

Prediksi Keberhasilan Pengobatan dan Identifikasi Faktor Klinis Penting pada Kanker Tiroid Berdiferensiasi Menggunakan *Kolmogorov-Arnold Networks* dan SHAP

Muhammad Ainul Fikri¹, Ajie Kusuma Wardhana², Fauzia Anis Sekar Ningrum³,
Ingrid Yanuar Risca Pratiwi⁴, Yudha Riwanto⁵, Raditya Arief Pratama⁶

Program Studi Teknik Informatika, PSDKU Polije Nganjuk, Kauman 64411, Indonesia^{1,6}

Program Studi Informatika, Universitas Multimedia Nusantara, Tangerang 15810, Indonesia²

Program Studi Teknologi Informasi, Politeknik Negeri Malang, Lowokwaru 65141, Indonesia⁴

Program Studi Informatika, Universitas Amikom Yogyakarta, Jl. Jl. Ring Road Utara, Condongcatur,
Daerah Istimewa Yogyakarta 55281^{3,5}

m.ainulfikri@polije.ac.id¹, ajie.wardhana@umn.ac.id², fauzianingrum@amikom.ac.id³,
ingrid.yanuar@polinema.ac.id⁴, yudha.riwanto@amikom.ac.id⁵, radityaariefp@polije.ac.id⁶

Abstract – Differentiated thyroid cancer requires accurate evaluation of therapy response to determine advanced patient management strategies. This study aims to develop a predictive model for the success of differentiated thyroid cancer treatment using Kolmogorov-Arnold Networks (KAN) integrated with the SHapley Additive exPlanations (SHAP) method. This integration aims to produce a predictive system that is not only accurate but also has intrinsic interpretability that is transparent to medical professionals. Retrospective clinical data of 383 patients with 17 features were evaluated using KAN modeling with adaptive weighting network pruning optimization. Interpretation of feature contributions was analyzed post-hoc using the SHAP KernelExplainer algorithm. The test results proved that the KAN model achieved very competitive performance with an accuracy of 97.40%, a precision of 97.87%, a recall of 97.40%, an F1-score of 97.47%, and an ROC-AUC of 99.75%. This model recorded a sensitivity level of 100% in predicting the success class of therapy without any classification errors. SHAP analysis revealed that the Response feature (therapy response evaluation) provided the most dominant contribution to the prediction results, followed by the Risk (risk stratification), Age (age), and M (metastasis status) variables. As a clinical decision support tool, KAN effectively selects automatic features through its spline sparsity mechanism and provides a comprehensive explanation along with the SHAP method. As a suggestion for future development, further research can deepen the mathematical correlation analysis between the KAN spline representation and the SHAP distribution values, as well as expand model testing using a larger scale multicenter dataset.

Keywords: Thyroid Cancer, Treatment Success Prediction, Kolmogorov-Arnold Networks, Machine Learning, SHAP, Explainable AI

Abstrak – Kanker tiroid berdiferensiasi memerlukan evaluasi respons terapi yang akurat untuk menentukan strategi penanganan pasien tingkat lanjut. Penelitian ini bertujuan mengembangkan model prediksi keberhasilan pengobatan kanker tiroid berdiferensiasi menggunakan *Kolmogorov-Arnold Networks* (KAN) yang diintegrasikan dengan metode *SHapley Additive exPlanations* (SHAP). Integrasi ini bertujuan menghasilkan sistem prediktif yang tidak hanya akurat tetapi juga memiliki interpretabilitas intrinsik yang transparan bagi tenaga medis. Data klinis retrospektif sebanyak 383 pasien dengan 17 fitur dievaluasi menggunakan pemodelan KAN dengan optimasi pemangkasan (*pruning*) jaringan pembobot adaptif. Interpretasi kontribusi fitur dianalisis secara *post-hoc* menggunakan algoritma SHAP *KernelExplainer*. Hasil pengujian membuktikan bahwa model KAN mencapai performa yang sangat kompetitif dengan akurasi 97,40%, *precision* 97,87%, *recall* 97,40%, *F1-score* 97,47%, dan *ROC-AUC* 99,75%. Model ini mencatatkan tingkat sensitivitas 100% dalam memprediksi kelas keberhasilan terapi tanpa adanya kesalahan klasifikasi. Analisis SHAP mengungkap bahwa fitur *Response* (evaluasi respons terapi) memberikan kontribusi paling dominan

terhadap hasil prediksi, diikuti oleh variabel *Risk* (stratifikasi risiko), *Age* (usia), dan *M* (status metastasis). Sebagai alat pendukung keputusan klinis, KAN secara efektif menyeleksi fitur otomatis melalui mekanisme *sparsity* pada *spline*-nya dan memberikan penjelasan yang komprehensif bersama metode SHAP. Sebagai saran pengembangan ke depan, penelitian selanjutnya dapat memperdalam analisis korelasi matematis antara representasi *spline* KAN dengan nilai distribusi SHAP, serta memperluas pengujian model menggunakan *dataset* multisenter dengan skala yang lebih besar.

Kata Kunci: Kanker Tiroid, Prediksi Keberhasilan Pengobatan, *Kolmogorov-Arnold Networks*, *Machine Learning*, SHAP, *Explainable AI*.

I. PENDAHULUAN

Kanker tiroid berdiferensiasi (*Differentiated Thyroid Cancer*, DTC) merupakan jenis keganasan endokrin yang paling sering ditemukan di seluruh dunia. Dalam beberapa dekade terakhir, insiden kanker tiroid menunjukkan tren peningkatan yang konsisten, yang sebagian besar dikaitkan dengan kemajuan teknologi pencitraan, meningkatnya penggunaan prosedur skrining, serta perbaikan metode diagnostik histopatologi [1], [2], [3]. Meskipun sebagian besar kasus DTC memiliki prognosis yang sangat baik dengan tingkat kelangsungan hidup jangka panjang yang tinggi, penyakit ini tetap menjadi perhatian klinis dan kesehatan masyarakat karena dapat menyebabkan komplikasi serius apabila tidak didiagnosis dan ditangani secara tepat. Pada kondisi tertentu, DTC dapat berkembang menjadi penyakit metastatik, menurunkan kualitas hidup pasien, dan meningkatkan beban pelayanan kesehatan [4], [5], [6].

Menurut data GLOBOCAN 2018, kanker tiroid menyumbang sekitar 3,1% dari seluruh kasus kanker di dunia, dengan angka mortalitas sebesar 0,4% [7]. Walaupun angka kematiannya relatif rendah dibandingkan jenis kanker lainnya, peningkatan jumlah kasus baru setiap tahun menunjukkan bahwa kanker tiroid merupakan masalah kesehatan yang terus berkembang. Pada populasi anak-anak dan remaja, DTC juga merupakan keganasan endokrin yang paling umum ditemukan meskipun insidennya tergolong jarang. Kelompok usia ini memiliki karakteristik klinis yang berbeda, termasuk kecenderungan metastasis regional yang lebih tinggi dan risiko ke kambuhan yang lebih besar dibandingkan pasien dewasa [7], [8], [9].

Apabila DTC tidak ditangani secara optimal, risiko ke kambuhan dan progresi penyakit meningkat secara signifikan. Keterlambatan

diagnosis atau terapi dapat menyebabkan pasien terdeteksi pada stadium yang lebih lanjut, sehingga meningkatkan kemungkinan terjadinya metastasis jauh dan menurunkan angka harapan hidup [6], [10], [11]. Selain itu, sebagian pasien dapat mengalami kondisi *radioactive iodine-refractory (RAI-refractory)*, yaitu keadaan ketika sel tumor tidak lagi merespons terapi iodium radioaktif. Kondisi ini secara substansial membatasi pilihan terapi dan berkaitan dengan prognosis yang lebih buruk [12], [13]. Oleh karena itu, identifikasi dini, stratifikasi risiko, dan evaluasi respons terapi yang akurat merupakan komponen penting dalam menentukan strategi pengobatan yang paling sesuai bagi setiap pasien.

