

BAB 1

PENDAHULUAN

1.1 Latar Belakang Masalah

Kanker ginjal merupakan salah satu keganasan urologi dengan insidensi yang terus meningkat secara global, dengan lebih dari 400.000 kasus baru setiap tahun dan angka mortalitas yang masih signifikan [1, 2]. Karsinoma Sel Ginjal (*Renal Cell Carcinoma/RCC*) mencakup sekitar 90% dari seluruh kanker ginjal dan terdiri dari beberapa subtype utama, termasuk *Clear Cell RCC* (ccRCC), *Papillary RCC* (pRCC), dan *Chromophobe RCC* (chRCC), yang memiliki karakteristik biologis dan respons terapi yang berbeda. Di antara subtype tersebut, pRCC menyumbang sekitar 10–20% kasus RCC dan menunjukkan tren peningkatan insidensi, yang sebagian besar dipengaruhi oleh meningkatnya penggunaan pencitraan non-invasif seperti CT [1, 3]. Namun, pRCC merupakan salah satu subtype yang paling menantang untuk diidentifikasi secara radiologis. antangan klinis terbesar dalam mendiagnosis pRCC adalah sifatnya yang hipovaskular dan homogen pada CT scan, sehingga secara visual sangat menyerupai lesi jinak seperti *Oncocytoma* maupun keganasan ambigu lain seperti *Chromophobe RCC* [4, 5].

Ambiguitas visual ini sering memicu *misdiagnosis* yang berdampak fatal pada kesalahan penanganan medis pasien, sementara pendekatan diagnostik pencitraan multimodal konvensional sering kali terbentur oleh keterbatasan biaya dan prosedur klinis [6, 7]. Sebagai solusi non-invasif, radiomik memungkinkan ekstraksi ratusan fitur tekstur kuantitatif yang mencakup statistik dasar tingkat pertama hingga transformasi matematis *high-order* seperti *Wavelet* dan *Laplacian of Gaussian* guna mengungkap heterogenitas tumor yang tidak kasat mata [8–11]. Namun, penggunaan ekstraksi fitur *high-order* memicu masalah dimensionalitas tinggi ($p \gg n$) dan multikolinearitas yang ekstrem [12, 13]. Ketika dihadapkan pada dataset medis dengan sampel terbatas, kondisi ini rentan menyebabkan *overfitting*, sehingga reduksi dimensi melalui metode *feature selection* menjadi langkah wajib untuk mengisolasi biomarker yang paling diskriminatif dan stabil secara komputasi [14–16].

Untuk mengatasi kompleksitas dimensi tersebut, metode *shallow learning* seperti *Random Forest* (RF), XGBoost, dan *Logistic Regression* (LR) sangat direkomendasikan karena memiliki mekanisme *bagging* dan regularisasi internal

yang tangguh dalam mencegah hafalan pola (*overfitting*) pada data kecil [17-19]. Guna semakin meningkatkan kemampuan generalisasi, penelitian ini mengusulkan arsitektur *stacked ensemble* secara spesifik dengan mengombinasikan RF dan LR. XGBoost secara sengaja dieksklusi dari arsitektur gabungan untuk mencegah penumpukan redundansi dari sesama model *tree-based* serta menghindari beban komputasi (*computational cost*) yang berlebihan [20, 21]. Sebaliknya, integrasi model heterogen dalam *stacking* ini yaitu pendekatan non-linear RF yang dievaluasi ulang oleh *meta-learner* linear parametrik LR terbukti jauh lebih efisien secara komputasi (memiliki *space-time complexity* yang rendah), namun tetap mampu menghasilkan keragaman (*diversity*) prediksi untuk meminimalkan misdiagnosis pRCC secara signifikan [22-24].

Oleh karena itu, diperlukan eksplorasi pendekatan *machine learning* yang mampu menangani karakteristik data berdimensi tinggi serta hubungan non-linear antar fitur secara lebih efektif [21]. Dalam konteks ini, metode *shallow learning* seperti *Random Forest*, XGBoost, dan *Logistic Regression* telah banyak digunakan karena kemampuannya dalam menangani data dengan ukuran terbatas melalui mekanisme *bagging* dan regularisasi internal yang kuat terhadap dimensi data yang tinggi [14]. Di sisi lain, pendekatan berbasis *ensemble*, seperti *stacked ensemble*, menawarkan mekanisme penggabungan beberapa model untuk menangkap pola data dari berbagai perspektif. Secara spesifik, arsitektur gabungan dalam penelitian ini dengan sengaja mengeksklusi XGBoost untuk mencegah penumpukan kompleksitas dari dua algoritma yang sama-sama berbasis pohon (*tree-based*). Menggabungkan dua algoritma yang memiliki sifat komputasi serupa pada dataset berukuran kecil berisiko memicu *overfitting* yang ekstrem serta hanya akan memberikan informasi probabilitas yang redundan bagi *meta-learner* [19]. Sebaliknya, kombinasi model yang heterogen (seperti pendekatan non-linear pada RF dan linear parametrik pada LR) terbukti lebih optimal dalam arsitektur *stacking* karena menghasilkan keragaman (*diversity*) prediksi yang saling melengkapi kelemahan masing-masing algoritma dasar [20, 21]. Namun demikian, efektivitas pendekatan *stacking* heterogen dalam konteks klasifikasi pRCC berbasis radiomik, khususnya dibandingkan dengan model *shallow learning* tunggal yang berdiri sendiri, masih belum sepenuhnya dipahami dan memerlukan evaluasi lebih lanjut.

