

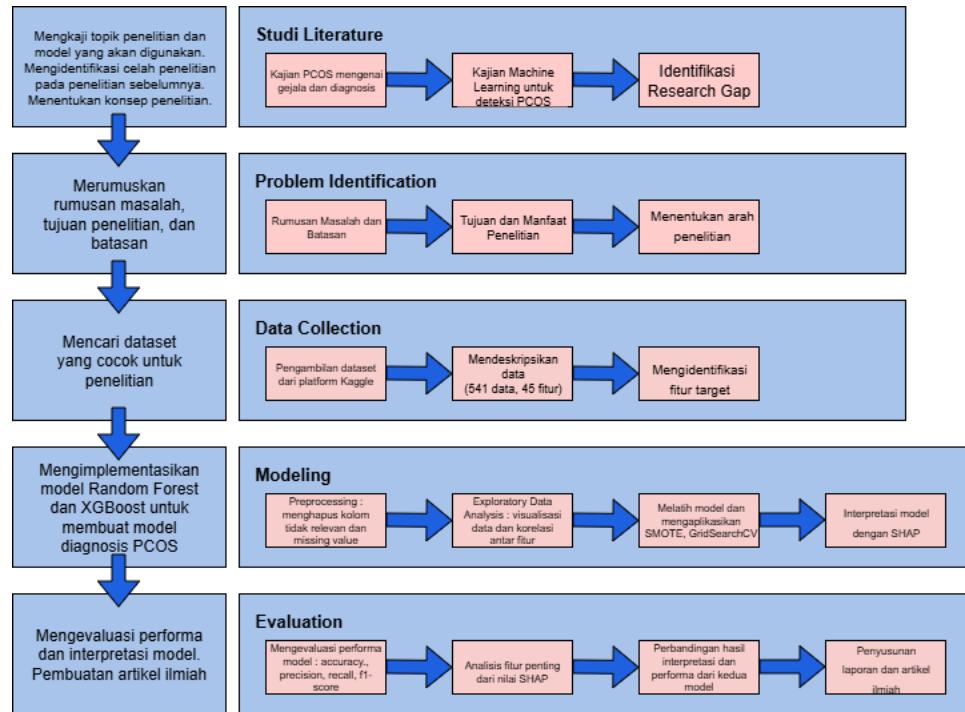
## **BAB III**

### **METODOLOGI PENELITIAN**

#### **3.1 Langkah-langkah Penelitian**

Penelitian ini diawali dengan melakukan pengumpulan data melalui studi literatur. Tahapan ini, dilakukan guna mengidentifikasi permasalahan serta celah penelitian dari topik penelitian yang diambil. Selanjutnya, setelah data-data dikumpulkan masalah diidentifikasi guna menentukan arah dan tujuan penelitian.

Kemudian, dirancang juga proses penerapan modelnya dari mulai pra-pemrosesan data, pelatihan model, evaluasi, hingga interpretasi. Setiap tahapan dilakukan secara sistematis untuk memastikan kualitas hasil penelitian. Terakhir, dilakukan evaluasi menyeluruh terhadap seluruh proses penelitian, dimulai dari tahapan pengumpulan data hingga proses pengujian dan interpretasi model. Alur penelitian ini dapat dilihat pada Gambar 3.1.



Gambar 3. 1 Alur Penelitian

### 3.2 Studi Literatur

Studi literatur dilakukan untuk mencari informasi mengenai *Polyzystic Ovary Syndrome* (PCOS) seperti gejala, diagnosis, faktor penyebabnya dari sisi medis. Selain itu, studi literatur juga dilakukan untuk memahami berbagai pendekatan yang dilakukan untuk mendiagnosis PCOS, algoritma machine learning yang biasa digunakan, teknik penanganan data *imbalance*, serta metode interpretabilitas model seperti SHAP. Proses ini melibatkan pengkajian literatur dari sisi medis maupun komputasional, dengan sumber yang berasal dari artikel ilmiah internasional dan lokal. Di samping itu, studi literatur juga dilakukan untuk mengidentifikasi celah-celah penelitian dari penelitian sebelumnya (*research gap*).

