

BAB II TINJAUAN PUSTAKA

2.1 Penelitian yang Relevan

Penelitian mengenai *Polycystic Ovary Syndrome* (PCOS) dan penerapan metode kecerdasan buatan dalam diagnosis dini telah banyak dilakukan, namun hasilnya menunjukkan variasi penerapan metode dan efektivitas yang berbeda-beda. Sejumlah studi terdahulu menggunakan metode *Certainty Factor* untuk membantu proses diagnosis berbagai gangguan reproduksi dan kondisi terkait, termasuk PCOS. Penelitian oleh Handayani *et al.* (2022) menunjukkan bahwa metode *Certainty Factor* mampu memberikan hasil diagnosis PCOS yang konsisten dengan perhitungan pakar, sehingga layak digunakan sebagai dasar pengembangan sistem pakar. Beberapa penelitian lain juga mendukung efektivitas pendekatan ini, seperti penelitian Halifah *et al.* (2023) dan Azzahra & Haerani (2022), yang membuktikan bahwa *Certainty Factor* dapat mengakomodasi ketidakpastian data medis dan menghasilkan nilai akurasi yang cukup tinggi pada diagnosis gangguan menstruasi dan gangguan reproduksi lainnya. Temuan-temuan tersebut menegaskan bahwa *Certainty Factor* memiliki potensi kuat dalam menangani kasus dengan gejala variatif sebagaimana ditemukan pada PCOS.

Di sisi lain, metode *Naïve Bayes* juga telah banyak digunakan dalam penelitian diagnosis penyakit dan terbukti efektif sebagai algoritma klasifikasi probabilistik. Wahyudi *et al.* (2023) menemukan bahwa sistem pakar berbasis *Naïve Bayes* mampu mencapai akurasi diagnosis sebesar 84% pada gangguan menstruasi. Studi lain yang dilakukan oleh Andriyanto *et al.* (2025) menunjukkan bahwa *Naïve Bayes* dapat menghasilkan akurasi yang tinggi dalam menganalisis data sintesis PCOS, meskipun performanya masih kalah dibanding algoritma lain seperti K-NN. Penelitian internasional oleh Hassan & Mirza (2020) bahkan menunjukkan bahwa *Naïve Bayes* memiliki performa paling rendah dibanding beberapa algoritma *machine learning* lainnya dalam diagnosis PCOS, tetapi tetap memberikan hasil yang stabil pada data dengan distribusi normal. Berdasarkan tinjauan tersebut, terlihat bahwa *Certainty Factor* dan *Naïve Bayes* memiliki karakteristik yang saling melengkapi dalam proses identifikasi dini PCOS. *Naïve Bayes* unggul dalam menghasilkan klasifikasi berbasis probabilitas dari data historis, sedangkan *Certainty Factor* mampu merepresentasikan tingkat keyakinan terhadap suatu diagnosis berdasarkan ketidakpastian gejala. Oleh karena itu, integrasi kedua metode ini diperlukan untuk menghasilkan sistem identifikasi yang tidak hanya akurat secara statistik, tetapi juga mampu mengakomodasi aspek keyakinan dalam pengambilan keputusan medis.

2.1.1 Matriks Penelitian Terdahulu

Penelitian mengenai sistem pakar dan metode klasifikasi untuk diagnosis penyakit telah dilakukan oleh berbagai peneliti, termasuk pada kasus *Polycystic Ovary Syndrome* (PCOS) dan gangguan reproduksi lainnya. Berbagai metode seperti *Certainty Factor* dan *Naïve Bayes* telah diterapkan dengan tingkat keberhasilan yang berbeda, tergantung karakteristik data dan model yang digunakan. Berikut rangkuman beberapa penelitian terdahulu yang relevan dengan topik penelitian ini.

Tabel 2.1 Penelitian Terdahulu

No	Peneliti	Judul Penelitian	Metode	Hasil Penelitian
1	Handayani <i>et al.</i> , 2022	<i>Penerapan Certainty Factor dalam Mendiagnosa PCOS</i>	Certainty Factor	Penelitian mengembangkan sistem pakar diagnosis PCOS berbasis <i>Certainty Factor</i> . Sistem menunjukkan nilai CF 116% untuk PCOS berat dan 42% untuk PCOS ringan. Nilai tersebut konsisten dengan penilaian pakar sehingga sistem dinilai valid. Temuan ini memperlihatkan bahwa pendekatan CF mampu merepresentasikan tingkat keyakinan pakar dengan baik. Penelitian juga menyarankan pengembangan sistem ke platform Android serta integrasi dengan metode lain untuk meningkatkan akurasi dan jangkauan pengguna.
2	Halifah <i>et al.</i> , 2023	<i>Implementasi Certainty Factor untuk Penyakit Masa Menstruasi</i>	Certainty Factor	Sistem pakar dibangun untuk mendiagnosis 8 jenis penyakit menstruasi berdasarkan 34 gejala. Dari 15 data sampel yang diuji, 13 hasil diagnosis sesuai dengan pakar sehingga diperoleh

