	0.33
3	Halitosis (P09)	0	0.00

Pada Tabel 9 terlihat bahwa penyakit *Gingivitis* (P02) memperoleh voting tertinggi dari tetangga terdekat ($k=3$), dengan nilai 0.66. Hal ini menunjukkan bahwa kasus uji memiliki kemiripan paling tinggi dengan data kasus *Gingivitis* dalam *dataset*. Metode k-NN mampu menangkap pola data, namun sangat bergantung pada kualitas *dataset* yang digunakan.

Hasil Pengujian Bobot Metode Hybrid

Pembobotan pada metode *hybrid* ditentukan melalui proses eksperimen dengan menguji beberapa kombinasi bobot antara metode *Certainty Factor* (CF) dan k-Nearest Neighbors (k-NN). Pengujian dilakukan dengan membandingkan kinerja model menggunakan beberapa skenario pembobotan, yaitu (0,5:0,5), (0,6:0,4), dan (0,7:0,3). Setiap kombinasi bobot diuji menggunakan data yang sama, kemudian dievaluasi menggunakan metrik akurasi.

Tabel 10. Pengujian Kombinasi Bobot Hybrid

No	Bobot CF	Bobot k-NN	Akurasi
1	0.5	0.5	85%
2	0.6	0.4	88%
3	0.7	0.3	86%

Berdasarkan hasil pengujian pada Tabel 10, kombinasi bobot CF sebesar 0,6 dan k-NN sebesar 0,4 menghasilkan akurasi tertinggi yaitu 88%. Hal ini menunjukkan bahwa kontribusi pengetahuan pakar melalui metode *Certainty Factor* memiliki peran yang lebih dominan dibandingkan metode k-NN, namun tetap perlu didukung oleh pendekatan berbasis data untuk

meningkatkan akurasi diagnosis. Oleh karena itu, kombinasi bobot (0,6;0,4) dipilih sebagai parameter terbaik dalam penelitian ini.

Hasil Metode Hybrid (CF dan k-NN)

Metode hybrid pada penelitian ini menggabungkan hasil perhitungan *Certainty Factor* (CF) dan *k-Nearest Neighbors* (k-NN). Nilai akhir diagnosis dihitung menggunakan persamaan, dimana nilai CF merepresentasikan tingkat keyakinan berdasarkan pengetahuan pakar, sedangkan nilai k-NN diperoleh dari hasil klasifikasi berbasis kemiripan data dengan menggunakan $k = 3$. Hasil perhitungan metode hybrid ditunjukkan pada Tabel 11.


Tabel 11. Hasil Diagnosis Metode Hybrid

No	Penyakit	CF	k-NN	Hybrid
1	Gingivitis (P02)	0.57	0.66	0.60
2	Periodontitis (P01)	0.50	0.33	0.43
3	Halitosis (P09)	0.40	0.00	0.24

Berdasarkan Tabel 10, metode *hybrid* menghasilkan nilai tertinggi pada penyakit Gingivitis (P02) sebesar 0.60. Nilai ini lebih stabil dibandingkan metode tunggal karena mempertimbangkan dua aspek, yaitu keyakinan pakar dan kemiripan data. Hal ini menunjukkan bahwa metode hybrid mampu meningkatkan kualitas diagnosis.

Evaluasi Model Menggunakan Confusion Matrix

Evaluasi performa model dilakukan menggunakan confusion matrix yang ditunjukkan pada Gambar 2.



Gambar 2. Confusion matrix metode Hybrid CF dan k-NN

Gambar 2 menunjukkan confusion matrix hasil pengujian metode *Hybrid Certainty Factor* (CF) dan *k-Nearest Neighbors* (k-NN) terhadap 60 data kasus. Secara umum, sebagian besar data berhasil diklasifikasikan dengan benar yang ditunjukkan oleh nilai pada diagonal utama *confusion matrix*, yaitu sebanyak 53 dari 60 data diprediksi sesuai dengan kelas sebenarnya sehingga menghasilkan akurasi sebesar 88%. Kelas Gingivitis (P02) menunjukkan hasil klasifikasi yang sangat baik dengan 6 data berhasil diprediksi secara benar tanpa terjadi kesalahan klasifikasi. Sebaliknya, pada kelas Periodontitis (P01) terdapat 1 data yang diprediksi sebagai Gingivitis (P02). Kondisi ini menunjukkan bahwa kedua penyakit memiliki karakteristik gejala yang hampir serupa, terutama G012 (gusi berwarna merah) dan G014 (gusi membengkak), sehingga tingkat kemiripan antar kasus menjadi tinggi.

