

BAB 5

PEMBAHASAN DAN PENDAPAT

5.1. Tahap I – Pengembangan Sistem Prediksi Dosis Radiasi

Pada Tahap I, penelitian difokuskan pada pengembangan sistem prediksi dosis radiasi berbasis citra film Gafchromic HD-V2 menggunakan algoritma *machine learning*. Hasil yang diperoleh pada Bab 4 menunjukkan bahwa baik regresi linier maupun *random forest* mampu memodelkan hubungan antara fitur citra dengan dosis radiasi, meskipun dengan tingkat akurasi yang berbeda. Bagian ini membahas lebih lanjut mengenai validasi konsep, analisis perbandingan model, fenomena pergeseran domain, serta interpretabilitas fitur penting yang berkontribusi terhadap performa model.

5.1.1. Validasi Konsep Dosimetri Berbasis Citra *Scanner*


Hasil penelitian menunjukkan bahwa sistem prediksi dosis berbasis *machine learning* menggunakan citra *scanner* memiliki kelayakan teknis yang tinggi. Kinerja pelatihan model dengan $R^2 > 0,99$ untuk kedua algoritma (**Tabel 4.3** dan **4.6**) mengkonfirmasi bahwa informasi dosis radiasi dapat diekstrak secara efektif dari karakteristik visual film Gafchromic HD-V2. Temuan ini sejalan dengan penelitian Palmer *et al.* (2023) yang menunjukkan potensi *machine learning* dalam dosimetri film radiokromik, meskipun dengan fokus aplikasi yang berbeda.

Keberhasilan ekstraksi 41 fitur dari citra *scanner* dan kemampuan model dalam mengenali pola perubahan warna yang berkorelasi dengan dosis radiasi memberikan validasi empiris terhadap prinsip dasar dosimetri film radiokromik. Seperti yang dijelaskan oleh Devic & Lewis (2023), film radiokromik mengalami polimerisasi yang proporsional dengan dosis radiasi, dan penelitian ini membuktikan bahwa perubahan mikroskopis tersebut dapat dikuantifikasi melalui analisis citra digital menggunakan *scanner* konvensional.

5.1.2. Analisis Multi-Parameter (*Random Forest* vs *Regresi Linier*)

Analisis perbandingan model (**Tabel 4.21**) menunjukkan bahwa *random forest* secara statistik signifikan lebih akurat dibandingkan regresi linier ($p < 0,05$). Superioritas ini dapat dijelaskan melalui kemampuan *random forest* dalam menangani kompleksitas hubungan *non-linear* antar fitur, sebagaimana dikemukakan oleh Vedelago *et al.* (2022) dalam konteks biodosimetri radiasi.

Identifikasi fitur g_b_diff dan g_b_ratio sebagai diskriminator terkuat oleh *random forest* (**Tabel 4.8**) memberikan wawasan penting tentang mekanisme respons film terhadap radiasi. **Gambar 5.2** memperlihatkan urutan kepentingan fitur tersebut, di mana fitur turunan antar kanal warna lebih dominan dibandingkan nilai absolut kanal tunggal. Hal ini konsisten dengan karakteristik spektral film Gafchromic yang memiliki absorbansi utama pada spektrum hijau-biru (Ghorbani et al., 2012). Kemampuan algoritma untuk secara otomatis mengidentifikasi fitur yang relevan secara fisik tanpa pengetahuan awal yang eksplisit menunjukkan kekuatan pendekatan Machine Learning dalam mengekstraksi informasi dari data dosimetri.



Gambar 5.1 Fitur Penting *Random Forest*

5.1.3 Fenomena Pergeseran Domain dan Implikasinya

A. Karakteristik dan Besaran Domain Shift

Fenomena pergeseran domain yang diamati dalam penelitian ini (**Tabel 4.9**) merupakan temuan yang signifikan dalam konteks aplikasi *machine learning* untuk dosimetri. Variabilitas ekstrem pada model regresi linier, dengan *offset* latar belakang berubah dari -437,96 Gy pada 17 April menjadi -0,48 Gy pada 3 Juli, menunjukkan sensitivitas tinggi terhadap perubahan kondisi pengukuran.