Di Indonesia, kanker tiroid menempati urutan kesembilan sebagai kanker tersering berdasarkan registrasi patologi nasional [14], [15]. Beberapa studi dari rumah sakit rujukan menunjukkan bahwa mayoritas pasien DTC adalah perempuan pada rentang usia produktif, terutama antara 41 hingga 54 tahun. *Papillary thyroid carcinoma (PTC)* merupakan sub tipe histopatologi yang paling dominan, mencakup lebih dari 90% dari seluruh kasus, dan sebagian besar pasien terdiagnosis pada stadium awal [15], [16]. Laporan dari pusat pelayanan kesehatan di Denpasar dan Bandung menunjukkan ratusan kasus DTC dalam kurun waktu lima tahun terakhir, sedangkan pada kelompok anak dan remaja ditemukan angka ke kambuhan yang relatif tinggi meskipun mortalitas tetap rendah [12], [15]. Penatalaksanaan DTC di Indonesia umumnya mengikuti pedoman internasional yang mencakup tiroidektomi total atau sub total, terapi ablasi iodium radioaktif, dan terapi supresi hormon tiroid jangka panjang [14], [15], [16]. Meskipun demikian, implementasi tata laksana tersebut masih menghadapi berbagai tantangan, terutama terkait keterbatasan akses terhadap fasilitas diagnostik lanjutan, pemeriksaan molekuler, dan terapi

adjuvan di beberapa wilayah [17], [18], [19]. Disparitas infrastruktur kesehatan ini berpotensi memengaruhi ketepatan diagnosis, stratifikasi risiko, dan evaluasi respons terapi [20], [21], [22], [23], [24], [25]. Padahal, penilaian keberhasilan pengobatan merupakan aspek yang sangat penting dalam manajemen DTC karena menentukan keputusan klinis lanjutan, termasuk kebutuhan terapi tambahan dan intensitas pemantauan pasien [26], [27], [28], [29].

Dalam konteks tersebut, diperlukan pendekatan yang lebih objektif, konsisten, dan *scalable* untuk mendukung proses evaluasi klinis. Salah satu pendekatan yang menjanjikan adalah pemanfaatan teknologi berbasis kecerdasan buatan (*artificial intelligence*) untuk memprediksi tingkat keberhasilan pengobatan kanker tiroid berdiferensiasi berdasarkan data klinis pasien [30], [31]. Selain mampu menghasilkan prediksi dengan tingkat akurasi yang tinggi, pendekatan ini juga memungkinkan identifikasi fitur-fitur klinis yang paling berkontribusi dalam proses pengambilan keputusan, sehingga dapat meningkatkan transparansi model dan memberikan wawasan yang lebih mendalam bagi klinisi dalam memahami faktor-faktor yang memengaruhi respons terapi [32], [33], [34].

Dalam praktik klinis, kebutuhan tidak hanya berhenti pada model dengan performa prediksi yang tinggi, tetapi juga pada model yang mampu menjelaskan alasan di balik suatu keputusan. Dengan kata lain, model yang dikembangkan harus mampu menjawab mengapa seorang pasien diprediksi memiliki probabilitas tinggi atau rendah untuk mencapai respons terapi yang baik. Sejumlah penelitian sebelumnya telah memanfaatkan model *black-box* seperti *XGBoost*, *Random Forest*, *CatBoost*, dan *neural network* untuk memprediksi ke kambuhan, metastasis jauh, dan respons terapi pada kanker tiroid [35], [36], [37], [38]. Guna meningkatkan interpretabilitas, penelitian-penelitian tersebut umumnya menambahkan metode SHAP (*SHapley Additive exPlanations*) guna mengidentifikasi fitur-fitur klinis yang paling berpengaruh, seperti respons terapi, stratifikasi risiko, ukuran tumor, status T dan N, kadar *thyroglobulin* (Tg), antibodi Tg, usia, dan parameter hematologi. Hasil analisis SHAP

terbukti mampu membantu klinisi memahami kontribusi masing-masing variabel, mengusulkan ambang baru (*cut-off*) untuk *biomarker* tertentu, serta menyesuaikan intensitas terapi dan strategi tindak lanjut secara lebih personal [35], [36], [37], [39].

Meskipun demikian, pendekatan tersebut masih memiliki keterbatasan mendasar. Sebagian besar penelitian tetap bertumpu pada model yang secara inheren bersifat *black-box*, kemudian dijelaskan pada tahap akhir menggunakan metode *post-hoc* seperti SHAP. Literatur *Explainable Artificial Intelligence* (XAI) menunjukkan bahwa strategi ini belum sepenuhnya menjamin transparansi model. Model dengan akurasi tinggi belum tentu menghasilkan estimasi pentingnya fitur yang bebas bias, terutama ketika model mengalami *overfitting* atau memiliki struktur yang sangat kompleks [38]. Selain itu, algoritma seperti *multilayer perceptron* (MLP), *Random Forest*, *XGBoost*, dan berbagai arsitektur *deep learning* pada dasarnya dirancang untuk memaksimalkan performa prediksi, bukan untuk menyediakan representasi fungsi yang mudah dipahami oleh manusia [40], [41], [42], [43]. Dalam konteks pengambilan keputusan klinis yang berisiko tinggi, sejumlah peneliti menekankan pentingnya penggunaan model yang sejak awal dirancang agar *interpretable*, bukan hanya dijelaskan setelah proses pelatihan selesai [43], [44], [45].

Salah satu pendekatan yang mulai mendapat perhatian adalah *Kolmogorov-Arnold Networks* (KAN). Berbeda dengan jaringan saraf konvensional yang menggunakan bobot linear statis, KAN merepresentasikan hubungan antarvariabel menggunakan fungsi-fungsi univariat yang dapat dipelajari pada setiap *edge*. Struktur ini memungkinkan hubungan antara fitur klinis dan *output* model divisualisasikan secara lebih intuitif, bahkan dalam beberapa kasus dapat diekstraksi menjadi formula simbolik yang eksplisit [42], [46], [47]. Berbagai varian KAN, seperti *Logistic-KAN*, *KAAM*, *CoxKAN*, dan *Bayesian-KAN*, telah menunjukkan kemampuan untuk menyamai atau melampaui performa model *deep learning* konvensional, sekaligus melakukan seleksi fitur otomatis dan menghasilkan representasi fungsi yang lebih mudah diinterpretasikan [36], [42], [47]. Ketika dikombinasikan dengan SHAP, KAN

berpotensi memberikan dua lapis interpretabilitas, yaitu transparansi intrinsik dari struktur model dan penjelasan kontribusi fitur pada tingkat global maupun individual [46].

Berdasarkan uraian tersebut, terdapat celah penelitian di mana belum banyak studi yang mengembangkan model prediksi keberhasilan pengobatan kanker tiroid berdiferensiasi dengan pendekatan yang tidak hanya memiliki performa tinggi, tetapi juga menyediakan interpretabilitas intrinsik yang kuat. Sebagian besar penelitian sebelumnya masih bergantung pada model *black-box* yang memerlukan metode penjelasan tambahan pada tahap akhir, sehingga transparansi model belum sepenuhnya terjamin [38], [40], [41], [42], [43], [44], [45]. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model berbasis *Kolmogorov-Arnold Networks* yang dipadukan dengan SHAP untuk mendeteksi tingkat keberhasilan pengobatan kanker tiroid berdiferensiasi serta mengidentifikasi fitur-fitur klinis yang paling berperan dalam proses pengambilan keputusan. Pendekatan ini diharapkan dapat menghasilkan model prediksi yang akurat, transparan, dan mudah diinterpretasikan, sehingga dapat memberikan dukungan yang lebih kuat bagi klinisi dalam menentukan strategi terapi dan tindak lanjut pasien secara berbasis data.

II. TINJAUAN PUSTAKA

A. *Kolmogorov-Arnold Networks* (KAN)

KAN merupakan salah satu varian arsitektur kecerdasan buatan yang berpotensi mencapai akurasi dan keterbacaan yang tinggi dalam lingkungan waktu nyata [48]. KAN dikembangkan sebagai model pembelajaran mesin baru yang bertujuan mendekati fungsi-fungsi kompleks dengan jumlah parameter yang lebih sedikit melalui penggabungan fungsi analisis tunggal atau univariat [49].

Teori *Kolmogorov-Arnold* menyatakan bahwa setiap fungsi kontinu multivariat $f(x_1, \dots, x_n)$ dapat direpresentasikan dalam bentuk komposisi sejumlah fungsi univariat yang dikombinasikan melalui operasi penjumlahan biner [48]. Adapun rumus umum KAN dituliskan pada fungsi berikut:

$$f_x = f(x_1, \dots, x_n) \sum_{q=1}^{2n+1} \phi_q \left(\sum_{p=1}^n \phi_{q,p}(x_p) \right) \quad (1)$$

di mana $\phi_{q,p} \rightarrow \mathbb{R}$ adalah fungsi univariat kontinu. $\phi_q : \mathbb{R} \rightarrow \mathbb{R}$ adalah fungsi kontinu yang bergantung pada hasil penjumlahan $\phi_{q,p}(x_p)$.