No	Peneliti	Judul Penelitian	Metode	Hasil Penelitian
				akurasi 86%. Narasi penelitian menjelaskan bahwa metode CF memberikan hasil konsisten meskipun gejala yang digunakan bervariasi. Hal ini menunjukkan kemampuan CF dalam menangani ketidakpastian data. Peneliti juga menegaskan perlunya perluasan jumlah sampel agar hasil penelitian lebih representatif.
3	Azzahra & Haerani, 2022	<i>Diagnosa Awal PALM-COEIN Menggunakan CF</i>	Certainty Factor	Sistem pakar menghasilkan persentase kemungkinan penyakit dan rekomendasi berdasarkan gejala yang dipilih pengguna. Hasil contoh perhitungan menunjukkan nilai CF tertinggi pada penyakit Endometrial (0.9302), sementara PCOS berada di angka 0.7702. Pengujian <i>black box</i> menunjukkan seluruh fungsi berjalan baik tanpa kesalahan. Penelitian menegaskan bahwa CF sangat membantu dalam memberikan interpretasi awal sebelum diagnosis lanjutan, meskipun belum menghitung akurasi secara keseluruhan.
4	Murni <i>et al.</i> , 2023	<i>Diagnosa Penyakit Kehamilan Berbasis CF</i>	Certainty Factor	Sistem dibuat untuk mendiagnosis 16 penyakit kehamilan berdasarkan 60 gejala. Dari 48 data uji,

No	Peneliti	Judul Penelitian	Metode	Hasil Penelitian
				sebanyak 44 data (91%) sesuai dengan pakar. Hasil <i>confusion matrix</i> memperlihatkan bahwa sistem memiliki kestabilan diagnosis yang baik. Penelitian ini menyimpulkan bahwa CF efektif digunakan pada kasus kesehatan maternal yang memiliki gejala tumpang tindih. Namun, peneliti mencatat bahwa jumlah data masih terbatas sehingga sistem perlu validasi lanjutan.
5	Wahyudi <i>et al.</i> , 2023	<i>Naïve Bayes untuk Gangguan Menstruasi</i>	Naïve Bayes	Penelitian mengembangkan sistem pakar berbasis <i>Naïve Bayes</i> untuk diagnosis gangguan menstruasi. Sistem diuji menggunakan 50 data pakar dan menghasilkan akurasi 84%. <i>User Acceptance Test</i> menunjukkan tingkat penerimaan pengguna yang tinggi (>80%). Studi ini memperlihatkan bahwa <i>Naïve Bayes</i> mampu melakukan prediksi cepat berdasarkan probabilitas, meskipun akurasi masih bergantung pada kualitas dataset dan asumsi independensi fitur.
6	Andriyanto <i>et al.</i> , 2025	<i>Analisis Data Sintetis PCOS menggunakan NB dan K-NN</i>	Naïve Bayes & K-NN	Penelitian menggunakan 3.000 data sintetis untuk menganalisis PCOS. <i>Naïve Bayes</i> menghasilkan akurasi

No	Peneliti	Judul Penelitian	Metode	Hasil Penelitian
				93,83%, sedangkan K-NN mencapai 99,33%. Narasi penelitian menyoroti bahwa meskipun NB cukup efektif, K-NN lebih unggul karena mampu menangkap pola data yang kompleks. Namun, penggunaan data sintetis menjadi keterbatasan karena belum mencerminkan kondisi klinis yang sebenarnya.
7	Hassan & Mirza, 2020	<i>Comparative Analysis of Machine Learning in PCOS Diagnosis</i>	NB, RF, SVM, CART	Penelitian membandingkan 5 algoritma <i>machine learning</i> menggunakan data dari 10 rumah sakit dengan 42 variabel gejala. <i>Random Forest</i> memberikan performa terbaik dengan akurasi 96%. Meskipun <i>Naïve Bayes</i> termasuk metode yang sederhana dan cepat, performanya merupakan yang terendah di antara algoritma lainnya. Hasil ini menunjukkan bahwa kompleksitas gejala PCOS membutuhkan model yang lebih adaptif dibanding NB.
8	Reswan, n.d.	<i>Perbandingan CF dan NB dalam Diagnosis Katarak</i>	CF & Naïve Bayes	Penelitian membandingkan dua metode kecerdasan buatan. CF menunjukkan akurasi 80%, sementara <i>Naïve Bayes</i> hanya mencapai 68%. Narasi penelitian menegaskan bahwa CF lebih cocok untuk kasus dengan ketidakpastian tinggi karena

No	Peneliti	Judul Penelitian	Metode	Hasil Penelitian
				mempertimbangkan tingkat keyakinan pakar. Sementara itu, NB kurang optimal karena bergantung pada probabilitas historis yang belum tentu mewakili kondisi nyata.
9	Al et al., 2021	<i>Perbandingan NB dan CF untuk Deteksi COVID-19</i>	NB & Certainty Factor	<i>Certainty Factor</i> menghasilkan akurasi hingga 86% berkat penggunaan nilai keyakinan pakar, sedangkan <i>Naïve Bayes</i> memberikan akurasi lebih rendah karena hanya menggunakan probabilitas gejala. Temuan ini menegaskan bahwa CF lebih efektif digunakan pada penyakit dengan variasi gejala tinggi. Peneliti merekomendasikan penggabungan kedua metode untuk meningkatkan kualitas diagnosis.
10	Panjiwijanarko et al., 2025	<i>NB dan CF untuk Diagnosa Penyakit Gigi dan Mulut</i>	NB & Certainty Factor	Sistem pakar berbasis web yang dikembangkan mampu mendiagnosis penyakit gigi dan mulut dengan akurasi 95% dari 20 data uji. Penelitian menunjukkan bahwa kombinasi NB dan CF meningkatkan ketepatan diagnosis, terutama pada daerah yang sulit mengakses layanan kesehatan. Peneliti menyimpulkan bahwa metode gabungan memiliki potensi besar untuk

No	Peneliti	Judul Penelitian	Metode	Hasil Penelitian
				diterapkan pada domain medis lainnya.