Besaran pergeseran ini jauh melebihi variabilitas yang umumnya diterima dalam dosimetri konvensional. Sebagai perbandingan, spektrofotometer hanya mengalami perubahan R^2 sebesar -1,27% antar periode (**Tabel 4.12**), yang masih dalam batas toleransi standar internasional dosimetri (ISO/ASTM 51707:2023). Perbedaan ini mengindikasikan bahwa metode *machine learning* berbasis citra lebih rentan terhadap variabilitas sistematis dibandingkan metode konvensional.

B. Analisis Penyebab dan Mekanisme

Berdasarkan analisis dalam Bagian 4.8, perbedaan protokol pengukuran antara spektrofotometer dan sistem *machine learning* menjadi faktor utama penyebab *domain shift*. Spektrofotometer menggunakan protokol pra-pasca pengukuran pada area film yang identik, sedangkan sistem *machine learning* menggunakan baseline dari potongan film yang berbeda. Hal ini sejalan dengan rekomendasi Taylor *et al.* (2016) yang menekankan pentingnya konsistensi area pengukuran dalam dosimetri film.

Sifat tidak homogen film yang dikemukakan oleh Massillon-JL *et al.* (2021) sebagai karakteristik inherent film Gafchromic dapat memperkuat efek *domain shift* ketika dikombinasikan dengan variabilitas posisi *scanning*. Penelitian lebih lanjut diperlukan untuk mengembangkan protokol standardisasi yang dapat meminimalkan sumber variabilitas ini, mengikuti pendekatan yang diusulkan oleh Sorriaux *et al.* (2016) untuk dosimetri film menggunakan *scanner*.

5.1.4 Interpretabilitas Model dan Fitur Penting

Analisis kepentingan fitur pada *random forest* menunjukkan bahwa fitur turunan seperti *g_b_diff* (9,85%) dan *uniformity_g* (9,81%) lebih informatif dibandingkan nilai absolut kanal tunggal. Hal ini menegaskan pentingnya analisis multi-kanal dan distribusi spasial warna dalam prediksi dosis. Konsistensi pemilihan fitur antar periode pengukuran juga memperkuat bahwa model tidak sekadar menangkap noise, tetapi benar-benar mengenali pola fisik perubahan warna akibat radiasi. Temuan ini membuka peluang pengembangan film dosimeter dengan respons spektral yang lebih optimal serta sensor dengan algoritma pembacaan yang lebih adaptif.

5.1.5 Kelemahan Regresi Linier dan Keunggulan *Random Forest*

Regresi linier terlihat sangat baik pada data pelatihan ($R^2 = 0,9995$), tetapi gagal memprediksi data uji dengan akurasi rendah (MAE 74,45 Gy; RMSE 175,04 Gy). Hal ini menunjukkan *overfitting*, lemahnya generalisasi, serta sensitivitas tinggi terhadap perubahan data (*domain shift*). Sebaliknya, *random forest* meskipun R^2 sedikit lebih rendah (0,9989), mampu memberikan prediksi jauh lebih akurat (MAE 16,47 Gy; RMSE 18,70 Gy) dan stabil pada berbagai periode. Keunggulan ini berasal dari sifat *ensemble learning*, *bootstrap sampling*, pemilihan fitur acak, serta regularisasi alami yang

membuat *random forest* lebih adaptif terhadap variasi data. Dengan demikian, *random forest* terbukti lebih andal untuk sistem prediksi dosis berbasis citra film dosimeter.


5.2 Tahap II – Validasi Biologis pada Bawang Merah

Tahap II penelitian bertujuan untuk menguji efektivitas prediksi dosis radiasi melalui validasi biologis pada umbi bawang merah. Pada Bab 4 telah ditunjukkan bahwa dosis 150 Gy yang diprediksi sistem memberikan pengaruh nyata dalam menghambat perkecambahan. Bagian ini membahas signifikansi biologis dari penghambatan tersebut, serta keterkaitannya dengan akurasi teknis model machine learning yang dikembangkan pada Tahap I.