### **3.3 Problem Identification (Perumusan Masalah)**

Berdasarkan studi literatur, penelitian mengenai prediksi atau diagnosis penyakit *Polycystic Ovary Syndrome* (PCOS) telah banyak dilakukan, umumnya model dapat memprediksi atau mendiagnosis dengan akurasi yang baik. Namun, meskipun banyak model dengan akurasi yang baik, model tersebut masih tergolong *blackbox* karena tidak dapat memberikan informasi yang jelas mengenai fitur mana yang paling berkontribusi dalam keputusan model. Sedangkan, PCOS adalah sebuah penyakit dengan gejala yang bervariasi untuk setiap individunya, atau bahkan gejala yang ditampilkan mirip dengan penyakit hormonal lainnya. Sehingga diperlukan model yang mampu menjelaskan atau memberikan informasi mengenai keputusan model dengan baik. Oleh karena itu, penelitian ini tidak hanya berfokus pada model dengan akurasi yang baik, tetapi juga pada interpretasi hasil prediksi dengan menggunakan metode SHAP.

### **3.4 Data Collection (Pengumpulan Data)**

Perolehan dataset PCOS dari platform Kaggle, dengan jumlah sampel data 541, dan 45 fitur.

### **3.5 Predictive Model Implementation (Penerapan Model Prediksi)**

Dataset yang digunakan pada penelitian ini bersumber dari repositori terbuka, yakni platform Kaggle. Dataset ini terdiri dari fitur-fitur klinis yang relevan terhadap diagnosis PCOS, seperti kadar AMH, beta-HCG, serta

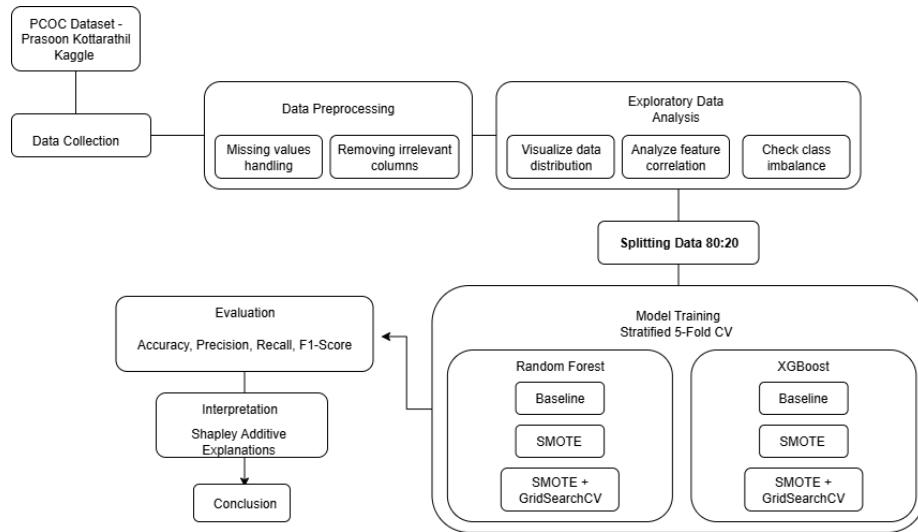
label diagnosis (PCOS Y/N). Dataset ini terdiri dari total 541 sampel dan 45 fitur.

Dalam pengerjaan proses ini, Google Colab digunakan sebagai *software* utama, sedangkan Jupyter Notebook digunakan sebagai alternatif apabila Google Colab mengalami gangguan. *Library* atau Pustaka yang digunakan dalam proses pelatihan, evaluasi hingga interpretasi tertera pada Tabel 3.1.

Tabel 3. 1 Library-library yang Digunakan

No.	<i>Library / Pustaka</i>	Fungsi
1.	pandas, numpy	Manipulasi data dan perhitungan numerik.
2.	matplotlib, seaborn	Visualisasi data untuk eksplorasi dan analisis awal.
3.	scikit-learn	Preprocessing, SMOTE, implementasi Random Forest.
4.	xgboost	Implementasi model Extreme Gradient Boosting.
5.	shap	Interpretasi model menggunakan SHAP.

Proses penerapan model prediksi diawali dengan *preprocessing*, *exploratory data analysis* (EDA), pelatihan model, evaluasi performa berdasarkan metrik klasifikasi (akurasi, *precision*, *recall*, dan *F1-score*), hingga analisis intrepretasi model dengan menggunakan SHAP. Diagram alur proses penerapan model dapat dilihat pada Gambar 3.2 di bawah ini.



Gambar 3. 2. Alur Penerapan Model

### 3.5.1 *Data Preprocessing*

Tahapan pra-pemrosesan data dilakukan dengan tujuan untuk membersihkan dan menyiapkan data agar siap diproses pada pelatihan model. Proses ini melibatkan Langkah-langkah sebagai berikut :

1. Menghapus kolom yang tidak relevan

Proses ini dilakukan untuk menghilangkan fitur-fitur yang tidak diperlukan atau tidak memiliki kontribusi signifikan terhadap proses pelatihan model. Biasanya, fitur yang dihapus ialah fitur yang berisi informasi yang bersifat identitas, data duplikatif, atau fitur yang memiliki korelasi rendah terhadap variable target. Proses ini bertujuan untuk menyederhanakan dataset, mengurangi kompleksitas model, dan meningkatkan efisiensi komputasi.