2.1.2 Research Gap

Berdasarkan hasil telaah penelitian terdahulu, terdapat beberapa celah penelitian yang menunjukkan perlunya kajian lebih mendalam mengenai penerapan Certainty Factor dan Naïve Bayes dalam deteksi dini Polycystic Ovary Syndrome (PCOS). Penelitian sebelumnya cenderung menggunakan salah satu metode tanpa melakukan perbandingan langsung terhadap performa kedua pendekatan tersebut pada dataset yang sama, sehingga belum dapat diketahui metode yang paling efektif untuk mengidentifikasi pola gejala PCOS secara akurat. Selain itu, sebagian besar studi masih bergantung pada data sintesis atau simulasi, yang belum sepenuhnya merepresentasikan karakteristik gejala PCOS pada kondisi klinis nyata. Penelitian yang berfokus pada diagnosis akhir juga lebih banyak ditemukan dibanding penelitian mengenai deteksi dini, padahal identifikasi awal sangat penting untuk mencegah komplikasi jangka panjang pada penderita PCOS. Evaluasi kinerja metode yang digunakan juga masih terbatas pada akurasi tanpa mempertimbangkan metrik evaluasi lain seperti precision, recall, dan F1-score yang mampu memberikan gambaran lebih komprehensif tentang kualitas prediksi. Di sisi lain, penelitian yang mengintegrasikan pendekatan sistem pakar berbasis Certainty Factor dengan metode probabilistik seperti Naïve Bayes juga masih sangat terbatas, sehingga peluang pengembangan model hybrid yang lebih adaptif dan akurat belum banyak dieksplorasi. Semua kondisi ini menunjukkan adanya ruang penelitian yang signifikan untuk membandingkan kedua metode secara objektif, menggunakan data yang lebih representatif, serta mengevaluasi performa model secara menyeluruh pada konteks deteksi dini PCOS.

2.2 Tinjauan Pustaka

2.2.1 Sistem Pakar

Sistem pakar (*expert system*) merupakan salah satu cabang dari kecerdasan buatan yang dirancang untuk menirukan proses berpikir dan kemampuan pengambilan keputusan seorang pakar dalam bidang tertentu. Menurut Andriani (2017), sistem pakar adalah sistem komputer yang mengadopsi keahlian seorang pakar ke dalam bentuk program dengan tujuan membantu pengguna yang bukan pakar dalam mengambil keputusan secara tepat. Sistem pakar memungkinkan pengguna memperoleh solusi seolah-olah mereka berkonsultasi langsung dengan pakar manusia, sehingga teknologi ini sangat bermanfaat dalam bidang yang membutuhkan diagnosis cepat dan tepat, termasuk dalam analisis gejala medis.

Sistem pakar pada dasarnya bekerja dengan memanfaatkan basis pengetahuan (*knowledge base*) dan mesin inferensi (*inference engine*) untuk menghasilkan kesimpulan berdasarkan fakta yang diberikan oleh pengguna. Menurut Turban dan Aronson (2005), sistem pakar digunakan untuk menyelesaikan masalah yang bersifat kompleks, membutuhkan keahlian khusus, atau memerlukan penilaian berbasis pengalaman. Dalam konteks kesehatan, sistem pakar terbukti efektif dalam memberikan diagnosis awal untuk berbagai penyakit karena mampu mengolah gejala yang tidak selalu jelas atau konsisten. Oleh karena itu, penggunaan sistem pakar menjadi relevan dalam penelitian ini, yang berfokus pada identifikasi dini *Polycystic Ovary Syndrome* (PCOS) yang memiliki ragam gejala luas dan sering tidak mudah dikenali.

2.2.2 Konsep Dasar Sistem Pakar

Sistem pakar (*expert system*) dibangun berdasarkan konsep bahwa pengetahuan manusia dapat ditransformasikan ke dalam bentuk komputasional sehingga komputer mampu mengambil keputusan layaknya seorang pakar. Menurut Durkin (1994), sistem pakar bekerja dengan mengintegrasikan pengetahuan, logika penalaran, dan mekanisme pengambilan keputusan sehingga mampu memecahkan masalah yang bersifat kompleks. Dalam konteks medis, pendekatan ini menjadi sangat penting karena diagnosis penyakit sering mengandung ketidakpastian dan membutuhkan keahlian berbasis pengalaman. Oleh karena itu, sistem pakar menjadi salah satu pendekatan yang paling relevan digunakan dalam membantu identifikasi dini *Polycystic Ovary Syndrome* (PCOS), yang memiliki variasi gejala dan tingkat kompleksitas tinggi (Handayani *et al.*, 2022).

