

KLASIFIKASI PERULANGAN KANKER TIROID MENGUNAKAN STACK ENSEMBLE DAN SMOTE

Endin Rahmanda Putri, Dwi Arman Prasetya, Achmad Junaidi
Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur
Jalan Raya Rungkut Madya Gunung Anyar Surabaya, Indonesia
20081010070@student.upnjatim.ac.id

ABSTRAK

Kanker tiroid berdiferensiasi (Differentiated Thyroid Cancer/DTC) memiliki tingkat perulangan sekitar 20%, sehingga identifikasi sejak dini menjadi krusial untuk intervensi dan rencana perawatan terhadap kekambuhan. Penelitian ini menggunakan dataset dari UCI Machine Learning Repository yang berisi 17 atribut klinis pasien dengan proporsi data latih dan uji 80:20. Untuk menangani ketidakseimbangan kelas, diterapkan Synthetic Minority Over-sampling Technique (SMOTE). Model Decision Tree, Support Vector Machine (SVM), dan Logistic Regression digunakan sebagai base learner, sementara meta learner dipilih dari salah satu algoritma tersebut untuk membentuk Stack Ensemble Learning. Decision Tree adalah model paling stabil, dengan akurasi 97% baik sebagai model tunggal, dengan SMOTE, maupun sebagai meta learner dalam Stack Ensemble. SVM memiliki akurasi 83% pada dataset asli, yang meningkat menjadi 94% setelah diterapkan SMOTE. Logistic Regression menunjukkan akurasi 96% di semua skenario. Stack Ensemble dengan meta learning Decision Tree dan Logistic Regression mempertahankan akurasi 97%, sedangkan SVM sebagai meta learner menunjukkan penurunan AUC. Analisis kurva ROC (Receiver Operating Characteristics) menunjukkan bahwa Stack Ensemble dan SMOTE meningkatkan AUC untuk Logistic Regression dan Decision Tree, namun SVM sebagai meta learner dengan dataset SMOTE mengalami penurunan performa dengan nilai terendah 0,94. Hasil ini membuktikan bahwa kombinasi Stack Ensemble dan SMOTE efektif dalam menangani ketidakseimbangan data pada dataset *Differentiated Thyroid Cancer Recurrence*.

Kata kunci : *Stack Ensemble Learning, SMOTE, Differentiated Thyroid Cancer, One-Hot Encoding, Hyperparameter tuning*

1. PENDAHULUAN

Berdasarkan data dari The Global Center Observatory, pada tahun 2020 tercatat 19,3 juta kasus kanker baru dengan sekitar 10 juta kematian [1]. Salah satu jenis kanker yang cukup umum adalah kanker tiroid, yang menempati peringkat kesembilan dalam insidensi global dengan 586.000 kasus [2]. Kanker tiroid adalah jenis kanker yang menyerang kelenjar tiroid, sebuah kelenjar yang memiliki bentuk menyerupai kupu-kupu dengan lobus kanan dan kiri yang dihubungkan oleh bagian sempit kelenjar yang disebut isthmus, struktur ini terletak di depan trakea (saluran pernafasan) [3] [4]. Kanker tiroid mengenai dua jenis sel utama, yaitu sel folikel tiroid yang dapat berkembang menjadi kanker tiroid berdiferensiasi (Differentiated Thyroid Cancer / DTC) dan sel parafolikuler tiroid atau sel C yang dapat berkembang menjadi karsinoma tiroid meduler atau Medullary Thyroid Carcinoma (MTC) [5]. Kanker tiroid berdiferensiasi (Differentiated Thyroid Cancer / DTC) sendiri merupakan penyumbang terbesar, mencakup 95% dari seluruh kasus kanker tiroid [6]. Oleh karena itu, deteksi dini sangat penting untuk dapat membantu tenaga kesehatan untuk mempertimbangan pasien yang membutuhkan perawatan intensif guna meminimalkan munculnya kembali kanker [7] [8]. Memprediksi pengulangan kanker tiroid pada penyintas merupakan langkah yang sangat krusial, karena dengan deteksi dini, rekurensi dapat diidentifikasi sebelum gejala lebih lanjut muncul.