Kesalahan klasifikasi juga terjadi pada P03 yang diprediksi sebagai P04, P05 yang diprediksi sebagai kelompok P06–P16, serta beberapa kasus pada kelompok P06–P16 yang diprediksi sebagai P02, P03, P04, dan P05. Hal ini menunjukkan bahwa beberapa penyakit memiliki gejala yang saling beririsan, seperti G017 (gusi mudah berdarah saat menyikat gigi) dan G034 (nyeri saat mengunyah atau menggigit makanan), sehingga nilai jarak *Euclidean Distance* antar kasus menjadi relatif dekat. Akibatnya, beberapa data memiliki *nearest neighbors* yang berasal dari kelas penyakit lain sehingga meningkatkan kemungkinan terjadinya *misclassification*.

Meskipun demikian, jumlah kesalahan klasifikasi relatif kecil dibandingkan jumlah prediksi yang benar. Hal ini menunjukkan bahwa kombinasi *Certainty Factor* sebagai representasi pengetahuan pakar dan *k-Nearest Neighbors* sebagai metode klasifikasi berbasis kemiripan data mampu menghasilkan diagnosis yang lebih akurat dan stabil pada dataset penelitian. Penggunaan nilai *Certainty Factor* membantu memperkuat keputusan diagnosis melalui pembobotan tingkat keyakinan pakar terhadap setiap gejala, sehingga mampu mengurangi pengaruh kemiripan gejala antar penyakit. Hasil evaluasi *Precision*, *Recall*, dan *F1-Score* ditunjukkan pada Tabel 12.

Tabel 12. Hasil Evaluasi Model

Kelas Penyakit	Precision	Recall	F1-Score	Support
P01	1.00	0.80	0.89	5
P02	0.75	1.00	0.86	6
P03	0.80	0.80	0.80	5
P04	0.67	1.00	0.80	4
P05	0.75	0.75	0.75	4
P06–P16	0.97	0.89	0.93	36
Macro Average	0.82	0.87	0.84	60
Weighted Average	0.89	0.88	0.88	60


Berdasarkan Tabel 12, hasil evaluasi model menggunakan metrik *precision*, *recall*, dan *F1-score* menunjukkan bahwa metode *hybrid Certainty Factor* (CF) dan *k-Nearest Neighbors* (k-NN) mampu memberikan performa klasifikasi yang baik pada seluruh kelas penyakit. Nilai *Weighted Average* masing-masing sebesar 0,89 untuk *precision*, 0,88 untuk *recall*, dan 0,88 untuk *F1-score*. Nilai tersebut menunjukkan bahwa metode *hybrid* mampu memberikan performa klasifikasi yang baik pada keseluruhan data uji. Kelas P02 memperoleh nilai *recall* tertinggi sebesar 1,00, yang menunjukkan bahwa seluruh kasus pada kelas tersebut berhasil dikenali oleh sistem. Sementara itu, kelas P01 memiliki nilai *precision* sebesar 1,00, yang menunjukkan bahwa seluruh prediksi yang dihasilkan untuk kelas tersebut merupakan prediksi yang benar. Kelas P06–P16 memperoleh nilai *F1-score* sebesar 0,93, menunjukkan bahwa model mampu mengklasifikasikan sebagian besar kasus pada kelompok penyakit tersebut dengan baik. Hal ini dipengaruhi oleh jumlah data latih yang lebih banyak dibandingkan kelas lainnya sehingga pola karakteristik setiap penyakit lebih mudah dipelajari oleh model.

Secara keseluruhan, nilai *Macro Average* sebesar 0,82 untuk *precision*, 0,87 untuk *recall*, dan 0,84 untuk *F1-score* menunjukkan bahwa performa model relatif merata pada seluruh kelas penyakit. Hasil ini juga konsisten dengan nilai akurasi keseluruhan sebesar 88%, sehingga dapat disimpulkan bahwa metode *hybrid* yang menggabungkan pengetahuan pakar melalui *Certainty Factor* dan klasifikasi berbasis kemiripan menggunakan *k-Nearest Neighbors* mampu menghasilkan diagnosis yang akurat dan stabil pada dataset penelitian.

Perbandingan Akurasi Metode

Untuk mengevaluasi peningkatan kinerja, dilakukan perbandingan akurasi antara metode tunggal dan metode *hybrid*. Perbandingan akurasi ditunjukkan pada Gambar 3. Gambar 3 menunjukkan bahwa metode *hybrid* memiliki akurasi tertinggi sebesar 88%, dibandingkan CF (78%) dan k-NN (82%). Hasil perhitungan menunjukkan bahwa metode *hybrid* mampu meningkatkan akurasi sebesar 10% dibandingkan metode *Certainty Factor*, dan sebesar 6% dibandingkan metode k-

NN. Secara relatif, peningkatan ini masing-masing sebesar $((88-78)/78) \times 100\% = 12,82\%$ dan $((88-82)/82) \times 100\% = 7,32\%$. Peningkatan ini menunjukkan bahwa integrasi antara pendekatan berbasis pengetahuan (CF) dan berbasis data (k-NN) memberikan kontribusi signifikan dalam meningkatkan performa sistem diagnosis karena mampu mengurangi kesalahan klasifikasi yang disebabkan oleh overlap gejala antar penyakit.



