

BAB 2

LANDASAN TEORI

Bab ini menjelaskan landasan teori yang menjadi dasar dalam pengembangan dan perancangan sistem pada penelitian ini. Pembahasan meliputi konsep umum, metode yang digunakan, serta teori pendukung lainnya yang relevan.

2.1 Kanker Payudara

Kanker payudara merupakan salah satu kanker yang paling sering dialami pada perempuan di seluruh dunia dan menjadi penyebab utama kematian pada tingkat global [11]. Kanker payudara berasal dari perkembangan sel abnormal pada jaringan payudara, terutama pada duktus laktiferus dan lobulus. Secara klinis, kanker payudara diklasifikasikan berdasarkan status reseptor hormon *estrogen* (ER), *progesteron* (PR), dan *human epidermal growth factor receptor 2* (HER2), yang menjadi indikasi penting dalam menentukan strategi terapi dan prognosis klinis pasien [12].

2.1.1 Karakteristik Klinis dan Patologis Kanker Payudara

Karakteristik klinis dan patologis merupakan faktor penting dalam menentukan diagnosa, perencanaan terapi, serta evaluasi prognosis pada pasien kanker payudara [13]. Kanker payudara dapat diidentifikasi oleh adanya massa atau benjolan pada payudara, perubahan ukuran atau bentuk payudara, retraksi puting, serta perubahan pada kulit seperti eritema atau penebalan. Pemeriksaan pencitraan medis termasuk *Magnetic Resonance Imaging* (MRI), memiliki peran penting dalam deteksi dan evaluasi karakteristik tumor secara lebih detail. Hal ini dikarenakan data klinis kanker payudara dapat bervariasi antar pasien dan sering kali tidak menunjukkan gejala pada tahap awal [14].

Secara patologis, kanker payudara diklasifikasikan berdasarkan tipe histologis dan derajat keganasan (*tumor grade*), yang menunjukkan tingkat diferensiasi sel tumor [15]. Tipe histologis kanker payudara yang paling umum adalah *invasive ductal carcinoma* dan *invasive lobular carcinoma* [16]. Kombinasi karakteristik klinis dan patologis sangat berpengaruh terhadap respons terapi, risiko kekambuhan serta prognosis jangka panjang pasien [17].


Pendekatan radiomik dan *machine learning* kini semakin sering digunakan karena mampu menangkap karakteristik biologis tumor melalui pola intensitas, tekstur, dan bentuk yang tampak pada citra MRI secara non-invasif [18].

2.1.2 Kekambuhan Kanker Payudara (Breast Cancer Recurrence)

Kekambuhan kanker payudara menandakan munculnya kembali keganasan setelah pasien menjalani terapi dan berada dalam kondisi remisi. Kekambuhan dapat berupa *local recurrence*, *regional recurrence*, atau *distant metastasis* tergantung pada lokasi dimana sel kanker ditemukan kembali [19]. Risiko terjadinya kekambuhan dipengaruhi oleh berbagai faktor klinis dan patologis, seperti status kelenjar getah bening, ukuran tumor, serta respons terhadap terapi sistemik maupun lokal [20]. Indikator yang sering digunakan dalam penelitian prognostik adalah *recurrence-free survival* (RFS) atau *disease-free survival* (DFS), yaitu rentang waktu dari diagnosis atau akhir terapi hingga kekambuhan terjadi atau kematian akibat penyakit [21].

2.1.3 Perbandingan Payudara Normal dan Lesi Kanker pada Citra MRI

Struktur payudara normal pada citra MRI terdiri atas jaringan lemak, jaringan fibroglandular, serta sistem dukturs yang tidak menunjukkan adanya massa fokal maupun peningkatan kontras abnormal. Pada sekuens *T1-weighted* dan *T2-weighted*, jaringan lemak tampak hiperintens, sedangkan jaringan fibroglandular memiliki intensitas intermediate yang cenderung merata tanpa distorsi arsitektur jaringan [22]. Sebaliknya, lesi kanker payudara memperlihatkan karakteristik yang tidak sama pada berbagai sekuens MRI, khususnya pada *Dynamic Contrast-Enhanced* (DCE) MRI [23]. Selain itu, pada *Diffusion-Weighted Imaging* (DWI), nilai *Apparent Diffusion Coefficient* (ADC) pada lesi ganas cenderung lebih rendah dibandingkan jaringan normal akibat densitas seluler yang tinggi membatasi difusi air [24].



Gambar 2.1. Perbandingan jaringan payudara normal dan lesi kanker pada sekuens DCE-MRI, *T1-weighted*, *T2-weighted*, dan ADC map

Perbedaan visual antara jaringan payudara normal dan lesi kanker pada berbagai sekuens MRI, termasuk pola *enhancement*, intensitas sinyal, dan heterogenitas tekstur, ditunjukkan pada Gambar 2.1 [25].