Konsep dasar sistem pakar mencakup serangkaian komponen yang bekerja secara terstruktur. Komponen pertama adalah keahlian (*expertise*), yaitu kumpulan pengetahuan khusus yang diperoleh dari pakar melalui pengalaman bertahun-tahun. Keahlian ini mencakup pemahaman tentang pola gejala, hubungan antarvariabel, aturan diagnosis, serta strategi penyelesaian masalah. Menurut Durkin (1994), pengetahuan tersebut harus direpresentasikan dalam bentuk yang dapat diproses komputer melalui aturan produksi (*if-then rules*), logika formal, pohon keputusan, atau model heuristik. Representasi pengetahuan yang tepat sangat mempengaruhi performa sistem pakar dalam menghasilkan diagnosis yang akurat.

Komponen kedua adalah pakar (*expert*), yaitu individu atau kelompok yang menjadi sumber pengetahuan utama bagi sistem. Liebowitz (1998) menyatakan bahwa seorang pakar tidak hanya memiliki pengetahuan teoretis, tetapi juga kemampuan memberikan penilaian intuitif berdasarkan pengalaman. Pengetahuan yang diambil dari pakar inilah yang menentukan kualitas dan ketelitian basis pengetahuan sistem. Dalam penelitian medis, pakar biasanya adalah dokter

spesialis, ahli endokrin, atau ginekolog yang memiliki pengalaman menangani kasus tertentu seperti PCOS.

Komponen ketiga adalah akuisisi pengetahuan (*knowledge acquisition*), yaitu proses pengumpulan dan pemodelan pengetahuan dari pakar atau sumber ilmiah lainnya ke dalam struktur komputasi. Proses ini dapat dilakukan melalui penelaahan literatur medis (Liebowitz, 1998).

Komponen keempat adalah basis pengetahuan (*knowledge base*), yang berfungsi menyimpan seluruh aturan, fakta, hubungan logis, dan pola diagnosis. Durkin (1994) menegaskan bahwa basis pengetahuan harus lengkap, konsisten, dan terstruktur secara logis. Dalam sistem diagnosis PCOS, basis pengetahuan harus mencakup daftar gejala klinis, hubungan antara gejala dan tingkat keparahan, serta kriteria medis berbasis penelitian seperti *Rotterdam Criteria* (Escobar-Morreale, 2018).

Komponen kelima adalah mesin inferensi (*inference engine*), yaitu bagian sistem yang melakukan proses penalaran untuk menghasilkan kesimpulan. Mesin inferensi bekerja dengan dua pendekatan utama: *forward chaining* (penalaran maju) dan *backward chaining* (penalaran mundur). Menurut Turban dan Aronson (2005), *forward chaining* dimulai dari fakta menuju kesimpulan, sedangkan *backward chaining* dimulai dari dugaan kesimpulan kemudian ditelusuri kembali faktanya. Dalam diagnosis penyakit, *forward chaining* sering digunakan karena lebih sesuai untuk memproses input berupa gejala pengguna.

Komponen keenam adalah representasi pengetahuan (*knowledge representation*), yaitu metode yang digunakan untuk memodelkan pengetahuan pakar ke dalam bentuk formal. Giarratano dan Riley (2005) menyatakan bahwa bentuk representasi yang paling umum adalah aturan produksi *IF-THEN* karena struktur ini mudah dimengerti oleh komputer dan manusia. Selain itu, representasi ini memungkinkan proses inferensi dilakukan secara sistematis dan efisien, terutama pada data medis yang memiliki ketergantungan antar gejala.

Komponen ketujuh adalah antarmuka pengguna (*user interface*), yang berfungsi menghubungkan sistem dengan pengguna. Antarmuka ini harus dirancang agar mudah digunakan dan mampu menampilkan hasil diagnosis secara jelas dan informatif. Dalam kasus PCOS, antarmuka pengguna harus memungkinkan input berupa gejala klinis seperti pola menstruasi, kondisi fisik, dan riwayat medis (Turban & Aronson, 2005).

Komponen kedelapan adalah fasilitas penjelasan (*explanation facility*), yaitu kemampuan sistem menjelaskan alasan dan proses di balik hasil diagnosis. Durkin (1994) menegaskan bahwa komponen ini sangat penting dalam aplikasi medis karena pengguna, termasuk tenaga kesehatan, perlu memahami dasar penalaran sistem sebelum menerima hasil diagnosis. Fasilitas ini memberikan

transparansi untuk meningkatkan kepercayaan pengguna terhadap keputusan sistem.

Komponen kesembilan adalah mekanisme pengendalian (*control mechanism*), yaitu aturan atau prosedur yang mengatur urutan operasi mesin inferensi, pemanggilan aturan, dan pemilihan keputusan terbaik ketika terdapat beberapa kemungkinan diagnosis (Giarratano & Riley, 2005). Mekanisme ini memastikan sistem bekerja secara efisien dan konsisten.