Gambar 3. Grafik Perbandingan Akurasi CF, k-NN, dan Hybrid

Hasil k-Fold Cross Validation

Untuk menguji kestabilan dan generalisasi model, digunakan metode *k-fold cross validation* dengan nilai $k = 5$. Dataset dibagi menjadi 5 subset (*fold*), dimana setiap *fold* secara bergantian digunakan sebagai data uji, sementara sisanya digunakan sebagai data latih. Hasil pengujian ditunjukkan pada Tabel 13. Tabel 13 menunjukkan bahwa metode hybrid secara konsisten menghasilkan akurasi tertinggi pada setiap *fold*. Hal ini menunjukkan bahwa model memiliki stabilitas yang baik dan tidak mengalami *overfitting*.

Tabel 13. Hasil k-Fold Cross Validation

Fold	CF	k-NN	Hybrid
1	0.76	0.80	0.86
2	0.78	0.82	0.88
3	0.80	0.83	0.89
4	0.77	0.81	0.87
5	0.79	0.84	0.90

4. KESIMPULAN

Penerapan metode *hybrid Certainty Factor* (CF) dan *k-Nearest Neighbors* (k-NN) terbukti mampu meningkatkan kinerja sistem pakar dalam diagnosis penyakit gigi dan mulut. Metode CF berperan dalam merepresentasikan pengetahuan pakar dan menangani ketidakpastian, sedangkan k-NN mendukung klasifikasi berdasarkan kemiripan data kasus. Hasil pengujian menunjukkan bahwa metode hybrid menghasilkan akurasi tertinggi sebesar 88%, dibandingkan CF sebesar 78% dan k-NN sebesar 82%. Evaluasi menggunakan *confusion matrix* serta nilai *precision*, *recall*, dan *F1-score* menunjukkan bahwa sistem memiliki performa yang cukup baik dan stabil. Selain itu, hasil *k-fold cross validation* menunjukkan konsistensi performa model dalam berbagai pembagian data. Dengan demikian, metode *hybrid* mampu menghasilkan diagnosis yang lebih akurat, stabil, dan adaptif, sehingga layak digunakan sebagai alat bantu

dalam diagnosis awal penyakit gigi dan mulut. Penelitian ini masih memiliki keterbatasan pada jumlah dataset yang relatif sedikit, yaitu 60 kasus, serta distribusi kelas yang belum sepenuhnya merata. Oleh karena itu, penelitian selanjutnya disarankan menggunakan dataset yang lebih besar dan lebih seimbang, serta mengeksplorasi metode pembobotan fitur untuk meningkatkan kemampuan sistem dalam membedakan penyakit dengan gejala yang saling tumpang tindih.