2. *Missing values handling*

Proses penanganan *missing value* dilakukan untuk menghilangkan atau mengisi nilai-nilai kosong yang dapat mengganggu kinerja model. Penanganan ini biasanya dapat dilakukan dengan berbagai metode, seperti menghilangkan fitur yang terlalu banyak memiliki nilai kosong, apabila datanya dengan nilai kosong berjumlah sedikit dilakukan penghapusan baris dengan nilai kosong, atau nilai kosong diisi dengan menggunakan teknik imputasi seperti mean, modus, median, atau metode berbasis model berdasarkan jenis dan distribusi data. Proses ini bertujuan untuk menjaga kualitas dan konsistensi data agar model dapat belajar secara optimal tanpa terpengaruh oleh informasi yang tidak lengkap.

### **3.5.2 Exploratory Data Analysis**

Tahapan ini merupakan tahapan pada proses analisis data yang bertujuan untuk memahami struktur dan karakteristik data dan mengidentifikasi pola-pola hubungan antar fitur. Tahapan ini merupakan tahapan yang krusial dalam menentukan pemodelan dan interpretasi hasil.

Dataset yang digunakan dalam penelitian ini merupakan data diagnosis *Polycystic Ovary Syndrome* (PCOS) yang bersumber dari situs Kaggle. Terdiri dari 541 baris data dan 45 fitur yang dideskripsikan pada Tabel 3.2 .

Tabel 3. 2 Deskripsi Fitur-fitur

No.	Nama Fitur	Deskripsi
1.	Sl. No.	Nomor urut entri data. Tidak memiliki makna analitik.

No.	Nama Fitur	Deskripsi
2.	Patient File No.	ID unik pasien. Tidak digunakan dalam analisis.
3.	PCOS (Y/N)	Label diagnosis: 1 = Terdiagnosis PCOS, 0 = Tidak PCOS. (target variabel)
4.	Age (yrs)	Usia pasien dalam tahun.
5.	Weight (Kg)	Berat badan pasien dalam kilogram.
6.	Height (Cm)	Tinggi badan pasien dalam sentimeter.
7.	BMI	Indeks massa tubuh, dihitung dari berat dan tinggi badan.
8.	Blood Group	Golongan darah pasien (dikodekan numerik).
9.	Pulse rate (bpm)	Detak jantung per menit.
10.	RR (breaths/min)	Laju pernapasan (Respiratory Rate) dalam satuan napas/menit.
11.	Hb(g/dl)	Kadar hemoglobin dalam darah (g/dL).
12.	Cycle(R/I)	Siklus menstruasi : Regular/Irregular
13.	Cycle length(days)	Panjang siklus haid dalam hari.
14.	Marraige Status (Yrs)	Status pernikahan (dalam tahun).
15.	Pregnant(Y/N)	Status kehamilan: 1 = Ya, 0 = Tidak.
16.	No. of abosptions	Jumlah aborsi yang pernah dialami.
17.	I beta-HCG(mIU/mL)	Kadar hormon beta-HCG (indikator kehamilan atau abnormalitas).
18.	II beta-HCG(mIU/mL)	Pengukuran kedua hormon beta-HCG.
19.	FSH(mIU/mL)	Hormon perangsang folikel (Follicle Stimulating Hormone).
20.	LH(mIU/mL)	Hormon luteinizing (Luteinizing Hormone).
21.	FSH/LH	Rasio antara FSH dan LH.