Metode KAN dirancang untuk mendekomposisi fungsi kompleks menjadi komponen yang lebih sederhana dan mudah diinterpretasikan melalui fungsi univariat adaptif berbasis *Spline* [50]. KAN menggunakan fungsi adaptif berbasis *Spline* pada setiap koneksi antar neuron untuk merepresentasikan hubungan non linier secara lebih fleksibel dan mudah diinterpretasikan. Pendekatan ini memungkinkan proses aproksimasi fungsi yang lebih akurat, stabil, serta efisien dalam penggunaan parameter dan sumber daya komputasi [48]. Secara matematis, fungsi *Spline* dapat direpresentasikan melalui persamaan berikut.

$$spline(x) = \sum_i c_i B_i(x) \quad (2)$$

di mana x adalah variabel *input*, $B_i(x)$ fungsi basis *spline* ke- i yang digunakan untuk membentuk kurva atau pola fungsi, c_i koefisien pembobot fungsi basis ke- i yang akan dipelajari selama proses pelatihan model, \sum_i operasi penjumlahan seluruh fungsi basis *Spline* yang telah dikalikan dengan koefisiennya.

Berdasarkan konsep tersebut, KAN mengubah paradigma pembelajaran jaringan saraf tiruan dari penggunaan bobot statis menjadi fungsi aktivasi adaptif yang dapat dipelajari pada setiap koneksi antar neuron. Pendekatan ini memungkinkan model untuk menentukan tingkat kepentingan fitur secara lebih fleksibel serta mendukung proses komputasi dengan kebutuhan sumber daya yang relatif rendah [51]. Selain itu, KAN menawarkan kerangka konseptual baru yang berbeda dari *Multi-Layer Perceptron* (MLP) tradisional yang umumnya didasarkan pada teorema aproksimasi universal. Pada KAN, parameter bobot konvensional digantikan oleh fungsi-fungsi adaptif yang dapat dipelajari, sehingga meningkatkan kemampuan model dalam merepresentasikan hubungan *nonlinear* secara lebih *interpretable* [52].

B. Shapley Additive exPlanation (SHAP)

Shapley Additive exPlanation (SHAP) merupakan salah satu metode yang banyak digunakan untuk menginterpretasikan hasil prediksi model pembelajaran mesin. Metode ini memanfaatkan konsep Teori Permainan untuk mengukur kontribusi setiap fitur terhadap suatu prediksi tertentu[53].

SHAP termasuk dalam kategori teknik atribusi fitur aditif yang bersifat model-agnostik, sehingga dapat diterapkan pada berbagai model pembelajaran mesin maupun pembelajaran mendalam. Melalui pendekatan tersebut, tingkat pengaruh masing-masing fitur masukan dapat dianalisis, sehingga membantu meningkatkan pemahaman terhadap perilaku dan proses pengambilan keputusan model[53]. Dalam pembelajaran mesin, konsep ini diadopsi melalui metode *Shapley Additive exPlanation (SHAP)* untuk menganalisis tingkat pengaruh setiap fitur terhadap keputusan model [54].

Nilai *Shapley* merupakan konsep dari teori permainan kooperatif yang digunakan untuk mengukur kontribusi setiap pemain secara adil berdasarkan seluruh kemungkinan koalisi yang dapat terbentuk [55]. Nilai SHAP untuk fitur ke-*i* (Φ_i) dihitung dengan merata-ratakan kontribusi marginal fitur tersebut di semua kemungkinan kombinasi fitur, dengan rumus:

$$\Phi_i(vx) = \sum_{s \in M \setminus \{i\}} \frac{|s|!(M - |s| - 1)!}{M!} (vx(S \cup \{i\}) - vx(S)) \quad (3)$$

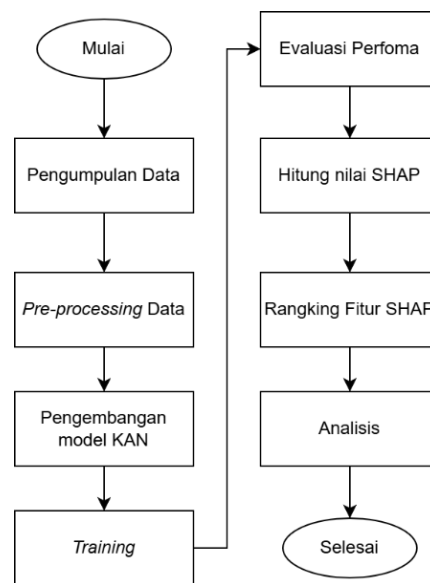
di mana Φ_i merupakan nilai Shapley dari anggota suatu fitur terhadap hasil prediksi. $Val(S)$ adalah *output* dari model yang akan dijelaskan menggunakan satu set fitur *S*, dan *p* adalah jumlah keseluruhan dari semua fitur. Kontribusi akhir atau nilai *Shapley* dari fitur *i* (Φ_i) didefinisikan juga sebagai rata-rata dari marginal kontribusinya di seluruh permutasi yang mungkin dari set fitur. Ini dilakukan dengan memasukkan semua kombinasi fitur yang mungkin dan menghitung bagaimana kontribusi masing-masing fitur berubah ketika fitur lain berubah.

Metode SHAP bersifat aditif karena menjelaskan prediksi model sebagai hasil penjumlahan kontribusi setiap fitur dengan nilai dasar (*base value*). Selain itu, SHAP juga menerapkan prinsip keadilan melalui nilai Shapley, sehingga kontribusi prediksi dapat didistribusikan secara proporsional pada setiap

fitur berdasarkan konsep teori permainan kooperatif [55]. Pada penelitian [56] metode SHAP juga digunakan untuk mengevaluasi peran masing-masing variabel prediktor secara relatif. Hal ini menunjukkan bahwa SHAP sangat mampu untuk menjabarkan peran fitur secara komprehensif.

III. ANALISA DAN PERANCANGAN SISTEM

Gambar 1 menunjukkan tahapan penelitian yang digunakan untuk membangun model prediksi keberhasilan pengobatan kanker tiroid berdiferensiasi menggunakan *Kolmogorov-Arnold Networks (KAN)* serta mengidentifikasi fitur-fitur klinis yang paling berpengaruh terhadap hasil prediksi. Setiap tahapan disusun secara berurutan agar proses pengembangan model, evaluasi performa, dan interpretasi hasil dapat dilakukan secara sistematis dan saling mendukung.



Gambar 1. Alur Penelitian

Penelitian diawali dengan pengumpulan data klinis pasien kanker tiroid berdiferensiasi. Data yang diperoleh kemudian melalui tahap *pre-processing*, yang mencakup pembersihan data, *encoding* variabel kategorikal, *scaling* fitur numerik, pembagian data ke dalam data latih dan data uji, serta penerapan SMOTE pada data latih untuk mengatasi ketidakseimbangan kelas. Selanjutnya, model KAN dikembangkan dan dilatih menggunakan data yang telah diproses untuk mempelajari hubungan antara karakteristik klinis pasien dan status

keberhasilan pengobatan. Setelah proses pelatihan selesai, performa model dievaluasi menggunakan beberapa metrik klasifikasi untuk memastikan kemampuan prediksi model. Model yang telah dievaluasi kemudian dianalisis menggunakan SHAP untuk menghitung kontribusi masing-masing fitur terhadap hasil prediksi. Nilai SHAP yang diperoleh digunakan untuk menyusun peringkat fitur berdasarkan tingkat kepentingannya, kemudian dibandingkan dengan fungsi spline yang dihasilkan oleh KAN untuk menilai kesesuaian pola hubungan yang dipelajari model. Tahap akhir dilakukan dengan menganalisis hasil prediksi, ranking fitur SHAP, dan visualisasi *spline* KAN secara terpadu guna mengidentifikasi faktor-faktor klinis yang paling berperan dalam menentukan keberhasilan pengobatan kanker tiroid berdiferensiasi.

A. Metode Pengambilan Data

Data yang digunakan adalah *Differentiated Thyroid Cancer Recurrence Dataset*, data ini berupa data klinis retrospeksi pasien kanker tiroid berdiferensiasi hingga evaluasi respons terapi [57]. Dataset ini telah digunakan secara luas dalam berbagai penelitian prediksi ke kambuhan berbasis *machine learning* dan menjadi salah satu *benchmark* yang representatif untuk domain onkologi tiroid. Keseluruhan data terdiri dari 383 rekam medis pasien dengan 17 fitur klinis yang mencakup aspek demografis, riwayat klinis, hasil pemeriksaan fisik, karakteristik patologis, klasifikasi TNM, hingga evaluasi respons terapi.

Salah satu fitur penting dalam dataset adalah kolom *Response* yang merepresentasikan hasil evaluasi respons terapi berdasarkan sistem *dynamic risk stratification*. Sistem ini digunakan untuk menilai kondisi pasien setelah terapi awal berupa operasi dan/atau radioiodine, sekaligus memperkirakan risiko ke kambuhan di masa mendatang. Terdapat empat kategori dalam fitur ini: Excellent yang menandakan tidak ada bukti penyakit pada pemeriksaan darah maupun *imaging*, *Biochemical Incomplete* yang menunjukkan kadar Tg/anti-Tg abnormal (*thyroglobulin* dan antibodi *thyroglobulin*) namun *imaging* masih negatif, *Structural*

Incomplete yang mengindikasikan ditemukannya bukti anatomi kanker pada *imaging*, serta *Indeterminate* yang merujuk pada temuan yang belum dapat disimpulkan secara klinis.