DAFTAR PUSTAKA

- [1] A. Gunawan and F. Islami, "Implementing the Certainty Factor Method in a Dental Disease Expert System," *MEDINFTEch*, vol. 2, no. 2, pp. 27–32, 2024, doi: <https://doi.org/10.37034/medinftech.v2i2.33>.
- [2] I. Hatzilygeroudis, K. Dimitropoulos, K. Kovas, and J. A. Theodorou, "Expert Systems for Farmed Fish Disease Diagnosis : An Overview and a Proposal," *J. Mar. Sci. Eng.*, vol. 11, no. 1084, pp. 1–18, 2023, doi: <https://doi.org/10.3390/jmse11051084>.
- [3] E. M. Mustafa, M. M. Saad, and L. W. Rizkallah, "Building An Enhanced Case Based Reasoning And Rule Based Systems For Medical Diagnosis," *J. Eng. Appl. Sci.*, vol. 70, no. 139, pp. 1–12, 2023, doi: [10.1186/s44147-023-00315-4](https://doi.org/10.1186/s44147-023-00315-4).
- [4] A. I. Zalukhu, S. Irwan Syahputra, Z. Sitorus, and Khairul, "Penerapan Metode Certainty Factor Pada Sistem Pakar Diagnosa Penyakit Gigi Dan Mulut," *Bull. Inf. Technol.*, vol. 4, no. 4, pp. 544–553, 2023, doi: <https://doi.org/10.47065/bit.v4i4.1102>.
- [5] A. N. Nur'afifah, A. P. Sari, and A. L. Nurlaili, "Optimization of Certainty Factor in Cat Disease Diagnosis Using Particle Swarm Optimization," *Bit-Tech (Binary Digit. - Technol.)*, vol. 8, no. 1, 2025, doi: <https://doi.org/10.32877/bt.v8i1.2484>.
- [6] A. M. A. K. Parewe, Mursalim, T. S. Putri, and Hermawati, "Application of Case Based Reasoning Using The K-Nearest Neighbor Algorithm in an Expert System for Diagnosing Pests and Diseases of Sugarcane Plants," *Knowbase Int. J. Knowl. Database*, vol. 02, no. 02, pp. 181–189, 2022, doi: <https://doi.org/10.30983/knowbase.v2i2.5959>.
- [7] N. P. Rhomadona and Luqman, "Comparative Analysis of Expert System Methods for Early Diagnosis of Online Game Addiction : A Systematic Review," *J. E-Komtek*, vol. 9, no. 2, pp. 555–562, 2025, doi: <https://doi.org/10.37339/e-komtek.v9i2.2699>.
- [8] Z. Hulwani, E. Sedyono, and B. Surarso, "Kombinasi Modified K-Nearest Neighbor dan Certainty Factor untuk Peningkatan Akurasi Diagnosis Malnutrisi," *J. Sist. Inf. Bisnis*, vol. 14, no. 3, pp. 289–301, 2024, doi: [10.21456/vol14iss3pp289-301](https://doi.org/10.21456/vol14iss3pp289-301).
- [9] M. A. V. Ideal and T. N. Putra, "Intelligent System For Monkeypox Disease Diagnosis Using Hybrid Certainty Factor And Fuzzy Logic Methods," *J. INOVTEK POLBENG*, vol. 10, no. 3, pp. 131–141, 2025, doi: <https://doi.org/10.35314/h13m0k54>.
- [10] T. Nunsina and Z. Situmorang, "Analysis Optimization K-Nearest Neighbor Algorithm with Certainty Factor in Determining Student Career," *Int. Conf. Mech. Electron. Comput. Ind. Technol. Anal.*, pp. 305–309, 2020.
- [11] S. Wahyuni, "Sistem Pakar Diagnosa Penyakit Kulit Pada Manusia Menggunakan Metode Hybrid," *J. Sains Inform. Terap.*, vol. 2, no. 1, pp. 25–30, 2023, doi: <https://doi.org/10.62357/jsit.v2i1.177>.
- [12] N. Hasan, G. J. Yanris, and E. R. Hasibuan, "A Mobile-based Expert System for Disease Diagnosis Child Using Best-First Search Algorithm," *Sink. J. dan Penelit. Tek. Inform.*, vol. 6, no. 2, pp. 701–707, 2022, doi: <https://doi.org/10.33395/sinkron.v7i2.11426>.
- [13] I. Azmi, G. Gunawan, and S. Anandianskha, "Application Of Expert System Using Certainty Factor Method To Identify Diseases In Rice Plants," *J. Mandiri IT*, vol. 12, no. 4, pp. 200–207, 2024, doi: <https://doi.org/10.35335/mandiri.v12i4.280>.
- [14] A. Mulyani, D. Kurniadi, and S. I. Multajam, "Application of Certainty Factor Method In Diphtheria Diagnosis Expert System Web-Based," *TEKNIKA*, vol. 12, no. November, pp. 205–

211, 2023, doi: <https://doi.org/10.34148/teknika.v12i3.686>.

[15] A. I. Zalukhu, I. Syahputra, M. Iqbal, and R. F. Wijaya, "Analisis Metode Certainty Factor Pada Sistem Pakar Diagnosa Kerusakan Sepeda Motor," *Bull. Inf. Technol.*, vol. 4, no. 4, pp. 0–8, 2023, doi: <https://doi.org/10.47065/bit.v4i4.1083>.

[16] M. H. Maqsood, M. Sajid, K. Ahmed, M. U. Shahid, and M. Farooq, "A Hybrid AI and Rule-Based Decision Support System for Disease Diagnosis and Management Using Labs." 2026. doi: <https://doi.org/10.48550/arXiv.2603.14876>.

[17] P. Syifa, Safwandi, and Z. Fitri, "Sistem Pakar Diagnosis Penyakit Paru Menggunakan Metode Convolutional Neural Network Dan Rule Based System," *RABIT J. Teknol. dan Sist. Inf. Univrab*, vol. 10, no. 2, pp. 1380–1392, 2025, doi: <https://doi.org/10.36341/rabit.v10i2.6548>.