No.	Nama Fitur	Deskripsi
22.	Hipertension (Y/N)	Riwayat hipertensi: 1 = Ya, 0 = Tidak.
23.	Diabetes(Y/N)	Riwayat diabetes: 1 = Ya, 0 = Tidak.
24.	TSH (mIU/L)	Hormon tiroid stimulasi (Thyroid Stimulating Hormone)
25.	AMH (ng/mL)	Anti-Mullerian Hormone, penanda cadangan ovarium.
26.	PRL (ng/mL)	Prolaktin, hormon yang dapat memengaruhi menstruasi dan ovulasi.
27.	Vit D3 (ng/mL)	Kadar vitamin D3 dalam tubuh.
28.	PRG (ng/mL)	Progesteron, hormon penting dalam siklus menstruasi dan kehamilan.
29.	RBS (mg/dl)	Gula darah sewaktu (Random Blood Sugar).
30.	Weight gain(Y/N)	Apakah pasien mengalami kenaikan berat badan: 1 = Ya, 0 = Tidak.
31.	hair growth(Y/N)	Tumbuhnya rambut berlebih (hirsutisme): 1 = Ya, 0 = Tidak.
32.	Skin darkening (Y/N)	Penggelapan kulit (acanthosis nigricans): 1 = Ya, 0 = Tidak.
33.	Hair loss(Y/N)	Kerontokan rambut: 1 = Ya, 0 = Tidak.
34.	Pimples(Y/N)	Jerawat: 1 = Ya, 0 = Tidak.
35.	Fast food (Y/N)	Konsumsi makanan cepat saji: 1 = Ya, 0 = Tidak.
36.	Reg.Exercise(Y/N)	Olahraga rutin: 1 = Ya, 0 = Tidak.
37.	BP _Systolic (mmHg)	Tekanan darah sistolik (angka atas).
38.	BP_Diastolic (mmHg)	Tekanan darah diastolik (angka bawah).
39.	Follicle No. (L)	Jumlah folikel di ovarium kiri.

No.	Nama Fitur	Deskripsi
40.	Follicle No. (R)	Jumlah folikel di ovarium kanan.
41.	Avg. F size (L) (mm)	Ukuran rata-rata folikel di ovarium kiri.
42.	Avg. F size (R) (mm)	Ukuran rata-rata folikel di ovarium kanan.
43.	Endometrium (mm)	Ketebalan endometrium (lapisan rahim).
44.	Unnamed: 44	Kolom kosong/tidak digunakan. Akan dihapus pada preprocessing.

Eksplorasi data dilakukan pada tahapan ini, dilakukan dengan cara memvisualisasikan data guna memperoleh informasi awal mengenai distribusi data, dan memahami hubungan antar fitur. Hasil eksplorasi ini menjadi dasar dalam menentukan strategi pemilihan fitur-fitur yang relevan dan interpretasi lebih lanjut. Berikut fitur-fitur yang akan divisualisasikan untuk mendeteksi pola dan mendapatkan informasi mengenai data ditampilkan pada Tabel 3.3.

Tabel 3. 3 Visualisasi Data

Fitur	Jenis Visualisasi	Tujuan
Fitur-fitur numerik	Heatmap Correlation	Mengidentifikasi korelasi antar fitur untuk mendukung pemilihan fitur yang relevan dan mengidentifikasi hubungan antara fitur-fitur dengan label PCOS (Y/N)
10 Fitur numerik dengan korelasi tertinggi	Heatmap Detail	Memperjelas fitur mana yang paling berhubungan dengan diagnosis PCOS.

<b>Fitur</b>	<b>Jenis Visualisasi</b>	<b>Tujuan</b>
terhadap label.		
PCOS (Y/N)	Barchart	Melihat distribusi label target dan mendeteksi keseimbangan kelas.
Age (yrs)	Histogram	Mengamati distribusi usia pasien, sebagian besar berada pada rentang usia produktif.
BMI	Boxplot	Menilai persebaran BMI, pasien PCOS cenderung memiliki indeks BMI yang tinggi.
FSH dan LH	Boxplot	Memeriksa rasio hormon yang dapat mempengaruhi diagnosis PCOS.
Follicle No. (L & R), AMH	Boxplot dan histogram	Menjelajahi indikator fisiologis ovarium yang berkaitan dengan gejala PCOS.
Age (yrs) vs Cycle length	Scatterplot	Menganalisis hubungan usia dengan panjang siklus menstruasi pada penderita PCOS dan normal.
Age (yrs) vs BMI	Scatterplot	Melihat pola kenaikan BMI pada usia antara wanita PCOS dan tidak.

### 3.5.3 Model Training

Random Forest adalah algoritma ensambel yang berbasis decision tree, model ini digunakan sebagai salah satu model pembanding dalam penelitian ini. Model ini dilatih dengan menggunakan teknik *cross validation* untuk memastikan generalisasi model yang baik, dilakukan juga *tuning* hyperparameter menggunakan GridSearchCV agar performa optimal

dapat dicapai. Berikut tabel konfigurasi yang digunakan untuk *cross-validation* dan GridSearchCV pada model Random Forest ditunjukkan pada Tabel 3.4.