Fitur lain yang turut berperan dalam stratifikasi risiko adalah klasifikasi TNM, yaitu sistem internasional yang dikembangkan oleh AJCC/UICC untuk menentukan tingkat keparahan kanker tiroid. Sistem ini menggambarkan kondisi pasien dari tiga dimensi sekaligus: ukuran dan penyebaran tumor primer (T1a hingga T4b), keterlibatan kelenjar getah bening regional (N0, N1a, N1b), serta ada tidaknya metastasis jauh ke organ lain seperti paru-paru atau tulang (M0, M1).

IV. IMPLEMENTASI DAN PEMBAHASAN

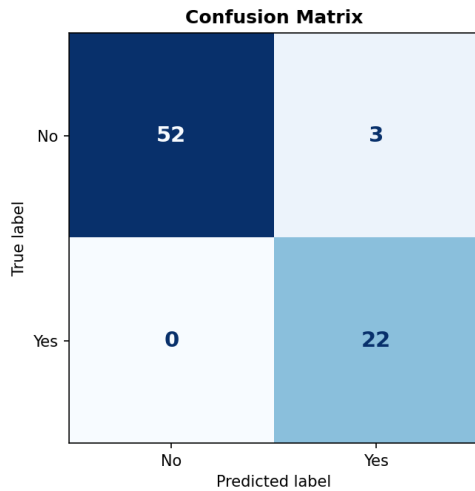
A. Implementasi Model Kolmogorov-Arnold Networks

Model *Kolmogorov-Arnold Networks* (KAN) yang telah dikembangkan selanjutnya dievaluasi untuk mengetahui kemampuannya dalam memprediksi keberhasilan pengobatan kanker tiroid berdiferensiasi. Evaluasi dilakukan menggunakan lima metrik utama, yaitu *accuracy*, *precision*, *recall*, *F1-score*, dan *ROC-AUC*. Selain itu, hasil prediksi juga dianalisis menggunakan *confusion matrix* serta kurva akurasi dan *loss* selama proses pelatihan untuk menilai stabilitas model.

Berdasarkan hasil evaluasi, model KAN memperoleh nilai *accuracy* sebesar 97,40%, *precision* sebesar 97,87%, *recall* sebesar 97,40%, dan *F1-score* sebesar 97,47%. Nilai *ROC-AUC* yang mencapai 99,75% menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam membedakan pasien dengan pengobatan berhasil dan tidak berhasil. Secara keseluruhan, hasil ini menunjukkan bahwa model KAN mampu mempelajari pola hubungan antara variabel klinis dan outcome pengobatan dengan tingkat ketepatan yang sangat tinggi.

Gambar 2 menunjukkan *confusion matrix* dari model KAN pada data pengujian. Dari total 77 data uji, model berhasil mengklasifikasikan 52 dari 55 pasien dengan label “No” secara benar, sementara 3 pasien salah diprediksi sebagai “Yes”. Pada kelas “Yes”, seluruh 22 pasien berhasil diprediksi dengan benar tanpa satu pun kesalahan

klasifikasi. Hasil ini menunjukkan bahwa model memiliki sensitivitas yang sangat baik dalam mendeteksi pasien yang mengalami keberhasilan pengobatan, serta tingkat kesalahan yang sangat rendah pada keseluruhan data uji.




Gambar 2. Confussion Matrix KAN

Kurva pelatihan pada Gambar 3 menunjukkan bahwa nilai *training loss* dan *validation loss* mengalami penurunan tajam pada epoch-epoch awal, yang menandakan

bahwa model dengan cepat mempelajari pola utama pada data. Setelah sekitar epoch ke-20, *validation loss* cenderung stabil di kisaran 0,09, sedangkan *training loss* terus menurun hingga mendekati nol. Pada saat yang sama, *training accuracy* meningkat hingga mencapai 100%, sedangkan *validation accuracy* stabil pada kisaran 96–97% dengan nilai terbaik sebesar 97,40%. Pola ini menunjukkan bahwa model telah mencapai konvergensi dengan performa yang stabil. Meskipun terdapat selisih kecil antara performa data latih dan data validasi, perbedaannya masih dalam batas yang wajar dan tidak menunjukkan indikasi *overfitting* yang signifikan.

Secara keseluruhan, hasil implementasi menunjukkan bahwa model KAN mampu memberikan performa prediksi yang sangat baik dan konsisten pada data kanker tiroid berdiferensiasi. Tingginya nilai metrik evaluasi, minimnya kesalahan klasifikasi pada *confusion matrix*, serta stabilitas kurva pelatihan menunjukkan bahwa model ini layak digunakan pada tahap interpretasi berikutnya untuk menganalisis hubungan antara fitur klinis dan keberhasilan pengobatan melalui *spline* KAN dan SHAP.



Gambar 3. Kurva akurasi dan *loss*

B. Analisis Spline Model Komolgorof-Arnold Networks

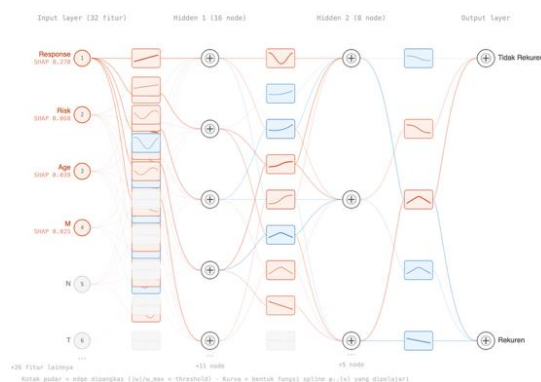
Visualisasi plot KAN (gambar 4) yang dihasilkan dalam penelitian ini menampilkan arsitektur jaringan dengan konfigurasi [32, 16, 8, 2], di mana setiap koneksi antar lapisan direpresentasikan sebagai kotak kecil berisi kurva *spline* yang mencerminkan fungsi transformasi yang dipelajari model pada

koneksi tersebut. Berbeda dengan visualisasi jaringan saraf tiruan konvensional yang hanya menampilkan bobot berupa garis dengan ketebalan tertentu, plot KAN memberikan informasi yang jauh lebih kaya karena setiap edge secara eksplisit memperlihatkan bentuk fungsi matematika yang menghubungkan node input dengan node output pada lapisan berikutnya.

Node bertanda \oplus pada setiap lapisan merepresentasikan operasi penjumlahan

seluruh *output spline* yang masuk, yang secara langsung mencerminkan implementasi Teorema *Kolmogorov-Arnold* dalam arsitektur jaringan.

Dari visualisasi plot KAN yang dihasilkan, terlihat bahwa sebagian besar *edge* pada lapisan pertama yang menghubungkan 32 fitur *input* ke lapisan tersembunyi pertama menampilkan variasi bentuk kurva yang beragam. *Edge-edge* yang aktif dan informatif menampilkan kurva dengan amplitudo yang terukur dan bentuk yang khas, sementara sejumlah *edge* lainnya menampilkan kurva yang relatif datar dengan amplitudo rendah, mengindikasikan kontribusi yang minimal terhadap keluaran model.



Gambar 4 Artitektur Kolmogorov Arnold Network

Pada lapisan kedua yang menghubungkan lapisan tersembunyi ke *node output*, tingkat *sparsitas* terlihat lebih tinggi, di mana hanya sebagian kecil koneksi yang menampilkan kurva aktif dengan bentuk yang terstruktur. Pola *sparsitas* yang terbentuk secara alami melalui proses optimasi ini mencerminkan kemampuan KAN dalam melakukan seleksi fitur secara implisit tanpa memerlukan mekanisme pemangkasan eksternal yang terpisah.

C. Implementasi SHAP

Implementasi SHAP dilakukan menggunakan *KernelExplainer*, yaitu metode interpretasi yang bekerja dengan memperkirakan kontribusi setiap fitur berdasarkan perubahan *output* prediksi model. Karena proses perhitungan SHAP memerlukan distribusi data sebagai referensi, penelitian ini menggunakan *subset* data latih yang diringkas menggunakan metode *k-means clustering*. Sebanyak 50 *cluster* digunakan sebagai

representasi distribusi data latih untuk membentuk *background distribution*. Pendekatan ini dipilih untuk mengurangi kompleksitas komputasi sekaligus mempertahankan karakteristik utama dari data pelatihan, sehingga proses interpretasi dapat dilakukan secara lebih efisien tanpa kehilangan pola penting yang dipelajari model.