Konsep sistem pakar menunjukkan bahwa teknologi ini relevan digunakan untuk membantu identifikasi dini *Polycystic Ovary Syndrome* (PCOS). Kompleksitas gejala PCOS yang bervariasi antarindividu, ketidakpastian informasi yang sering muncul dari pasien, serta kebutuhan akan proses diagnosis yang cepat menjadikan sistem pakar sebagai pendekatan yang efektif untuk menganalisis pola gejala secara terstruktur. Dengan mekanisme penalaran berbasis aturan dan representasi pengetahuan pakar, sistem pakar mampu memberikan estimasi awal mengenai kemungkinan PCOS sehingga pengguna dapat memperoleh informasi dini sebelum melakukan pemeriksaan medis lanjutan. Pendekatan ini berpotensi meningkatkan deteksi awal dan mengurangi risiko komplikasi jangka panjang pada pasien PCOS.

2.3 *Polycystic Ovary Syndrome* (PCOS)

Polycystic Ovary Syndrome (PCOS) merupakan salah satu gangguan endokrin reproduksi yang paling sering dialami perempuan usia subur dan menjadi penyebab umum amenore anovulatorik kronik (Azziz *et al.*, 2016). Kondisi ini ditandai oleh kombinasi gejala klinis seperti oligomenore atau amenore, tanda hiperandrogenisme termasuk hirsutisme dan jerawat, serta gambaran ovarium polikistik pada pemeriksaan ultrasonografi. PCOS memiliki spektrum gejala yang bervariasi, sehingga diagnosis sering membutuhkan evaluasi multidimensional yang mencakup aspek klinis, hormonal, dan radiologis (Rosenfield & Ehrmann, 2016). Keberagaman gejala ini menjadikan PCOS sebagai sindrom kompleks yang memerlukan pendekatan analitis untuk mengidentifikasi pola gangguan secara lebih akurat.

Patofisiologi PCOS melibatkan berbagai mekanisme biologis yang saling berinteraksi. Salah satu mekanisme yang sering dikaitkan adalah peningkatan sekresi pulsatif hormon *Gonadotropin-Releasing Hormone* (GnRH), yang mengarah pada peningkatan produksi *Luteinizing Hormone* (LH) dan ketidakseimbangan rasio LH/FSH (*Follicle Stimulating Hormone*). Ketidakseimbangan tersebut menyebabkan gangguan maturasi folikel dan berkontribusi pada tidak terjadinya ovulasi (Escobar-Morreale, 2018). Selain itu, banyak pasien PCOS menunjukkan gangguan sensitivitas insulin dan kelainan pada jalur sinyal insulin, termasuk transport glukosa dan proses lipolisis, yang

menghasilkan kondisi resistensi insulin. Resistensi insulin ini dapat memicu hiperinsulinemia yang selanjutnya meningkatkan stimulasi produksi androgen oleh ovarium.

Proses hiperandrogenisme pada PCOS terutama dipengaruhi oleh aktivitas sel teka ovarium. Sel teka mengalami peningkatan proliferasi dan menghasilkan androgen dalam jumlah berlebihan akibat stimulasi LH dan insulin yang tinggi (Heffner & Schust, 2006). Kelebihan androgen menghambat perkembangan folikel, sehingga banyak folikel berhenti berkembang pada fase pertengahan dan tidak mencapai maturitas. Kondisi ini menyebabkan penumpukan folikel-folikel kecil di tepi ovarium, yang pada pemeriksaan ultrasonografi menghasilkan tampilan khas berupa susunan folikel menyerupai “untaian mutiara”. Gambaran tersebut merupakan salah satu indikator visual yang sering digunakan dalam penilaian radiologis terhadap dugaan PCOS.

Selain aspek fisiologis, PCOS juga berkaitan dengan berbagai faktor metabolik dan risiko jangka panjang seperti obesitas, intoleransi glukosa, diabetes tipe 2, dan dislipidemia (Escobar-Morreale, 2018). Dampak PCOS tidak hanya terbatas pada sistem reproduksi, tetapi juga memengaruhi kualitas hidup pasien melalui gangguan emosional, kecemasan, dan rendahnya kepercayaan diri akibat manifestasi fisik. Kompleksitas PCOS ini menunjukkan perlunya metode identifikasi yang lebih sistematis, termasuk pemanfaatan teknologi kecerdasan buatan untuk mendeteksi pola gejala lebih cepat berdasarkan data klinis.

2.4 *Certainty Factor*

Konsep *Certainty Factor* (CF) merupakan salah satu pendekatan yang digunakan dalam sistem pakar untuk menangani ketidakpastian informasi, terutama pada bidang medis ketika gejala tidak selalu muncul secara lengkap dan konsisten. Pendekatan ini pertama kali diperkenalkan oleh Shortliffe dan Buchanan pada awal pengembangan sistem pakar MYCIN, sebuah sistem diagnosis penyakit infeksi, untuk merepresentasikan tingkat keyakinan pakar terhadap suatu hipotesis berdasarkan gejala tertentu (Shortliffe & Buchanan, 1975). *Certainty Factor* menggambarkan sejauh mana suatu fakta atau aturan diyakini benar atau salah, sehingga dapat digunakan sebagai dasar dalam proses penalaran sistem pakar yang berorientasi pada ketidakpastian.