Tabel 3. 4 Konfigurasi GridSearchCV dan Cross Validation pada Random Forest

Parameter	Nilai yang dicoba	Keterangan
n_estimators	[100, 200, 300]	Jumlah pohon dalam hutan.
max_depth	[None, 5, 10, 20]	Kedalaman maksimum pohon.
min_samples_split	[2, 5, 10]	Jumlah minimum sampel untuk split internal.
min_samples_leaf	[1, 2, 4]	Jumlah minimum sampel pada daun.
max_features	['sqrt', 'log2']	Metode pemilihan pada daun
cv	5	Jumlah <i>fold</i> pada cross-validation
scoring	'f1'	Metrik utama untuk memilih parameter terbaik.

Nilai  $k=5$  pada teknik *k-fold cross-validation* digunakan secara konsisten pada GridSearchCV. Selain itu, metrik ‘f1’ dipilih sebagai ‘scoring’ karena sifat dataset PCOS yang imbalanced, f1 dianggap lebih representatif dibandingkan dengan akurasi.

XGBoost adalah algoritma *gradient boosting* yang dikenal unggul dalam tugas klasifikasi, terutama pada dataset dengan struktur dan kompleksitas tinggi. Sama halnya dengan Random Forest, model ini dilatih

dengan *cross validation* dan dilakukan hyperparameter *tuning* dengan GridSearchCV untuk mengoptimalkan performa model. Berikut tabel konfigurasi yang digunakan untuk GridSearchCV dan *cross-validation* yang diaplikasikan untuk model XGBoost disajikan pada Tabel 3.5.

Tabel 3. 5 Konfigurasi GridSearchCV dan Cross Validation pada XGBoost

Parameter	Nilai yang dicoba	Keterangan
n_estimators	[100, 200, 300]	Jumlah pohon dalam hutan.
max_depth	[3, 5, 7]	Kedalaman maksimum pohon.
learning_rate	[0.01, 0.1, 0.2]	Kecepatan model dalam mempelajari data baru.
subsample	[0.8, 1.0]	Proporsi sampel yang digunakan untuk setiap pohon.
colsample_bytree	[0.8, 1.0]	Proposisi fitur yang digunakan untuk setiap pohon.
gamma	[0, 1, 5]	Minimum <i>loss reduction</i> untuk membuat split baru.
cv	5	Jumlah <i>fold</i> pada <i>cross-validation</i>
scoring	'f1'	Metrik utama untuk menilai parameter terbaik.

Metrik 'f1' dalam GridSearchCV dipilih karena menyesuaikan kondisi data yang tidak seimbang. Untuk menghindari *overfitting*, parameter subsample dan colsample\_bytree dikombinasikan. Untuk mengontrol kompleksitas pohon dan regularisasi model, nilai gamma digunakan.

Nilai  $k=5$  pada  $k$ -fold cross-validation tidak bersifat mutlak, nilai yang umum digunakan, biasanya  $k = 5$  atau  $k = 10$ . Pemilihan nilai  $k = 5$  juga didukung oleh penelitian Marcot dan Hanea (2021) yang mengemukakan bahwa nilai  $k = 5$  dinilai cukup untuk menghasilkan validasi yang stabil serta efisien untuk dataset yang berskala sedang ( $\pm 1000$ -5000 sampel). Mereka juga mengemukakan bahwa apabila akurasi meningkat dengan nilai  $k$  yang lebih besar, maka waktu komputasinya juga meningkat signifikan. Berdasarkan temuan tersebut, pemilihan  $k = 5$  pada penelitian ini cocok karena menggunakan dataset yang berukuran sedang ( $\pm 1000$ -5000 sampel). Selain itu, pemilihan  $k = 5$  pada memungkinkan hasil yang optimal dari segi akurasi, dan efisiensi komputasi.

Salah satu tantangan utama pada penelitian ini adalah dataset dengan kelas yang tidak seimbang. Apabila tidak ditangani secara tepat, akan mengakibatkan hasil diagnosis yang bias terhadap kelas mayoritas dan cenderung mengabaikan kelas minoritas. Untuk mengatasi masalah ini, dilakukan teknik penyeimbangan data seperti SMOTE (*Synthetics Minority Over-sampling Technique*). Proses ini bertujuan agar model mampu belajar secara adil dari semua kelas sehingga menghasilkan prediksi yang lebih akurat dan tidak bias. SMOTE bekerja dengan cara menyintesis data pada kelas minoritas berdasarkan kemiripan dengan data yang sudah ada. Pada penelitian ini, SNOTE diaplikasikan pada tahapan pelatihan data untuk menghindari kebocoran data ke dalam proses validasi dan pengujian.