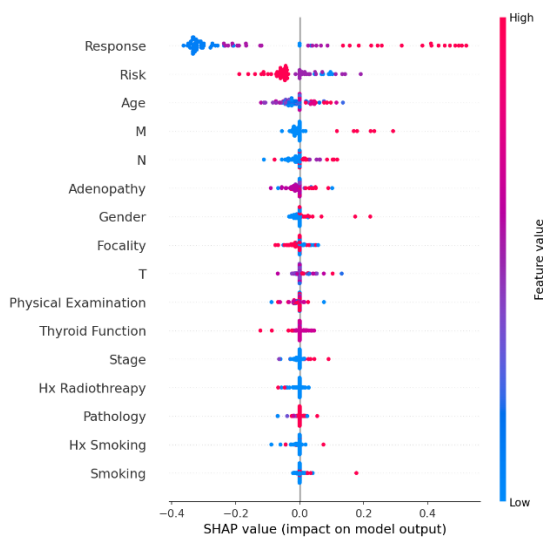
Selanjutnya, *KernelExplainer* digunakan untuk menghitung nilai SHAP pada data pengujian. Perhitungan dilakukan pada maksimal 150 sampel data uji dengan sejumlah iterasi tertentu agar proses interpretasi tetap stabil dan tidak memerlukan waktu komputasi yang terlalu besar. Pada tahap ini, SHAP mengevaluasi perubahan *output* prediksi ketika suatu fitur dipertahankan atau dihilangkan dari kombinasi fitur lainnya. Melalui mekanisme tersebut, setiap fitur memperoleh nilai kontribusi yang menunjukkan seberapa besar pengaruhnya terhadap probabilitas keberhasilan pengobatan yang dihasilkan oleh model KAN.

Nilai SHAP yang diperoleh kemudian dinormalisasi agar memiliki format yang konsisten untuk setiap kelas prediksi. Hasil tersebut selanjutnya digunakan untuk menyusun peringkat fitur berdasarkan rata-rata kontribusinya terhadap *output* model. Semakin besar nilai absolut SHAP suatu fitur, maka semakin besar pula pengaruh fitur tersebut terhadap keputusan model. Dengan pendekatan ini, fitur-fitur klinis yang paling dominan dalam menentukan keberhasilan pengobatan dapat diidentifikasi secara lebih objektif dan terukur.

Selain menghasilkan peringkat fitur, implementasi SHAP juga memberikan informasi mengenai arah pengaruh setiap variabel terhadap prediksi model. Nilai SHAP positif menunjukkan bahwa suatu fitur meningkatkan probabilitas keberhasilan pengobatan, sedangkan nilai negatif menunjukkan kecenderungan penurunan probabilitas keberhasilan terapi. Informasi ini menjadi penting karena tidak hanya menunjukkan fitur mana yang berpengaruh, tetapi juga bagaimana pengaruh tersebut bekerja terhadap hasil prediksi model. Dengan demikian, interpretasi SHAP dapat membantu menjelaskan hubungan antara karakteristik klinis pasien dan *outcome* pengobatan secara lebih transparan.

D. Analisis hasil SHAP

Hasil interpretasi menggunakan SHAP menunjukkan bahwa model KAN mampu mengidentifikasi fitur-fitur klinis yang memiliki kontribusi paling besar terhadap prediksi keberhasilan pengobatan kanker tiroid berdiferensiasi. Gambar 5 menampilkan SHAP beeswarm plot yang memperlihatkan distribusi kontribusi setiap fitur terhadap output model. Fitur diurutkan berdasarkan rata-rata nilai absolut SHAP, sehingga fitur yang berada di posisi paling atas merupakan variabel yang paling berpengaruh terhadap keputusan model.



Gambar 5. SHAP Beeswarm Plot

Berdasarkan hasil tersebut, fitur *Response* menjadi variabel dengan kontribusi terbesar terhadap prediksi model. Nilai SHAP pada fitur ini memiliki rentang distribusi paling luas dibandingkan fitur lainnya, yang menunjukkan bahwa perubahan nilai pada variabel *Response* memberikan dampak signifikan terhadap probabilitas prediksi kelas *Recurred = Yes*. Titik berwarna merah yang dominan berada pada sisi kanan grafik menunjukkan bahwa nilai fitur yang tinggi cenderung meningkatkan output prediksi, sedangkan titik biru pada sisi kiri menunjukkan kontribusi negatif terhadap probabilitas ke kambuhan. Setelah *Response*, fitur *Risk*, *Age*, dan *M* juga menunjukkan pengaruh yang relatif besar dibandingkan fitur klinis lainnya.

Fitur *Risk* memperlihatkan pola kontribusi yang cukup konsisten, di mana nilai fitur tertentu cenderung memberikan dampak

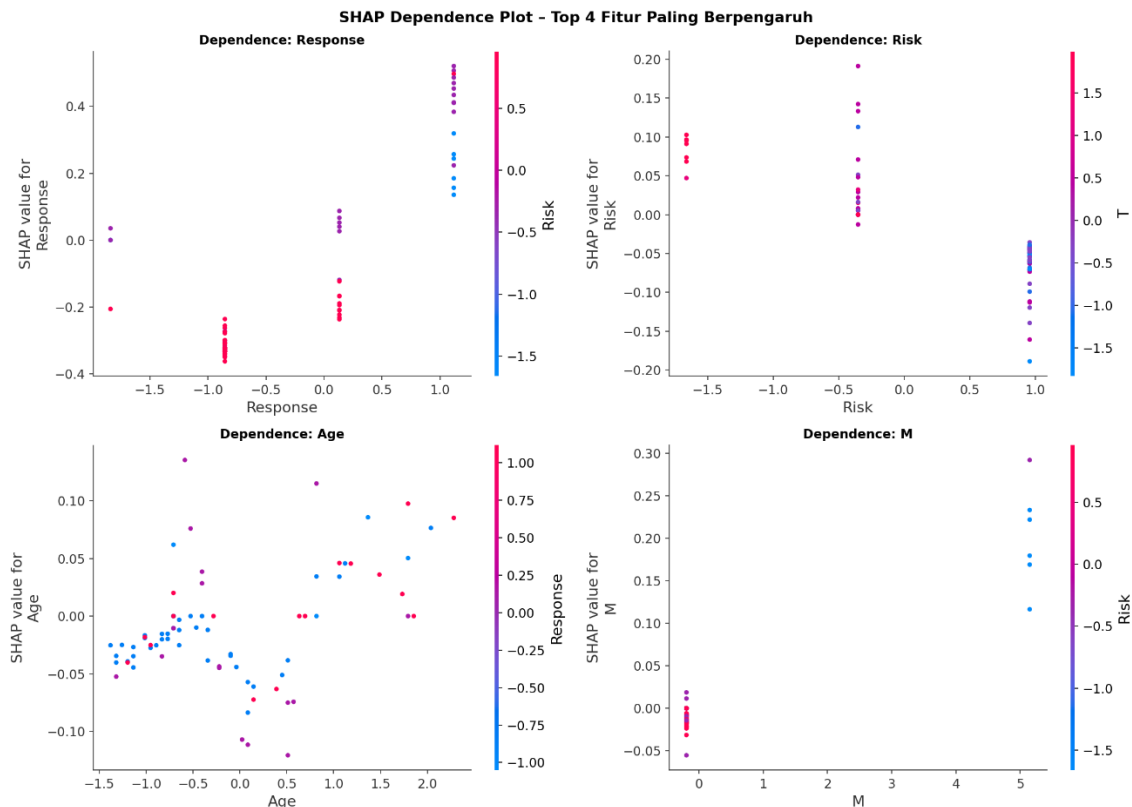
negatif terhadap prediksi ke kambuhan. Hal ini menunjukkan bahwa model mempelajari hubungan yang kuat antara stratifikasi risiko pasien dan *outcome* terapi. Sementara itu, fitur *Age* menunjukkan distribusi SHAP yang lebih menyebar, mengindikasikan adanya hubungan *nonlinier* antara usia pasien dan probabilitas keberhasilan pengobatan. Pada fitur *M*, terlihat bahwa sebagian kecil sampel memiliki kontribusi SHAP yang sangat tinggi, yang mengindikasikan bahwa keberadaan metastasis memiliki pengaruh besar pada keputusan model untuk beberapa pasien tertentu.

Guna memahami hubungan antarfitur secara lebih rinci, dilakukan analisis menggunakan SHAP dependence plot pada empat fitur dengan kontribusi tertinggi, yaitu *Response*, *Risk*, *Age*, dan *M*, seperti ditunjukkan pada Gambar 5. Pada fitur *Response*, terlihat bahwa perubahan nilai fitur menghasilkan perubahan SHAP yang cukup drastis dari negatif ke positif. Pola ini menunjukkan bahwa model sangat sensitif terhadap perubahan status respons terapi pasien. Selain itu, pewarnaan berdasarkan fitur *Risk* menunjukkan adanya interaksi antara kedua variabel tersebut dalam memengaruhi prediksi model.