Salah satu metode Machine Learning yang dapat digunakan untuk klasifikasi adalah Ensemble Learning, yang meningkatkan akurasi dengan menggabungkan beberapa model menjadi satu output yang lebih optimal. Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk meningkatkan akurasi pada klasifikasi perulangan kanker tiroid dengan menerapkan Stack Ensemble dan optimasi SMOTE untuk menangani ketidakseimbangan data. Penelitian ini mengevaluasi performa Decision Tree, SVM, dan Logistic Regression sebagai base learner, serta menentukan meta learner terbaik guna mengoptimalkan hasil klasifikasi. Hasil evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score untuk menilai efektivitas pendekatan yang digunakan.

2. TINJAUAN PUSTAKA

2.1. Synthetic Minority Oversampling Technique (SMOTE)

Synthetic Minority Over-sampling Technique adalah salah satu teknik *oversampling* yang digunakan untuk mengatasi ketidakseimbangan kelas pada dataset. Teknik ini diperkenalkan oleh Chawla dalam Journal of Artificial Intelligence pada tahun 2002 [9]. Inti dari SMOTE adalah meningkatkan kelas minoritas dengan menghasilkan sampel sintetis daripada hanya menduplikasi yang sudah ada, sehingga mengurangi risiko *overfitting* pada classifier [10]. Persamaan dari SMOTE sebagai berikut.

$$X_{syn} = X_i + \delta (X_j - X_i) \quad (1)$$

Rumus ini menjelaskan :

- X_{syn} = data sintetis yang akan dibuat
- X_i = data yang akan direplikasi
- X_j = data yang memiliki jarak terdekat dari data yang akan direplikasi
- δ = nilai random antara 0 dan 1

2.2. Decision Tree

Tahapan pertama dalam membangun Decision Tree adalah menentukan atribut yang akan dijadikan root node dengan cara menghitung Information Gain dari masing-masing atribut. Atribut dengan nilai Information Gain tertinggi akan dipilih sebagai akar pertama. Information Gain dihitung menggunakan persamaan berikut :

$$IG = Entropy(N) - \sum \frac{|N_i|}{|N|} Entropy(N_i) \quad (3)$$

Dimana :

- N = himpunan kasus
- p = jumlah partisi berdasarkan atribut A
- A = atribut yang digunakan untuk split
- $|N_i|$ = jumlah kasus pada partisi ke- i
- $|N|$ = jumlah total kasus dalam N

Setelah mendapatkan nilai gain, penentuan entropi dan nilai gain diulang pada semua atribut.

2.3. Support Vector Machine (SVM)

Algoritma Support Vector Machine (SVM) adalah model machine learning yang efektif untuk membagi data yang nonlinear dan berdimensi tinggi [12]. SVM berusaha menemukan hyperplane optimal yang memaksimalkan margin, yaitu jarak antara hyperplane dengan support vector (data yang berada tepat di batas margin). Data yang berada di sisi positif hyperplane memiliki label +1, sedangkan data di sisi negatif hyperplane memiliki label -1. Hyperplane dihitung melalui persamaan sebagai berikut [13] :

$$w \cdot x + b = 0 \quad (4)$$

Dimana :

- w = vektor bobot yang menentukan orientasi hyperplane
- x = vektor fitur dari data
- b = bias yang menentukan posisi hyperplane relatif terhadap asal koordinat

Penggunaan kernel pada SVM bertujuan untuk mengubah data menjadi ruang berdimensi tinggi sehingga dapat dipisahkan secara linear. Salah satu kernel tersebut adalah *Radial Basis Function* (RBF), yang dihitung dengan persamaan :

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (5)$$

Dimana :

- $x_i - x_j$ = vektor fitur dari dua sampel data
- $\|x_i - x_j\|^2$ = vektor fitur dari data
- γ = parameter yang mengontrol seberapa jauh pengaruh satu sampel terhadap yang lain

2.4. Logistic Regression

Regresi Logistik menggunakan fungsi logistik untuk mengubah output dari persamaan linier menjadi nilai antara 0 dan 1. Selain itu, regresi ini juga menetapkan hubungan antara satu variabel dependen biner dan satu atau lebih variabel independen. Regresi Logistik tidak mengharuskan hubungan linier antara variabel dependen dan independen. Sebaliknya, model ini menggunakan fungsi sigmoid untuk memetakan hubungan non-linear antara input dan probabilitas keluaran. Persamaan Logistic Regression diketahui melalui persamaan berikut.