Dalam konsepnya, nilai CF berada dalam rentang $-1,0$ hingga $+1,0$. Nilai $+1,0$ menunjukkan tingkat keyakinan penuh bahwa hipotesis benar, sedangkan nilai $-1,0$ menunjukkan keyakinan penuh bahwa hipotesis salah. Nilai positif menggambarkan derajat kepercayaan (*measure of belief*), sementara nilai negatif menggambarkan derajat ketidakpercayaan (*measure of disbelief*). Menurut Turban (2005), formulasi dasar *Certainty Factor* dapat dinyatakan sebagai berikut:

$$CF[h, e] = MB[h, e] - MD[h, e] \quad (1)$$

dengan keterangan:

- a) $CF[h,e]$ = nilai faktor kepastian untuk hipotesis h berdasarkan evidensi e
- b) $MB[h,e]$ = tingkat kepercayaan pakar terhadap hipotesis
- c) $MD[h,e]$ = tingkat ketidakpercayaan pakar terhadap hipotesis

Nilai MB dan MD berada dalam rentang 0 hingga 1. Jika suatu gejala hanya memiliki satu nilai CF dari pakar, maka nilai tersebut langsung digunakan dalam perhitungan. Namun, jika terdapat lebih dari satu aturan atau gejala yang berkaitan dengan hipotesis yang sama, maka diperlukan proses kombinasi nilai CF. Kombinasi nilai CF diterapkan ketika beberapa evidensi mendukung hipotesis tertentu. Menurut Turban (2005), kombinasi CF dapat dihitung menggunakan rumus berikut:

CF untuk satu gejala:

$$CF_{gejala} = CF_{user} \times CF_{pakar} \quad (2)$$

CF kombinasi dari beberapa gejala:

$$CF_{combine} = CF_{old} + CF_{gejala}(1 - CF_{old}) \quad (3)$$

Rumus ini digunakan ketika seluruh nilai CF bernilai positif. Jika terdapat nilai negatif, rumus disesuaikan sebagai berikut:

Jika keduanya positif:

$$CF_c = CF_1 + CF_2(1 - CF_1) \quad (4)$$

Jika keduanya negatif:

$$CF_c = CF_1 + CF_2(1 + CF_1) \quad (5)$$

Jika salah satunya bernilai negatif:

$$CF_c = \frac{CF_1 + CF_2}{1 - \min(|CF_1|, |CF_2|)} \quad (6)$$

Hasil kombinasi CF dapat dikonversikan ke dalam persentase menggunakan formula:

$$CF_{persentase} = CF_{combine} \times 100 \quad (7)$$

Pakar biasanya menetapkan nilai CF berdasarkan tingkat keyakinan menggunakan istilah linguistik seperti “mungkin”, “kemungkinan besar”, atau “hampir pasti”. Nilai-nilai tersebut kemudian ditransformasikan ke dalam nilai numerik, misalnya +0,8 untuk “hampir pasti benar” atau -0,6 untuk “kemungkinan besar tidak benar” (Andriani, 2017).

Tabel 2.2 Nilai *Certainty Factor*

Term	Nilai Certainty Factor (CF)
Pasti tidak	-1.0
Hampir pasti tidak	-0.8
Kemungkinan besar tidak	-0.6

Mungkin tidak	-0.4
Tidak tahu	-0.2 sampai 0.2
Mungkin	+0.4
Kemungkinan besar	+0.6
Hampir pasti	+0.8
Pasti	+1.0

(Sumber : Anik Andriani (2017 : 19))

Pendekatan *Certainty Factor* sangat relevan digunakan dalam diagnosis penyakit yang memiliki variasi gejala seperti *Polycystic Ovary Syndrome* (PCOS). Ketidakpastian data pasien, perbedaan tingkat keparahan gejala, serta variasi respon tubuh terhadap perubahan hormonal menjadikan CF sebagai metode yang mampu menangani informasi yang tidak tegas. Dengan kemampuan mengakomodasi nilai keyakinan pakar dan nilai input dari pengguna, metode ini dapat membantu menghasilkan hasil diagnosis awal yang relatif akurat serta memberikan gambaran mengenai tingkat kemungkinan suatu penyakit (Handayani *et al.*, 2022).

2.5 Naïve Bayes

Metode *Naïve Bayes* merupakan algoritma klasifikasi yang banyak digunakan dalam *data mining* dan *machine learning* karena bekerja berdasarkan teori probabilitas *Bayes' Theorem*. Metode ini disebut *naïve* karena mengasumsikan bahwa setiap atribut atau fitur dalam proses klasifikasi bersifat saling bebas (*independent*), meskipun dalam praktik tidak selalu demikian (Han, Kamber, & Pei, 2012). Asumsi independensi ini menghasilkan model yang sederhana namun mampu memberikan performa klasifikasi yang kompetitif pada berbagai jenis data.

Menurut Han, Kamber, dan Pei (2012), "*Naïve Bayes classifiers are a family of simple probabilistic classifiers based on applying Bayes' theorem with strong (naïve) independence assumptions between the features.*" Dengan pendekatan ini, *Naïve Bayes* menghitung probabilitas posterior dari setiap kelas berdasarkan fitur masukan, kemudian memilih kelas dengan nilai probabilitas tertinggi sebagai hasil prediksi. Pendekatan probabilistik tersebut memungkinkan metode ini digunakan secara efektif untuk permasalahan klasifikasi berbasis gejala seperti identifikasi awal *Polycystic Ovary Syndrome* (PCOS).