Pada fitur *Risk*, nilai SHAP cenderung menurun pada kelompok risiko tertentu, yang menunjukkan bahwa model mengasosiasikan beberapa kategori risiko dengan probabilitas keberhasilan terapi yang lebih rendah. Interaksi dengan fitur *T* juga terlihat melalui variasi warna titik, yang mengindikasikan bahwa pengaruh *Risk* dapat berubah tergantung kondisi stadium tumor pasien. Sementara itu, fitur *Age* menunjukkan pola hubungan yang lebih kompleks dan tidak sepenuhnya linear. Pada beberapa rentang usia, kontribusi SHAP meningkat secara bertahap, sedangkan pada rentang lainnya terjadi penurunan kontribusi terhadap output model. Pola ini memperlihatkan kemampuan KAN dalam mempelajari hubungan *nonlinier* antarvariabel klinis.

Fitur *M* menunjukkan pola distribusi yang cukup jelas antara kelompok dengan dan tanpa metastasis. Sampel dengan nilai *M* tertentu menghasilkan kontribusi SHAP positif yang relatif tinggi terhadap prediksi ke kambuhan. Hal ini menunjukkan bahwa status metastasis menjadi salah satu indikator penting yang dipertimbangkan model dalam menentukan

probabilitas keberhasilan pengobatan pasien kanker tiroid berdiferensiasi.



Gambar 6. SHAP Dependence Plot

V. PENGUJIAN

Berdasarkan hasil perbandingan pada tabel 1, performa model KAN yang diusulkan dalam penelitian ini mampu mencapai akurasi sebesar 97,40%, sehingga berada pada tingkat yang kompetitif dibandingkan beberapa penelitian sebelumnya yang menggunakan algoritma seperti SVM, MLP, dan *Random Forest*. Perbedaan performa yang relatif kecil antar penelitian menunjukkan bahwa tingkat akurasi prediksi pada kasus kanker tiroid berdiferensiasi dipengaruhi oleh banyak faktor, seperti karakteristik *dataset*, jumlah sampel, distribusi kelas, jenis fitur klinis yang digunakan, strategi *pre-processing*, hingga pendekatan validasi model yang diterapkan. Oleh karena itu, tingginya performa suatu model tidak hanya ditentukan oleh kompleksitas algoritma, tetapi juga oleh kualitas representasi data yang dipelajari. Dalam konteks ini, keunggulan utama KAN tidak hanya terletak pada kemampuan prediksinya yang tinggi, tetapi juga pada aspek

interpretabilitas model. Kombinasi antara performa yang kompetitif dan kemampuan interpretasi inilah yang menjadikan KAN memiliki potensi yang kuat untuk diterapkan pada sistem pendukung keputusan klinis, khususnya dalam evaluasi keberhasilan pengobatan kanker tiroid berdiferensiasi.

TABEL 1
TABEL HASIL PERBANDINGAN PERFORMA DENGAN PENELITIAN TERDAHULU

Penelitian (Tahun)	Model Utama	Performa (test/terbaik dilaporkan)
Borzooei et al. 2023 [57]	SVM	97.14%
Yasar S 2024 [58]	SVM	94.81%
Onah et al. 2025 [59]	MLP	97.39%
Öztürk et al. 2025 [60]	RF	97.39%
Penelitian ini	KAN	97.40%

Perbandingan antara visualisasi spline KAN dan hasil analisis SHAP mengungkapkan konsistensi yang signifikan antara kedua metode interpretabilitas tersebut. Fitur

Response yang memperoleh nilai mean SHAP tertinggi sebesar 0,278 jauh melampaui fitur-fitur lainnya secara konsisten menampilkan kurva spline dengan amplitudo paling tinggi dan bentuk paling terstruktur di antara seluruh fitur input, dengan pola kurva yang mendekati fungsi sigmoid yang mengindikasikan adanya efek ambang batas yang tegas dalam penilaian status rekurensi kanker tiroid. Hal ini menunjukkan bahwa model KAN tidak hanya mengidentifikasi *Response* sebagai fitur terpenting, tetapi juga mengungkapkan mekanisme nonlinear spesifik yang digunakan model dalam memproses fitur tersebut, yaitu berupa transformasi berbasis ambang batas yang membedakan secara tajam antara pasien yang merespons terapi dengan baik dan yang tidak.

Fitur *Risk* dan *Age* dengan nilai SHAP masing-masing sebesar 0,060 dan 0,039 menampilkan kurva spline yang lebih sederhana namun tetap memiliki struktur yang jelas dan dapat diinterpretasikan. Kurva pada edge fitur *Risk* cenderung menampilkan pola yang mendekati fungsi linear atau sedikit kuadratik, mengindikasikan bahwa peningkatan tingkat risiko berkontribusi secara proporsional terhadap probabilitas rekurensi. Sementara itu, fitur *Age* menampilkan kurva dengan bentuk yang lebih kompleks dan tidak monoton, mengindikasikan adanya interaksi nonlinear antara usia pasien dengan kemungkinan rekurensi yang tidak dapat ditangkap oleh model linear sederhana. Fitur *M* dan *N* dengan nilai SHAP masing-masing 0,025 dan 0,023 menampilkan kurva dengan amplitudo yang lebih rendah, konsisten dengan kontribusi prediktifnya yang lebih terbatas dibandingkan tiga fitur teratas.

Fitur-fitur dengan peringkat SHAP rendah seperti *Gender*, *Smoking*, dan *Hx Radiotherapy* secara konsisten menampilkan kurva spline yang mendekati garis datar dengan amplitudo yang sangat rendah, mengonfirmasi bahwa kontribusi fitur-fitur tersebut terhadap prediksi model memang dapat diabaikan. Korespondensi yang kuat antara kompleksitas bentuk kurva spline KAN dan besaran nilai SHAP ini memberikan validasi silang yang meyakinkan antara dua metode interpretabilitas yang secara metodologis independen satu sama lain. Konvergensi hasil dari kedua pendekatan tersebut memperkuat reliabilitas penjelasan

model secara keseluruhan dan memberikan kepercayaan yang lebih tinggi terhadap proses pengambilan keputusan klinis berbasis model KAN dalam konteks prediksi rekurensi kanker tiroid diferensiasi, di mana transparansi dan interpretabilitas model merupakan prasyarat fundamental bagi penerapannya dalam praktik medis.

VI. KESIMPULAN

Penelitian ini menyimpulkan bahwa implementasi Kolmogorov-Arnold Networks (KAN) terbukti sangat efektif dan kompetitif dalam memprediksi tingkat keberhasilan pengobatan kanker tiroid berdiferensiasi. Model KAN berhasil mencapai performa yang luar biasa dengan akurasi sebesar 97,40%, precision 97,87%, recall 97,40%, F1-score 97,47%, dan nilai ROC-AUC mencapai 99,75%. Model ini juga menunjukkan tingkat sensitivitas yang baik dengan berhasil mengklasifikasikan seluruh data pasien pada kelas keberhasilan pengobatan ("Yes") secara tepat tanpa satu pun kesalahan klasifikasi pada evaluasi confusion matrix. Melalui penggabungan dengan metode interpretasi SHAP, penelitian ini berhasil mengidentifikasi bahwa fitur klinis *Response* (respons terapi) memiliki kontribusi paling dominan terhadap keputusan prediksi model, yang kemudian diikuti secara berurutan oleh faktor *Risk* (stratifikasi risiko), *Age* (usia), dan *M* (status metastasis).

Selain menghasilkan akurasi yang kompetitif, keunggulan utama dari pendekatan ini terletak pada transparansi dan dua lapis interpretabilitas yang baik dalam membedah alasan di balik sebuah keputusan klinis.