$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (6)$$

Dimana :

- z = kombinasi linier dari variabel independen.
- $\sigma(z)$ = probabilitas bahwa sampel termasuk dalam kelas positif ($y=1$)
- e = bilangan eksponensial untuk menghitung nilai probabilitas.

2.5. Stack Ensemble Learning

Stack Ensemble merupakan salah satu model machine learning yang menggabungkan prediksi dari beberapa model dasar (base learner atau base model) dan meta model [14].



Gambar 1. Stack ensemble learning

Base learner terdiri dari beberapa algoritma tunggal yang membuat prediksi awal, yang kemudian digunakan sebagai input bagi meta learner untuk menghasilkan keputusan akhir [15]. Meta learner berfungsi sebagai "pembelajar tingkat kedua" yang mengolah hasil base learner untuk mengurangi bias dan meningkatkan performa model [16]

2.6. Confusion Matrix

Confusion matrix adalah sebuah metode evaluasi yang dirancang dalam bentuk tabel untuk membantu memvisualisasikan kinerja algoritma klasifikasi. Confusion matrix dapat digunakan sebagai acuan untuk menghitung nilai accuracy, precision, recall, dan F-1 Score yang dihitung berdasarkan nilai pada TP, TN, FP, dan FN. Dari hasil proses klasifikasi pada confusion matrix, dihitung tiap nilai dengan accuracy, precision, recall dan F-1 score.

- Akurasi menggambarkan seberapa akurat model yang digunakan dalam klasifikasi

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

- Recall (Sensitivity) mengukur seberapa baik model dalam identifikasi kelas positif

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

- Precision mengukur proporsi positif yang benar terhadap semua prediksi positif


$$Precision = \frac{TP}{TP + FP} \quad (9)$$

- F1-Score adalah rata-rata harmonik dari precision dan recall, yang memberikan keseimbangan antara keduanya.

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (10)$$

3. METODE PENELITIAN

Pada penelitian ini mengevaluasi kinerja Stack Ensemble Learning dan SMOTE terhadap dataset prediksi kekambuhan kanker tiroid.



Gambar 2. Alur penelitian

Pada penelitian ini menggunakan dataset bernama *Differentiated Thyroid Cancer Recurrence* dari repository UCI Machine Learning.

3.1. PENGUMPULAN DATASET


Data yang dipakai adalah data yang digunakan berasal dari dataset UCI Machine Learning “Differentiated Thyroid Cancer Recurrence” yang berisi 13 atribut riwayat klinis dan pengulangan kanker tiroid pada penyintas. Data ini dikumpulkan dalam 15 tahun, dimana sejumlah 383 pasien diikuti setidaknya selama 10 tahun. Fitur-fitur dalam dataset ini mencakup informasi yang relevan tentang karakteristik kanker dan pasien, yang dapat membantu dalam mengidentifikasi pola dan faktor risiko yang berkontribusi terhadap pengulangan penyakit [17].

3.2. Preprocessing

Pada penelitian ini, dilakukan proses pelabelan data menggunakan one-hot encoding untuk mengkonversi nilai kategorik menjadi numerik, sehingga menghindari masalah interpretasi dalam model machine learning. Dataset kemudian dibagi menjadi fitur (X) sebagai variabel independen dan target (y) sebagai variabel dependen yang ingin diprediksi. Selanjutnya, dataset dibagi menjadi 80% data latih dan 20% data uji untuk memastikan model dapat dievaluasi secara efektif terhadap data yang tidak terlihat sebelumnya.

3.3. SMOTE

Distribusi kelas target menunjukkan adanya ketidakseimbangan data, di mana jumlah sampel pada kelas Not Recurred menjadi kelas mayoritas. Hal ini dapat menyebabkan model cenderung lebih bias terhadap kelas mayoritas dan kurang mampu mengenali pola pada kelas minoritas, yang berpotensi menurunkan performa klasifikasi.