Hasil prediksi dari kedua model ini tidak hanya akan dibandingkan berdasarkan metrik evaluasi, melainkan dilihat dari sisi interpretabilitas dengan menggunakan analisis SHAP, hal ini bertujuan untuk menentukan model terbaik yang tidak hanya akurat namun juga dapat memberikan informasi yang jelas dari diagnosis yang dihasilkan oleh model.

#### **3.4.4 Model Evaluation**

Setelah model dilatih, model akan dievaluasi untuk menilai kemampuan model dalam melakukan klasifikasi. Evaluasi model dalam penelitian ini menggunakan beberapa metrik evaluasi yang biasa digunakan dalam tugas klasifikasi, yaitu akurasi, *precision*, *recall*, dan *f1-score*. Metrik-metrik ini dihitung berdasarkan nilai dari confusion matrix, yang merupakan matriks perbandingan antara prediksi model dengan label sebenarnya. Tabel 3.6 menampilkan metrik-metrik evaluasi yang digunakan untuk penelitian ini.

Tabel 3. 6 Metrik Evaluasi Prediksi PCOS

<b>Metrik</b>	<b>Rumus</b>	<b>Keterangan dalam Konteks PCOS</b>
Akurasi	$\frac{(TP + TN)}{(TP + TN + FP + FN)}$	Seberapa sering model membuat prediksi yang benar terhadap seluruh data.

Metrik	Rumus	Keterangan dalam Konteks PCOS
Precision	$\frac{TP}{(TP + FP)}$	Dari seluruh pasien yang benar-benar PCOS, berapa yang benar-benar PCOS.
Recall	$\frac{TP}{(TP + FN)}$	Seberapa baik model menangkap semua pasien yang benar-benar PCOS.
F1-Score	$2 * \frac{(Precision * Recall)}{(Precision + Recall)}$	Rata-rata harmonis dari <i>precision</i> dan <i>recall</i> , cocok untuk data dengan ketidakseimbangan kelas.

Metrik *recall* dan *precision* dalam konteks diagnosis PCOS ini cukup penting. Recall digunakan untuk menghindari kondisi pasien yang sebenarnya PCOS tidak terdeteksi oleh model atau biasa disebut *false negatif*. Sedangkan, *precision* digunakan untuk mengurangi *false positif* yang menyebabkan over diagnosis. Sehingga metrik F1-score digunakan untuk menyeimbangkan *recall* dan *precision*.

### 3.4.5 Interpretation

Setelah model melewati proses evaluasi, proses interpretasi dilakukan dengan menggunakan SHAP untuk mengetahui kontribusi setiap fitur terhadap prediksi model. Kedua model, yaitu Random Forest dan XGBoost, dianalisis menggunakan SHAP untuk dibandingkan tidak hanya

dari sisi performa dalam mendiagnosis PCOS, tetapi juga dari sisi transparansi dan pemahaman terhadap faktor-faktor yang memengaruhi keputusan model. Perbandingan ini bertujuan untuk melihat apakah kedua model memberikan interpretasi yang serupa terhadap fitur penting, atau justru menghasilkan wawasan yang berbeda. Langkah ini penting untuk membantu praktisi kesehatan memahami variabel-variabel utama yang berkontribusi terhadap diagnosis PCOS.

SHAP dipilih dalam penelitian ini karena memiliki dasar teori yang kuat, yaitu teori permainan kooperatif Shapley Values, yang memberikan kontribusi yang adil dari setiap fitur terhadap prediksi. SHAP menawarkan konsistensi dan stabilitas dalam interpretasi. Selain itu, SHAP mendukung berbagai jenis model machine learning dan menyediakan visualisasi yang intuitif, sehingga memudahkan pemahaman bagi praktisi non-teknis seperti tenaga medis.

Penelitian ini menghasilkan model klasifikasi yang mampu mendiagnosis dengan *output* berupa probabilitas prediksi antara 0 dan 1. Ambang batas sebesar 0.5 digunakan dalam mengklasifikasikan pasien sebagai PCOS atau tidak. Tabel 3.7 menampilkan ambang batas dalam klasifikasi model.

Tabel 3. 7 Ambang Batas Klasifikasi Model

Nilai Ambang	Keterangan	Interpretasi
--------------	------------	--------------

$\geq 0.5$	Probabilitas prediksi dari model.	Diklasifikasikan sebagai PCOS.
$< 0.5$	Probabilitas prediksi dari model.	Diklasifikasikan sebagai non-PCOS.