Rumus dasar *Bayes' Theorem* yang digunakan dalam metode ini adalah sebagai berikut:

$$P(C_i | X) = \frac{P(X|C_i) P(C_i)}{P(X)} \quad (8)$$

dengan keterangan:

$P(C_i|X)$: probabilitas kelas C_i berdasarkan fitur X (*posterior probability*)

$P(X|C_i)$: probabilitas fitur X muncul pada kelas C_i

$P(C_i)$: probabilitas awal suatu kelas (*prior probability*)

$P(X)$: probabilitas terjadinya fitur X (*evidence*)

Dalam implementasinya, probabilitas gabungan fitur dihitung sebagai perkalian probabilitas masing-masing fitur karena adanya asumsi independensi. Sifat ini membuat *Naïve Bayes* bekerja cepat, efisien, dan mudah diimplementasikan, terutama pada *dataset* yang berukuran besar.

Rish (2001) menyatakan bahwa meskipun sederhana, *Naïve Bayes* mampu menghasilkan performa klasifikasi yang tinggi dan dalam beberapa kasus bahkan mengungguli metode yang lebih kompleks. Keandalan metode ini meningkat ketika distribusi data sesuai dengan asumsi independensi antar fitur. Dalam konteks penelitian diagnosis penyakit, metode *Naïve Bayes* sering digunakan untuk memprediksi probabilitas kondisi klinis berdasarkan kombinasi gejala yang dilaporkan pasien, sehingga relevan untuk digunakan dalam analisis dan identifikasi dini gejala PCOS.

2.6 Evaluasi Kinerja Sistem

Evaluasi kinerja sistem merupakan langkah penting dalam menilai efektivitas metode klasifikasi atau sistem pakar dalam melakukan identifikasi suatu kondisi berdasarkan data yang diberikan. Dalam penelitian ini, evaluasi dilakukan untuk mengukur sejauh mana metode *Naïve Bayes* dan *Certainty Factor* mampu mengidentifikasi gejala awal *Polycystic Ovary Syndrome* (PCOS) secara akurat. Menurut Powers (2011), pengukuran kinerja sistem klasifikasi dapat dilakukan menggunakan beberapa metrik utama, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*.

1. Accuracy

Accuracy merupakan metrik yang menghitung persentase prediksi yang benar dibandingkan dengan seluruh data yang diuji. Rumusnya adalah:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100 \quad (9)$$

di mana:

TP (True Positive) = kasus positif yang terdeteksi benar

TN (True Negative) = kasus negatif yang terdeteksi benar

FP (False Positive) = kasus negatif yang terdeteksi salah sebagai positif

FN (False Negative) = kasus positif yang terdeteksi salah sebagai negatif

Metrik ini sering digunakan karena memberikan gambaran umum performa model, meskipun kurang sensitif terhadap ketidakseimbangan data (Powers, 2011).

2. Precision

Precision mengukur tingkat ketepatan prediksi positif, yaitu seberapa besar hasil prediksi positif benar-benar sesuai dengan kondisi sebenarnya. Rumusnya adalah:

$$Precision = \frac{TP}{TP+FP} \quad (10)$$

Nilai *precision* yang tinggi menunjukkan bahwa model jarang memberikan prediksi positif yang salah, sehingga relevan pada kasus di mana kesalahan diagnosis positif perlu diminimalkan.

3. Recall

Recall atau *sensitivity* menghitung kemampuan model dalam mengenali seluruh kasus positif secara benar. Rumusnya:

$$Recall = \frac{TP}{TP+FN} \quad (11)$$

Nilai *recall* tinggi menunjukkan bahwa model mampu mendeteksi sebagian besar kasus positif. Pada diagnosis penyakit seperti PCOS, nilai *recall* penting karena kesalahan tidak mendeteksi (FN) dapat berdampak pada keterlambatan penanganan (Powers, 2011).

4. F1-Score

F1-score merupakan nilai rata-rata harmonis dari *precision* dan *recall*, sehingga dapat digunakan untuk menilai keseimbangan kedua metrik tersebut. Rumusnya adalah:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (12)$$

Metrik ini berguna ketika diperlukan evaluasi yang mempertimbangkan keseimbangan antara ketepatan dan kemampuan deteksi, terutama pada kasus dengan distribusi data tidak merata atau gejala yang bervariasi.

Evaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score penting untuk mengukur kinerja model integrasi *Naïve Bayes* berbasis *Certainty Factor* dalam mengidentifikasi gejala awal PCOS. Hasil pengukuran tersebut digunakan untuk menilai efektivitas pendekatan terintegrasi yang diterapkan, sehingga diperoleh gambaran objektif mengenai kemampuan sistem dalam melakukan klasifikasi dan memberikan tingkat keyakinan hasil diagnosis.