5.2.1 Signifikansi Penghambatan Perkecambahan

Keberhasilan validasi biologis dengan efektivitas penghambatan 87,0% (**Tabel 4.18**) memberikan konfirmasi kuat bahwa sistem *machine learning* mampu memprediksi dosis yang relevan secara biologis. Nilai ini melebihi target minimal 80% yang ditetapkan berdasarkan literatur iradiasi bawang merah dan konsisten dengan penelitian Kavita *et al.* (2024) yang melaporkan efektivitas penghambatan pada dosis 100-120 Gy.

Odds ratio 16,67 (95% CI: 4,90-56,7) menunjukkan efek biologis yang sangat signifikan dan memberikan validasi berbasis bukti terhadap akurasi prediksi sistem. Hasil statistik *chi-square* ($\chi^2 = 22,78$, $p < 0,001$) mengkonfirmasi bahwa perbedaan yang diamati bukan karena variabilitas acak, melainkan efek langsung dari dosis iradiasi yang diprediksi sistem.



Gambar 5.2 Perbandingan Persentase Perkecambahan Kontrol Vs Iradiasi

5.2.2 Korelasi Prediksi Teknis dengan Efektivitas Biologis

Meskipun terdapat variabilitas dalam metrik teknis model (RMSE 16,47-175,04 Gy pada **Tabel 4.11**), efektivitas biologis tetap tercapai secara konsisten. Hal ini mengindikasikan bahwa untuk aplikasi praktis iradiasi pangan, akurasi prediksi dalam kisaran ± 20 -30 Gy dari target 150 Gy masih dapat memberikan efek biologis yang diinginkan.

Temuan ini sejalan dengan konsep "toleransi biologis" dalam iradiasi pangan yang dikemukakan oleh IAEA (2022), dimana efektivitas biologis tidak selalu memerlukan presisi dosis yang sangat ketat seperti dalam aplikasi medis. Namun, untuk standarisasi komersial, peningkatan akurasi prediksi tetap diperlukan untuk memenuhi regulasi internasional.

5.3 Perbandingan dengan Metode Konvensional

Hasil penelitian menunjukkan adanya perbedaan yang jelas antara metode konvensional dan sistem berbasis *machine learning*. Spektrofotometer memiliki akurasi tinggi dan konsistensi waktu yang baik (perubahan R^2 hanya -1,27%), namun membutuhkan laboratorium khusus dan operator terlatih, sehingga aksesnya terbatas. Sebaliknya, sistem *machine learning* memang lebih bervariasi secara temporal, tetapi jauh lebih mudah diakses, murah, dan mendukung digitalisasi dosimetri, terutama di fasilitas dengan sumber daya terbatas. Dalam konteks iradiasi pangan, akurasi yang dibutuhkan tidak seketat bidang medis; ISO 14470:2011 masih memberi toleransi terhadap ketidakpastian. Oleh karena itu, pendekatan *Machine Learning* tetap layak diterapkan, meski untuk skala industri diperlukan protokol standar dan peningkatan konsistensi.

5.4 Implikasi terhadap Pengembangan Teknologi Dosimetri

Penelitian ini menjadi bukti konsep bahwa digitalisasi dapat diterapkan dalam dosimetri dengan memanfaatkan *scanner* konvensional dan algoritma *machine learning open-source*. Pendekatan ini menawarkan solusi ekonomis, mudah direplikasi, serta berpotensi memperluas adopsi teknologi iradiasi di negara berkembang yang terkendala infrastruktur. Dengan begitu, teknologi dosimetri modern tidak hanya terbatas di

laboratorium besar, melainkan juga bisa diakses lebih luas untuk mendukung ketahanan pangan dan inovasi pascapanen.

5.5. Keterbatasan Penelitian

Meski memberikan hasil yang menjanjikan, penelitian ini masih memiliki keterbatasan, antara lain: protokol pengukuran belum sepenuhnya setara dengan standar spektrofotometer, kondisi lingkungan saat *scanning* belum sepenuhnya terkontrol, jumlah sampel masih terbatas, serta belum tersedia data jangka panjang untuk menguji stabilitas model. Faktor-faktor ini perlu diperhatikan dalam penelitian lanjutan agar sistem yang dikembangkan semakin reliabel dan dapat diterapkan secara luas.