Fitur-fitur yang berkontribusi pada diagnosis PCOS yang dihasilkan oleh SHAP, dinilai sesuai dengan pertimbangan dasar klinis. Kriteria Rotterdam digunakan sebagai acuan yang biasa digunakan sebagai pedoman dalam diagnosis PCOS. Fitur-fitur pada dataset dibagai ke dalam dua kategori, yaitu fitur utama dan fitur pendukung. Fitur utama adalah fitur yang mewakili Kriteria Rotterdam. Sementara itu, fitur pendukung adalah fitur yang tidak termasuk kriteria Rotterdam, namun secara medis dianggap berkaitan dengan kondisi PCOS, baik secara gejala, maupun faktor risiko.

Tabel 3.8 menampilkan pemetaan fitur berdasarkan kriteria klinis.

Tabel 3. 8 Pemetaan Fitur Berdasarkan Kriteria Klinis

Kategori	Nama Fitur	Deskripsi Singkat
Fitur Utama	Cycle (R/I), Cycle length (days)	Siklus haid tidak teratur.
	Hair growth, Pimples, Hair loss	Gejala klinis hiperandrogenisme.
	LH, FSH, LH/FSH Ratio	Ketidakseimbangan hormon reproduksi.

Kategori	Nama Fitur	Deskripsi Singkat
	AMH, Follicle No. (L), Follicle No. (R)	Menunjukkan morfologi ovarium (PCOM).
Fitur Pendukung	BMI	Obesitas dan resistensi insulin.
	Skin darkening, RBS	Indikator metabolik atau resistensi insulin.
	Fast food, Reg.Exercise	Faktor gaya hidup yang mempengaruhi PCOS.
	PRL, PRG, Vit D3, TSH	Hormon lainnya yang berkaitan dengan kesehatan reproduksi.
	BP Systolic, BP Diastolic	Tekanan darah, komorbid terkait metabolismik.

Ambang batas klinis sangat penting untuk dipahami dalam proses interpretasi model, terutama untuk fitur utama dan fitur pendukung. Ambang batas ini berguna untuk menilai apakah suatu fitur pada pasien tertentu dapat dianggap mendukung diagnosis PCOS atau tidak. Tabel 3.9 menampilkan ambang batas klinis berdasarkan referensi medis dan kriteria Rotterdam.

Tabel 3. 9 Ambang Batas Klinis Berdasarkan Referensi Medis

<b>Fitur</b>	<b>Ambang Klinis</b>	<b>Interpretasi</b>	<b>Relevansi dengan PCOS</b>	<b>Sumber</b>
AMH (ng/mL)	> 4.5	Kadar AMH yang tinggi menandakan PCOM.	Mendukung diagnosis PCOS. Merupakan salah satu dari tiga kriteria utama PCOS (PCOM).	(Gorzko dkk., 2025), Kriteria Rotterdam
LH (mIU/mL)	> 10	LH tinggi mengindikasikan gangguan ovulasi.	Sering ditemukan pada pasien PCOS.	(Ghafari dkk., 2025)
FSH (mIU/mL)	> 5	FSH rendah mengindikasikan ketidakseimbangan hormon.	Mendukung PCOS apabila rasio LH/FSH tinggi.	(Ghafari dkk., 2025)
LH/FSH Ratio	> 2	Rasio yang tinggi menunjukkan hiperandrogenisme.	Ciri khas endokrin PCOS. Merupakan salah satu dari tiga kriteria utama PCOS (hiperandrogenisme).	Kriteria Rotterdam
BMI	> 30	BMI yang tinggi mengindikasikan obesitas atau resistensi insulin.	Faktor risiko dan pemicu gangguan ovulasi.	WHO
Cycle (R/I)	Irregular	Siklus yang tidak teratur menandakan oligo atau anovulasi.	Salah satu dari tiga kriteria utama PCOS (oligo/anovulasi).	Kriteria Rotterdam
Follicle No. (L)	≥ 20	Jumlah folikel berlebih.	Menandakan morfologi ovarium polikistik. Merupakan salah satu dari tiga kriteria utama PCOS.	(Gorzko dkk., 2025)
Follicle No. (R)	≥ 20	Jumlah folikel berlebih.	Menandakan morfologi ovarium polikistik. Merupakan salah satu dari tiga kriteria utama PCOS.	
Hair Growth (Y/N)	Yes	Hirsutisme.	Gejala hiperandrogenisme. Merupakan salah	(Baba, 2025)

			satu dari tiga kriteria utama PCOS.	
Pimples (Y/N)	Yes	Jerawat berat.	Gejala hiperandrogenisme. Merupakan salah satu dari tiga kriteria utama PCOS.	(Baba, 2025)
Skin darkening (Y/N)	Yes	Penggelapan kulit.	Sering terjadi pada pasien PCOS.	(Sudk., 2025)
RBS (mg/dl)	> 140	Glukosa darah acak tinggi.	Berhubungan dengan resistensi insulin.	WHO

Pemilihan fitur yang ditampilkan pada Tabel 3.8 didasarkan pada kriteria Rotterdam dan indikasi medis pendukung seperti obesitas dan resistensi insulin yang seringkali terjadi pada pengidap PCOS.