2.2 Rekayasa Fitur Radiomik

Rekayasa fitur radiomik merupakan proses penting dalam analisis citra medis yang bertujuan untuk mentransformasikan informasi visual pada citra MRI menjadi fitur kuantitatif. Melalui proses ini, karakteristik tumor seperti distribusi intensitas sinyal, tekstur, dan bentuk dari tumor dapat direpresentasikan secara objektif [26]. Tahap ini terdiri dari dua langkah utama, yaitu ekstraksi fitur dari area tumor yang telah disegmentasi dan seleksi fitur untuk memilih subset fitur yang paling relevan terhadap proses prediksi klinis.

2.2.1 Ekstraksi Fitur Radiomik

Ekstraksi fitur radiomik berfungsi untuk mendapatkan representasi kuantitatif dari citra MRI yang mampu menggambarkan karakteristik internal tumor secara objektif

[27]. Fitur orde pertama (*first-order*) digunakan untuk menganalisis distribusi intensitas voxel dalam *Region of Interest* (ROI), seperti nilai rata - rata, varians, dan entropi intensitas [28]. Sementara itu, fitur bentuk (*shape*) merepresentasikan karakteristik geometris tumor dalam tiga dimensi, termasuk ukuran, volume, serta kompleksitas dan heterogenitas batas tumor, yang berhubungan dengan pola pertumbuhan lesi [29]. Selain fitur tersebut, fitur tekstur seperti *Gray Level Co-occurrence Matrix* (GLCM), *Gray Level Run Length Matrix* (GLRLM), dan *Gray Level Size Zone Matrix* (GLSZM) digunakan untuk memperoleh heterogenitas intratumoral yang sering dikaitkan dengan agresivitas biologis tumor [30].

Proses ekstraksi fitur radiomik umumnya dilakukan menggunakan perangkat lunak terstandarisasi seperti *PyRadiomics*. Berbagai penelitian melaporkan bahwa fitur radiomik yang diekstraksi dari citra MRI, khususnya fitur tekstur dan bentuk, memiliki nilai prognostik yang dapat digunakan dalam memprediksi respons terapi serta risiko kekambuhan pada pasien kanker payudara [31].

2.2.2 Seleksi Fitur

Seleksi fitur merupakan tahapan penting dalam analisis radiomik karena bertujuan untuk mengidentifikasi fitur - fitur yang paling relevan dari sekumpulan besar fitur kuantitatif yang diekstraksi dari citra medis [32]. Jumlah fitur radiomik yang berdimensi tinggi berpotensi menimbulkan reduksi informasi serta meningkatkan risiko *overfitting*, terutama ketika jumlah sampel relatif terbatas. Oleh karena itu, seleksi fitur diperlukan untuk menyederhanakan representasi data tanpa menghilangkan informasi penting yang berkaitan dengan karakteristik biologis tumor [33].

Salah satu pendekatan yang umum digunakan dalam seleksi fitur adalah metode berbasis regularisasi, seperti *Least Absolute Shrinkage and Selection Operator* (LASSO). LASSO bertujuan untuk menekan kontribusi fitur yang kurang informatif dan mempertahankan fitur yang memiliki hubungan lebih kuat dengan variabel target [34].

2.3 Metode Klasifikasi

Metode klasifikasi digunakan untuk menentukan label klinis berdasarkan fitur radiomik yang telah melalui proses ekstraksi dan seleksi. Dalam prediksi kekambuhan kanker payudara, pemilihan metode klasifikasi yang tepat sangat

penting karena secara langsung memengaruhi akurasi, sensitivitas, dan kemampuan generalisasi model terhadap data baru. Dataset medis umumnya memiliki jumlah sampel yang terbatas serta dimensi fitur yang tinggi, sehingga membutuhkan algoritma yang mampu menangani kompleksitas tersebut secara efektif [35]. Oleh karena itu, *Support Vector Machine* (SVM) sering digunakan dalam penelitian radiomik karena kestabilan performanya dan kemampuannya dalam memisahkan kelas secara optimal terhadap data berdimensi tinggi [36].

2.3.1 *Support Vector Machine* (SVM)

Support Vector Machine (SVM) merupakan algoritma klasifikasi yang digunakan untuk mencari hyperplane optimal untuk memisahkan dua kelas dengan memaksimalkan margin pemisah antara dua kelas. Secara matematis, hyperplane pemisah pada SVM dapat didefinisikan dengan persamaan:

$$w^T x + b = 0 \quad (2.1)$$

dimana w merupakan vektor bobot yang menentukan orientasi hyperplane, x adalah vektor fitur masukan, dan b adalah bias. Pendekatan berbasis margin ini membuat SVM sesuai untuk data radiomik yang memiliki jumlah fitur besar dibandingkan jumlah sampel pasien [36].

Pada kasus di mana data tidak dapat dipisahkan secara linear, SVM memanfaatkan fungsi kernel untuk memproyeksikan data ke ruang fitur dengan dimensi yang lebih tinggi sehingga batas antar kelas menjadi lebih jelas. Salah satu kernel yang paling sering digunakan dalam analisis radiomik adalah *Radial Basis Function* (RBF), yang efektif dalam menangkap hubungan non-linear antar fitur [37]. Kernel RBF dapat dirumuskan sebagai:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (2.2)$$