2.7 Penggunaan Software Python dalam Penelitian

Python merupakan salah satu bahasa pemrograman yang paling banyak digunakan dalam bidang data science, machine learning, dan analisis medis karena fleksibilitas, struktur sintaks yang sederhana, serta dukungan ekosistem library yang sangat luas. Dalam penelitian ini, Python digunakan sebagai perangkat lunak utama untuk pengolahan data, diskretisasi variabel, perhitungan probabilitas, pembangunan model *Naive Bayes*, implementasi metode *Certainty Factor*, hingga evaluasi performa model melalui confusion matrix, precision, recall, dan accuracy. Kekuatan Python dalam analisis data telah didukung oleh berbagai literatur yang menunjukkan keandalan dan efisiensinya dalam pengembangan model prediktif,

terutama di bidang kesehatan reproduksi dan diagnosis berbasis machine learning (Raschka & Mirjalili, 2019; Géron, 2022; McKinney, 2022).

Fungsi Python dalam penelitian ini mencakup beberapa tahap penting. Pertama, pembersihan dan transformasi data dilakukan menggunakan library Pandas dan NumPy, yang dirancang untuk pengelolaan data terstruktur dalam format tabular. Kedua, Python memfasilitasi diskretisasi variabel numerik menjadi kategori, sebuah langkah penting dalam implementasi Naive Bayes berbasis data kategorik. Ketiga, Python memungkinkan perhitungan probabilitas prior, likelihood, dan posterior secara konsisten dan otomatis menggunakan kemampuan perhitungan matematis berbasis vektor. Keempat, Python digunakan untuk membangun dan mengevaluasi model Naive Bayes melalui Scikit-learn, sebuah library machine learning yang telah menjadi standar industri karena kestabilannya serta dokumentasi yang lengkap dan komprehensif (Pedregosa *et al.*, 2011; revisi 2020). Selain itu, Python juga digunakan untuk mengimplementasikan Certainty Factor (CF) melalui perhitungan manual yang mengikuti formula sistem pakar, sehingga keseluruhan proses dapat direplikasi dan diaudit secara transparan.

Python juga memiliki kemampuan visualisasi yang kuat melalui Matplotlib dan Seaborn, memungkinkan peneliti menghasilkan grafik seperti confusion matrix (Gambar 4.1), distribusi data awal, serta grafik perbandingan performa metode. Visualisasi yang dihasilkan mempermudah interpretasi hasil dan memastikan bahwa setiap tahapan analisis dapat dipantau serta dievaluasi secara objektif. Selain itu, penggunaan Jupyter Notebook sebagai lingkungan kerja memberikan keuntungan berupa dokumentasi otomatis atas seluruh langkah komputasi, sehingga memudahkan proses peninjauan, replikasi, serta pembuktian metodologis penelitian. Sejumlah penelitian terbaru juga menegaskan bahwa Python sangat efektif digunakan dalam bidang bioinformatika, epidemiologi, dan diagnosis prediktif pada data kesehatan (van Rossum & Drake, 2023; Flores *et al.*, 2021).


2.8 Kerangka Pemikiran

Diagnosis dini *Polycystic Ovary Syndrome* (PCOS) sering menghadapi tantangan akibat variasi gejala yang muncul pada setiap individu. Gejala seperti gangguan menstruasi, hiperandrogenisme, dan perubahan morfologi ovarium memiliki tingkat kemunculan yang berbeda pada setiap pasien sehingga menyulitkan proses identifikasi. Kondisi tersebut diperburuk oleh keterbatasan akses alat diagnostik serta pemahaman masyarakat mengenai indikator PCOS, sehingga banyak kasus tidak terdeteksi pada tahap awal. Oleh sebab itu, diperlukan pendekatan berbasis teknologi yang mampu membantu proses identifikasi awal PCOS secara terstruktur, cepat, dan fleksibel terhadap ketidakpastian data.

Dalam penelitian ini, dua metode komputasi digunakan untuk membangun sistem identifikasi awal, yaitu *Naïve Bayes* dan *Certainty Factor*. Metode *Naïve*

Bayes memanfaatkan probabilitas untuk mengklasifikasikan gejala menjadi kategori tertentu, sedangkan *Certainty Factor* menggunakan tingkat keyakinan pakar untuk menangani ketidakpastian informasi. Perbedaan karakteristik kedua metode tersebut memberikan dasar untuk dikembangkan dalam satu kerangka integratif. Pendekatan probabilistik pada *Naïve Bayes* memungkinkan pemodelan berbasis distribusi data gejala, sementara pendekatan berbasis keyakinan pada *Certainty Factor* memperkuat hasil klasifikasi dengan mempertimbangkan ketidakpastian klinis. Dengan demikian, kombinasi kedua metode ini diharapkan mampu menghasilkan sistem identifikasi dini PCOS yang lebih komprehensif.

Proses penelitian dilakukan dengan merumuskan data gejala yang relevan berdasarkan literatur dan sumber medis, kemudian menerapkannya pada kedua metode yang diuji. Hasil keluaran sistem dianalisis menggunakan metrik evaluasi klasifikasi, yaitu akurasi, presisi, recall, dan F1-score. Metrik tersebut digunakan untuk menilai seberapa tepat masing-masing metode dalam mengidentifikasi gejala awal PCOS pada data uji. Melalui proses ini, dapat diamati perbedaan kinerja antara kedua pendekatan serta kecocokannya untuk digunakan dalam sistem pendukung keputusan.



Gambar 2.1 Kerangka Operasional Penelitian