Pasien dinyatakan berisiko tinggi atau terdiagnosa PCOS jika memenuhi dua syarat utama, diantaranya adalah :

1. Hasil prediksi model menunjukkan probabilitas  $\leq 0.5$ , yang merupakan ambang klasifikasi biner untuk memutuskan apakah pasien tersebut termasuk kelas positif PCOS.
2. Hasil interpretasi model dengan SHAP menunjukkan bahwa fitur-fitur dominan dalam prediksi pasien tersebut memresentasikan setidaknya 2 atau 3 kriteria Rotterdam, yang dinyatakan sebagai fitur utama.

Apabila memenuhi dua syarat tersebut, maka model dinyatakan mampu memprediksi probabilitas pasien dan model selaras dengan pendekatan medis berdasarkan kriteria Rotterdam. Selain itu terdapat pembobotan probabilitas PCOS berdasarkan interpretasi fitur. Tabel 3.10 menampilkan interpretasi probabilitas berdasarkan kombinasi fitur.

Tabel 3. 10 Interpretasi Probabilitas PCOS Berdasarkan Kombinasi Fitur

<b>Fitur Utama</b>	<b>Fitur Pendukung</b>	<b>Estimasi Probabilitas</b>	<b>Kesimpulan</b>
Tiga dari tiga kriteria terpenuhi.	Satu atau lebih.	> 90%	Sangat kuat dan valid secara klinis dan model.
Tiga dari tiga kriteria terpenuhi.	Tidak ada.	85%-90%	Sangat kuat secara klinis, cukup dari sisi model.
Dua dari tiga kriteria terpenuhi.	Satu atau lebih.	70%-85%	Kuat dan valid secara klinis dan model.
Satu dari tiga kriteria terpenuhi.	Dua atau lebih.	55%-70%	Cukup mendukung, tapi masih memerlukan verifikasi klinis.
Satu dari tiga kriteria terpenuhi.	Tidak ada.	45%-60%	Lemah, hasil model belum meyakinkan secara klinis.
Tidak ada kriteria terpenuhi.	Dua atau lebih.	< 50%	Tidak cukup, kemungkinan bukan PCOS.

### 3.4.6 *Comparison*

Tahapan *comparison*, dilakukan perbandingan fitur-fitur hasil interpretasi, tahapan ini dilakukan untuk memilih model mana yang hasil interpretasinya sesuai dengan karakteristik klinis yang diketahui dari diagnosis manual.

Validasi dari fitur-fitur hasil interpretasi, dilakukan pada tahapan ini. Validasi dilakukan dengan cara membandingkan fitur-fitur hasil interpretasi dengan literatur medis dan jika memungkinkan dikonsultasikan juga dengan dokter obstetri dan ginekologi, untuk memastikan fitur-fitur hasil interpretasi sesuai dengan kajian ilmunya.

### 3.4.7 Conclusion

Tahapan *conclusion* merupakan tahapan akhir dari proses penerapan model prediksi. Tahapan ini dilakukan untuk memperoleh *insight* dari proses *interpretation* yang mengaplikasikan SHAP guna memperoleh fitur-fitur mana yang memberikan kontribusi dalam hasil diagnosis yang dilakukan model.

## 3.6 Evaluation

Evaluasi merupakan tahapan akhir dari penelitian ini. Tahapan ini mengevaluasi dari awal hingga akhir penelitian. Tahapan-tahapan penelitian yang telah dilakukan ditinjau kembali untuk mengidentifikasi kekuatan, kelebihan, dan metode apa yang efektif dalam rangka mencapai tujuan penelitian. Tahapan ini menjadi dasar dalam menarik kesimpulan dan saran

yang komprehensif dan mengukur seberapa efektif metode yang digunakan dalam mencapai tujuan penelitian. Tahapan evaluasi ini tidak hanya mengukur hasil, tetapi merefleksikan proses secara menyeluruh sebagai bahan evaluasi dan acuan untuk penelitian selanjutnya