Berdasarkan hal tersebut, penelitian ini bertujuan untuk membandingkan performa pendekatan *shallow learning* dan *stacked ensemble* dalam klasifikasi biner antara pRCC dan non-pRCC, serta menganalisis kontribusi fitur *high-order*

terhadap kemampuan diskriminatif model. Diharapkan, hasil penelitian ini dapat memberikan pemahaman yang lebih komprehensif terkait efektivitas masing-masing pendekatan serta mendukung pengembangan sistem klasifikasi yang lebih robust dan aplikatif dalam konteks klinis.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, rumusan masalah dalam penelitian ini adalah:

1. Sejauh mana kontribusi fitur radiomik *high-order* terhadap peningkatan performa klasifikasi biner subtype pRCC dibandingkan fitur radiomik konvensional?
2. Bagaimana pengaruh kombinasi antara metode reduksi dimensi (*feature selection*) dan tingkat kompleksitas arsitektur algoritma (*shallow learning* tunggal vs. *stacked ensemble*) terhadap stabilitas dan performa klasifikasi pRCC?

1.3 Batasan Permasalahan

1. Data yang digunakan terbatas pada citra CT *multiphasic* pasien dengan diagnosis histopatologis subtype RCC, di mana analisis dilakukan pada *region of interest* (ROI) yang telah disegmentasi sebelumnya.
2. Fitur yang dievaluasi mencakup fitur radiomik konvensional dan *high-order*, tanpa menggunakan pendekatan ekstraksi fitur berbasis *deep learning*.
3. Fokus utama penelitian adalah klasifikasi biner untuk membedakan pRCC dari non-pRCC menggunakan model *shallow learning* tunggal dan pendekatan *stacked ensemble*.
4. Evaluasi performa model dibatasi pada penggunaan metrik klasifikasi biner (*accuracy, precision, recall, F1-score*, dan AUC).
5. Validasi kemampuan generalisasi model dilakukan melalui teknik *nested cross-validation* pada dataset yang tersedia, tanpa melibatkan pengujian pada dataset eksternal atau validasi klinis prospektif.

1.4 Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini adalah:

1. Menganalisis kontribusi fitur radiomik *high-order* terhadap peningkatan performa klasifikasi biner pRCC dibandingkan fitur radiomik konvensional.
2. Mengevaluasi pengaruh kombinasi antara metode reduksi dimensi (*feature selection*) dengan tingkat kompleksitas arsitektur algoritma (*shallow learning* tunggal vs *stacked ensemble*) terhadap stabilitas dan kemampuan generalisasi model pada klasifikasi biner pRCC.

1.5 Manfaat Penelitian

Penelitian ini diharapkan memberikan manfaat sebagai berikut:

1. Memberikan wawasan ilmiah mengenai peran fitur radiomik *high-order* dan keunggulan metode *ensemble* dalam meningkatkan akurasi identifikasi subtipe RCC pada citra medis.
2. Manfaat Metodologis: Menyediakan kerangka kerja (*pipeline*) pengolahan data radiomik melalui teknik reduksi dimensi yang efisien dan stabil secara komputasi sebagai referensi bagi penelitian selanjutnya.
3. Manfaat Praktis: Menjadi dasar pengembangan alat bantu diagnosis digital bagi radiolog untuk mengidentifikasi subtipe tumor secara objektif dan non-invasif guna meminimalkan risiko kesalahan diagnosis.

1.6 Sistematika Penulisan

Sistematika penulisan laporan adalah sebagai berikut:

1. Bab 1 - PENDAHULUAN
Bab ini berisi latar belakang penelitian, rumusan masalah, tujuan penelitian, manfaat penelitian, batasan masalah, dan sistematika penulisan.
2. Bab 2 - LANDASAN TEORI
Bab ini membahas teori-teori dan konsep dasar yang mendukung penelitian mengenai klasifikasi multi-kelas subtipe *Renal Cell Carcinoma* (RCC) berbasis radiomik dan *machine learning*.

3. Bab 3 - METODOLOGI PENELITIAN

Bab ini membahas metodologi penelitian yang digunakan, mulai dari pengumpulan data, tahapan *preprocessing*, *feature extraction*, *feature selection*, serta metode atau algoritma yang diterapkan dalam proses analisis.

4. Bab 4 - HASIL DAN DISKUSI

Bab ini menyajikan evaluasi model, perbandingan performa, serta pembahasan terhadap temuan yang diperoleh berdasarkan metode yang telah diterapkan.

5. Bab 5 - SIMPULAN DAN SARAN

Bab ini berisi kesimpulan dari seluruh hasil penelitian yang telah dilakukan, serta memberikan saran atau rekomendasi untuk pengembangan penelitian selanjutnya.