REFERENSI

- [1] P. van Houten, R. T. Netea-Maier, and J. W. Smit, "Differentiated thyroid carcinoma: An update," *Best Pract. Res. Clin. Endocrinol. Metab.*, vol. 37, no. 1, p. 101687, Jan. 2023, doi: 10.1016/j.beem.2022.101687.
- [2] A. Sanabria *et al.*, "Growing incidence of thyroid carcinoma in recent years: Factors underlying overdiagnosis," *Head Neck*, vol. 40, no. 4, pp. 855–

- 866, Apr. 2018, doi: 10.1002/hed.25029.
- [3] C. M. Kitahara and J. A. Sosa, "The changing incidence of thyroid cancer," *Nat. Rev. Endocrinol.*, vol. 12, no. 11, pp. 646–653, Nov. 2016, doi: 10.1038/nrendo.2016.110.
- [4] M. Schlumberger and S. Leboulleux, "Current practice in patients with differentiated thyroid cancer," *Nat. Rev. Endocrinol.*, vol. 17, no. 3, pp. 176–188, Mar. 2021, doi: 10.1038/s41574-020-00448-z.
- [5] L. Boucai, M. Zafereo, and M. E. Cabanillas, "Thyroid Cancer," *JAMA*, vol. 331, no. 5, p. 425, Feb. 2024, doi: 10.1001/jama.2023.26348.
- [6] A. Coca-Pelaz *et al.*, "Recurrent Differentiated Thyroid Cancer: The Current Treatment Options," *Cancers (Basel)*, vol. 15, no. 10, p. 2692, May 2023, doi: 10.3390/cancers15102692.
- [7] M. V. Wisescistiati, N. G. A. A. M. Yuniawaty Wetan, I. B. T. W. Manuaba, and P. A. T. Adiputra, "GAMBARAN PASIEN KARSINOMA TIROID BERDIFERENSIASI DI RSUP SANGLAH TAHUN 2015-2020," *E-Jurnal Medika Udayana*, vol. 11, no. 4, p. 76, Jul. 2022, doi: 10.24843/MU.2022.V11.i04.P13.
- [8] A. S. Harahap *et al.*, "Clinicopathological Profile of Thyroid Carcinoma in Young Patients: An Indonesian Single-Center Study," *J. Thyroid Res.*, vol. 2022, pp. 1–8, Jan. 2022, doi: 10.1155/2022/9944083.
- [9] Y. Azhar, D. Achmad, K. Lukman, and D. Hilmanto, "Pediatric Differentiated Thyroid Carcinoma Risk Factor For Analysis For Disease Free Survival," *Indian Journal of Medical and Paediatric Oncology*, vol. 39, no. 02, pp. 153–158, Apr. 2018, doi: 10.4103/ijmpo.ijmpo_70_17.
- [10] Y. Azhar, D. Achmad, K. Lukman, and D. Hilmanto, "Pediatric Differentiated Thyroid Carcinoma Risk Factor For Analysis For Disease Free Survival," *Indian Journal of Medical and Paediatric Oncology*, vol. 39, no. 02, pp. 153–158, Apr. 2018, doi: 10.4103/ijmpo.ijmpo_70_17.
- [11] M. Amit, Y. Rudnicki, Y. Binenbaum, L. Trejo-Leider, J. T. Cohen, and Z. Gil, "Defining the outcome of patients with delayed diagnosis of differentiated thyroid cancer," *Laryngoscope*, vol. 124, no. 12, pp. 2837–2840, Dec. 2014, doi: 10.1002/lary.24744.
- [12] S. A. Putri, Monty Priosodewo Soemitro, Basuki Hidayat, and Kharisma Perdani Kusumahstuti, "Prevalence and Analysis of Risk Factors for RAI-Refractory Thyroid Cancer Patients: A 5-Year Retrospective Analysis from a Single Institution in Indonesia," *Bioscientia Medicina : Journal of Biomedicine and Translational Research*, vol. 8, no. 11, pp. 5357–5367, Aug. 2024, doi: 10.37275/bsm.v8i11.1116.
- [13] S. Hamidi *et al.*, "Review article: new treatments for advanced differentiated thyroid cancers and potential mechanisms of drug resistance," *Front. Endocrinol. (Lausanne)*, vol. 14, Jun. 2023, doi: 10.3389/fendo.2023.1176731.
- [14] I. G. N. G. D. Aryanata, I. W. Sudarsa, and P. A. T. Adiputra, "Faktor-faktor yang mempengaruhi kualitas hidup pasien kanker tiroid berdiferensiasi baik (DTC) paska tiroidektomi total di Rumah Sakit Umum Pusat (RSUP) Sanglah, Denpasar," *Intisari Sains Medis*, vol. 10, no. 1, Apr. 2019, doi: 10.15562/ism.v10i1.379.
- [15] M. V. Wisescistiati, N. G. A. A. M. Yuniawaty Wetan, I. B. T. W. Manuaba, and P. A. T. Adiputra, "GAMBARAN PASIEN KARSINOMA TIROID BERDIFERENSIASI DI RSUP SANGLAH TAHUN 2015-2020," *E-Jurnal Medika Udayana*, vol. 11, no. 4, p. 76, Jul. 2022, doi: 10.24843/MU.2022.V11.i04.P13.
- [16] K. Arrumugam, N. P. Ekawati, and I. M. Gotra, "Characteristic of thyroid carcinoma based on age, sex and histology type at Sanglah General Hospital, Bali, Indonesia, 2016,"

- Intisari Sains Medis*, vol. 9, no. 3, Dec. 2018, doi: 10.15562/ism.v9i3.285.
- [17] A. Coca-Pelaz *et al.*, “Molecular Diagnostics and Personalized Therapeutics in Differentiated Thyroid Carcinoma: A Clinically Oriented Review,” *Diagnostics*, vol. 15, no. 19, p. 2493, Sep. 2025, doi: 10.3390/diagnostics15192493.
- [18] Y. Li, Q. Ye, Y. Chen, and X. Hu, “Thyroid Cancer: Pathogenesis, Clinicopathology, Diagnosis, and Management,” *MedComm (Beijing)*, vol. 6, no. 11, Nov. 2025, doi: 10.1002/mco2.70449.
- [19] A. Ryška *et al.*, “Molecular predictive biomarker testing in advanced thyroid cancer – a European consensus,” *Eur. Thyroid J.*, vol. 14, no. 4, Jun. 2025, doi: 10.1530/ETJ-25-0024.
- [20] S. Davis, T. M. Ullmann, and S. Roman, “Disparities in Treatment for Differentiated Thyroid Cancer,” *Thyroid®*, vol. 33, no. 3, pp. 287–293, Mar. 2023, doi: 10.1089/thy.2022.0432.
- [21] K. Agbedinu *et al.*, “A Scoping Review on Barriers to Cancer Diagnosis and Care in Low- and Middle-Income Countries,” *Cancer Epidemiology, Biomarkers & Prevention*, vol. 34, no. 7, pp. 1066–1073, Jul. 2025, doi: 10.1158/1055-9965.EPI-25-0120.
- [22] H. H. Huston-Paterson, Y. V. Mao, E. G. Hughes, I. Bobanga, J. X. Wu, and M. W. Yeh, “Closing the Distance: A Qualitative Study to Identify Equitable Innovations for Rural Thyroid Cancer Treatment,” *Am. Surg.*, vol. 91, no. 4, pp. 548–555, Apr. 2025, doi: 10.1177/00031348241307399.
- [23] A. Ryška *et al.*, “Molecular predictive biomarker testing in advanced thyroid cancer – a European consensus,” *Eur. Thyroid J.*, vol. 14, no. 4, Jun. 2025, doi: 10.1530/ETJ-25-0024.
- [24] C. de la Fouchardière *et al.*, “Improved guidance is needed to optimise diagnostics and treatment of patients with thyroid cancer in Europe,” *Endocrine*, vol. 83, no. 3, pp. 585–593, Nov. 2023, doi: 10.1007/s12020-023-03610-5.
- [25] D. Ceruti *et al.*, “Differentiated thyroid cancer in two European referral centres: impact of different diagnostic and therapeutic strategies,” *Eur. Thyroid J.*, vol. 14, no. 4, Jul. 2025, doi: 10.1530/ETJ-25-0161.
- [26] A. M. Avram, K. Zukotynski, H. R. Nadel, and L. Giovanella, “Management of Differentiated Thyroid Cancer: The Standard of Care,” *Journal of Nuclear Medicine*, vol. 63, no. 2, pp. 189–195, Feb. 2022, doi: 10.2967/jnumed.121.262402.
- [27] M. Klain *et al.*, “Long-Term Prognostic Value of the Response to Therapy Assessed by Laboratory and Imaging Findings in Patients with Differentiated Thyroid Cancer,” *Cancers (Basel)*, vol. 13, no. 17, p. 4338, Aug. 2021, doi: 10.3390/cancers13174338.
- [28] A. M. Avram, K. Zukotynski, H. R. Nadel, and L. Giovanella, “Management of Differentiated Thyroid Cancer: The Standard of Care,” *Journal of Nuclear Medicine*, vol. 63, no. 2, pp. 189–195, Feb. 2022, doi: 10.2967/jnumed.121.262402.
- [29] M. D. Ringel *et al.*, “2025 American Thyroid Association Management Guidelines for Adult Patients with Differentiated Thyroid Cancer,” *Thyroid®*, vol. 35, no. 8, pp. 841–985, Aug. 2025, doi: 10.1177/10507256251363120.
- [30] R. Sa, T. Yang, Z. Zhang, and F. Guan, “Random Forest for Predicting Treatment Response to Radioiodine and Thyrotropin Suppression Therapy in Patients With Differentiated Thyroid Cancer But Without Structural Disease,” *Oncologist*, vol. 29, no. 1, pp. e68–e80, Jan. 2024, doi: 10.1093/oncolo/oyad252.
- [31] A. Abd-Alrazaq *et al.*, “Artificial Intelligence for Predicting Responses to Thyroid Cancer Treatment,” 2024, pp. 248–260. doi: 10.1007/978-3-031-67285-9_18.
- [32] A. Schindele *et al.*, “Interpretable machine learning for thyroid cancer