Gambar 3. Distribusi kelas pada data latih

SMOTE sebagai metode oversampling yang dirancang untuk menangani ketidakseimbangan kelas dengan cara menciptakan contoh sintetik baru dari kelas minoritas, sehingga diharapkan dengan penerapan SMOTE dapat meningkatkan data minoritas pada data latih.

3.4. Implementasi

Setiap masing-masing dari algoritma base learning akan diuji menggunakan parameter yang berbeda untuk mencapai kombinasi parameter dengan performa yang optimal. Kemudian Setiap dataset, baik dataset latih asli maupun dataset dengan optimasi SMOTE akan diuji pada model yang berbeda. Model pertama adalah masing-masing algoritma tunggal, yaitu Decision Tree, SVM, dan Logistic Regression. Pada Stack Ensemble, akan menggunakan Decision Tree, SVM, dan Logistic Regression sebagai base model, sementara meta learning akan diuji dengan setiap algoritma tunggal.

3.5. Evaluasi

Evaluasi setiap model mencakup Accuracy, Precision, Recall, dan F1-Score. Evaluasi ini dilakukan untuk membandingkan performa model pada dataset asli dan dataset yang telah dioptimasi menggunakan SMOTE, serta mengidentifikasi konfigurasi terbaik pada base learners dan meta learner dalam Stack Ensemble Learning.

4. HASIL DAN PEMBAHASAN

Dataset dibagi menjadi 2 kolom yaitu kolom fitur dan target. Fitur merupakan variabel untuk melakukan klasifikasi, sementara target adalah variabel yang ingin

diprediksi. Setelah itu data dibagi menjadi 20% data uji dan 80% data latih, distribusi seperti pada tabel berikut.

Tabel 1. Perbandingan distribusi kolom target


Target	Not Recurred (0)	Recurred (1)	Total Data
Data asli (y)	275	108	383
Data testing (y_test)	58	19	77
Data latih (y_train)	217	89	306
Data latih SMOTE (y_train_SMOTE)	217	217	434

Hypertuning parameter diterapkan pada setiap parameter, performa ditentukan melalui kombinasi parameter dengan akurasi tertinggi, sehingga didapatkan kombinasi parameter dengan akurasi paling optimal sebagai berikut pada tabel 2.

Tabel 2. Hasil Hypertuning Parameter

Algoritma	Parameter	Nilai parameter	Akurasi
Decision Tree	criterion	entropy	0,951084
	max depth	3	
SVM	kernel	rbf	0,751507
	C	3	
Logistic Regression	solver	liblinear	0,9346348
	penalty	l1	
	C	0,1	

Terdapat 4 skenario implementasi model. Skenario pertama algoritma pada base learning dijalankan sebagai model tunggal menggunakan dataset asli tanpa *oversampling*. Pada skenario kedua, model dijalankan pada dataset dengan *SMOTE*. Pada skenario ketiga menggunakan stack ensemble dengan meta learning yang berbeda menggunakan dataset asli tanpa *oversampling*. Pada skenario terakhir, setiap model stack ensemble akan dijalankan pada dataset dengan *SMOTE*.



Gambar 4. Perbandingan akurasi per skenario

Decision Tree sebagai algoritma tunggal sudah memiliki nilai akurasi yang cukup tinggi dan tetap stabil dengan optimasi dan sebagai meta learning. Sementara Logistic Regression meningkat secara bertahap dan konsisten. SVM, meskipun sebagai model tunggal memiliki akurasi awal yang rendah

walaupun telah melalui *hyperparameter tuning*, menunjukkan peningkatan signifikan setelah optimasi SMOTE. SVM sebagai meta learning akhirnya menyamai performa dua model lainnya setelah skenario terakhir dengan akurasi 97.40%. Oleh karena itu, dalam hal peningkatan performa setelah optimasi, SVM menunjukkan potensi yang baik sebagai model tunggal maupun sebagai meta learning, dan Decision Tree tetap menjadi model yang seimbang dengan performa yang konsisten.