- recurrence prediction: Leveraging XGBoost and SHAP analysis,” *Eur. J. Radiol.*, vol. 186, p. 112049, May 2025, doi: 10.1016/j.ejrad.2025.112049.
- [33] A. Redlich, E. Pfähler, M. Kunstreich, M. Schmutz, C. Lapa, and M. Kuhlen, “Machine Learning Prediction of Recurrence in Pediatric Thyroid Cancer: Malignant Endocrine Tumors Cohort Analysis Using XGBoost and SHAP,” *J. Clin. Endocrinol. Metab.*, vol. 111, no. 3, pp. e844–e852, Feb. 2026, doi: 10.1210/clinem/dgaf487.
- [34] A. A. Hanani, T. B. Donmez, M. Kutlu, and M. Mansour, “Predicting thyroid cancer recurrence using supervised CatBoost: A SHAP-based explainable AI approach,” *Medicine*, vol. 104, no. 22, p. e42667, May 2025, doi: 10.1097/MD.0000000000042667.
- [35] F. Hou *et al.*, “Development and validation of an interpretable machine learning model for predicting the risk of distant metastasis in papillary thyroid cancer: a multicenter study,” *EClinicalMedicine*, vol. 77, p. 102913, Nov. 2024, doi: 10.1016/j.eclinm.2024.102913.
- [36] K. Zhong *et al.*, “Interpretable Disease Prediction Based on Kolmogorov - Arnold Networks,” in *2024 IEEE International Conference on Medical Artificial Intelligence (MedAI)*, IEEE, Nov. 2024, pp. 645–650. doi: 10.1109/MedAI62885.2024.00090.
- [37] E. ŞAHİN, N. N. Arslan, and D. Özdemir, “Unlocking the black box: an in-depth review on interpretability, explainability, and reliability in deep learning,” *Neural Comput. Appl.*, vol. 37, no. 2, pp. 859–965, Jan. 2025, doi: 10.1007/s00521-024-10437-2.
- [38] S. Oka and Y. Takefuji, “Complementing interpretable machine learning with synergistic analytical strategies for thyroid cancer recurrence prediction,” *Eur. J. Radiol.*, vol. 191, p. 112308, Oct. 2025, doi: 10.1016/j.ejrad.2025.112308.
- [39] D. Guo *et al.*, “Optimizing C-TIRADS for sub-centimeter thyroid nodules using machine learning–derived feature importance,” *Front. Endocrinol. (Lausanne)*, vol. 16, Sep. 2025, doi: 10.3389/fendo.2025.1668347.
- [40] M. Frasca, D. La Torre, G. Pravettoni, and I. Cutica, “Explainable and interpretable artificial intelligence in medicine: a systematic bibliometric review,” *Discover Artificial Intelligence*, vol. 4, no. 1, p. 15, Feb. 2024, doi: 10.1007/s44163-024-00114-7.
- [41] G. Hu *et al.*, “Machine learning prediction of thyroid cancer recurrence for early screening and clinical decision pathways: a retrospective cohort study,” *Discover Oncology*, vol. 17, no. 1, p. 239, Jan. 2026, doi: 10.1007/s12672-025-04293-2.
- [42] W. Knottenbelt *et al.*, “CoxKAN: Kolmogorov-Arnold networks for interpretable, high-performance survival analysis,” *Bioinformatics*, vol. 41, no. 8, Aug. 2025, doi: 10.1093/bioinformatics/btaf413.
- [43] K. Rasheed, A. Qayyum, M. Ghaly, A. Al-Fuqaha, A. Razi, and J. Qadir, “Explainable, Trustworthy, and Ethical Machine Learning for Healthcare: A Survey,” Apr. 09, 2021. doi: 10.36227/techrxiv.14376179.v1.
- [44] C. Rudin, “Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead,” *Nat. Mach. Intell.*, vol. 1, no. 5, pp. 206–215, May 2019, doi: 10.1038/s42256-019-0048-x.
- [45] R. Marcinkevičs and J. E. Vogt, “Interpretable and explainable machine learning: A methods-centric overview with concrete examples,” *WIREs Data Mining and Knowledge Discovery*, vol. 13, no. 3, May 2023, doi: 10.1002/widm.1493.
- [46] S. Somvanshi, S. A. Javed, M. M. Islam, D. Pandit, and S. Das, “A Survey on Kolmogorov-Arnold Network,” *ACM Comput. Surv.*, vol. 58, no. 2, pp. 1–35, Jan. 2026, doi: 10.1145/3743128.
- [47] A. Schindele *et al.*, “Interpretable machine learning for thyroid cancer recurrence prediction: Leveraging XGBoost and SHAP analysis,” *Eur. J.*

- Radiol.*, vol. 186, p. 112049, May 2025, doi: 10.1016/j.ejrad.2025.112049.
- [48] L. G. Feb *et al.*, “KAN : Kolmogorov – Arnold Networks,” pp. 1–50, 2025.
- [49] M. R. Baidillah *et al.*, “Hybrid Kolmogorov-Arnold and convolutional neural network model for single-lead electrocardiogram classification,” vol. 23, no. 5, pp. 1342–1352, 2025, doi: 10.12928/TELKOMNIKA.v23i5.2673 5.
- [50] S. Somvanshi, S. A. Javed, D. Pandit, and S. Das, “A Survey on Kolmogorov-Arnold Network,” vol. 58, no. 2, 2025.
- [51] A. N. Sahid and D. R. Fauzi, “A Deep Learning Method for Forest Fire Classification Using Convolutional Kolmogorov-Arnold Network,” vol. 2, no. 1, pp. 30–37, 2026.
- [52] M. Kiamari, “GKAN : Graph Kolmogorov-Arnold Networks,” no. 2017, 2018.
- [53] H. Wang, Q. Liang, J. T. Hancock, and T. M. Khoshgoftaar, “Feature selection strategies : a comparative analysis of SHAP - value and importance - based methods,” *J. Big Data*, 2024, doi: 10.1186/s40537-024-00905-w.
- [54] E. Mosca, S. Tragianni, D. Gallagher, and G. Groh, “SHAP-Based Explanation Methods : A Review for NLP Interpretability,” pp. 4593–4603, 2022.
- [55] M. T. Syamkalla, S. Khomsah, Y. Setiya, and R. Nur, “IMPLEMENTASI ALGORITMA CATBOOST DAN SHAPLEY ADDITIVE EXPLANATIONS (SHAP) DALAM MEMPREDIKSI POPULARITAS GAME INDIE PADA PLATFORM STEAM IMPLEMENTATION OF CATBOOST AND SHAPLEY ADDITIVE EXPLANATIONS (SHAP) ALGORITHMS IN PREDICTING THE POPULARITY OF INDIE ,” vol. 11, no. 4, 2024, doi: 10.25126/jtiik.1148503.
- [56] R. Fitriansyah and A. F. Baihaqi, “Perbandingan Kinerja Algoritma Machine Learning Logistic Regression dan XGBoost dalam Memprediksi Gangguan Tidur dengan Analisis SHAP,” *Jurnal Informatika dan Multimedia*, vol. 17, no. 2, pp. 66–77, 2025, doi: 10.33795/jtim.v17i2.8661.
- [57] S. Borzooei, G. Briganti, M. Golparian, J. R. Lechien, and A. Tarokhian, “Machine learning for risk stratification of thyroid cancer patients: a 15-year cohort study,” *European Archives of Oto-Rhino-Laryngology*, vol. 281, no. 4, pp. 2095–2104, Apr. 2024, doi: 10.1007/s00405-023-08299-w.
- [58] Ş. Yaşar, “Determination of Possible Biomarkers for Predicting Well-Differentiated Thyroid Cancer Recurrence by Different Ensemble Machine Learning Methods,” *Middle Black Sea Journal of Health Science*, vol. 10, no. 3, pp. 255–265, Aug. 2024, doi: 10.19127/mbsjohs.1498383.
- [59] E. Onah, U. J. Eze, A. S. Abdulaheem, U. G. Ezigbo, K. C. Amorha, and F. Ntie-Kang, “Optimizing unsupervised feature engineering and classification pipelines for differentiated thyroid cancer recurrence prediction,” *BMC Med. Inform. Decis. Mak.*, vol. 25, no. 1, p. 182, May 2025, doi: 10.1186/s12911-025-03018-3.
- [60] A. C. Öztürk, E. Akkur, and S. Çizmeciogullari, “Predicting recurrence of differentiated thyroid cancer with an explainable artificial intelligence model,” *Archives of Current Medical Research*, vol. 6, no. 3, pp. 280–287, Sep. 2025, doi: 10.47482/acmr.1677545.