Tabel 3. Evaluasi pada dataset asli (y_train)

Model	Presisi	Recall	F1-Score	Accuracy
Decision Tree	1,00	0,89	0,94	0,97
Support Vector Machine	1,00	0,31	0,48	0,83
Logistic Regression	1,00	0,84	0,91	0,96
Stack Ensemble Meta learning Decision Tree	1,00	0,84	0,94	0,97
Stack Ensemble Meta learning Support Vector Machine	1,00	0,89	0,94	0,97
Stack Ensemble Meta learning Logistic Regression	1,00	0,89	0,94	0,97


Decision Tree memiliki Precision 1,00, Recall 0,89, dan F1-Score 0,94, dengan Accuracy 0,97, menunjukkan keseimbangan dalam klasifikasi. SVM memiliki Precision 1,00, tetapi Recall rendah (0,31), menyebabkan F1-Score turun menjadi 0,48 dengan Accuracy 0,83, yang menunjukkan banyak kasus positif yang terlewat. Logistic Regression memiliki performa lebih baik, dengan Precision 1,00, Recall 0,84, F1-Score 0,91, dan Accuracy 0,96. Pada Stack Ensemble Learning, Meta Learner Decision Tree menunjukkan F1-Score 0,94 dan Accuracy 0,97, sedikit meningkat dibandingkan Logistic Regression. Meta Learner SVM dan Logistic Regression memiliki peningkatan Recall menjadi 0,89, menghasilkan F1-Score 0,94 dan Accuracy 0,97, menunjukkan performa terbaik dalam klasifikasi. Dengan demikian, Stack Ensemble Learning meningkatkan performa SVM secara signifikan dan mempertahankan performa Decision Tree dan Logistic Regression pada level optimal.

Tabel 4. Evaluasi pada dataset SMOTE (y_train_SMOTE)

Model	Presisi	Recall	F1-Score	Accuracy
Decision Tree	1,00	0,89	0,94	0,97
Support Vector Machine	0,94	0,84	0,88	0,94

Model	Precisi	Recall	F1-Score	Accuracy
Logistic Regression	0.90	0.94	0.92	0.96
Stack Ensemble Meta learning Decision Tree	1.00	0.89	0.94	0.97
Stack Ensemble Meta learning Support Vector Machine	1.00	0.89	0.94	0.97
Stack Ensemble Meta learning Logistic Regression	1.00	0.89	0.94	0.97

Pada pengujian menggunakan data SMOTE, Decision Tree menunjukkan Precision sempurna (1,00) dengan Recall 0,89, menghasilkan F1-Score 0,94 dan Accuracy 0,97, yang menunjukkan peningkatan dibandingkan tanpa SMOTE. SVM mengalami penyesuaian, di mana Precision turun menjadi 0,94, tetapi Recall meningkat signifikan menjadi 0,84, sehingga F1-Score naik ke 0,88 dengan Accuracy 0,94, menunjukkan bahwa SMOTE membantu dalam menangkap lebih banyak kasus positif yang sebelumnya terlewat. Logistic Regression mengalami peningkatan performa, dengan Precision 0,90, Recall 0,94, F1-Score 0,92, dan Accuracy 0,96, yang lebih baik dibandingkan sebelum penerapan SMOTE. Pada Stack Ensemble Learning, semua kombinasi meta learner (Decision Tree, SVM, dan Logistic Regression) menghasilkan performa yang sama, yaitu Precision 1,00, Recall 0,89, F1-Score 0,94, dan Accuracy 0,97. Hasil ini menunjukkan bahwa penerapan SMOTE meningkatkan kinerja model tunggal, terutama dalam Recall, serta Stack Ensemble Learning tetap konsisten dalam mempertahankan performa optimal, menjadikannya metode yang andal dalam klasifikasi kekambuhan kanker tiroid berdiferensiasi.



Gambar 5. ROC Curve Stack Ensemble

Hasil kurva ROC pada model stack ensemble menunjukkan bahwa Logistic Regression memiliki AUC sebesar 1.00, Decision Tree mencapai AUC 0.99, sedangkan SVM memiliki nilai paling rendah dibandingkan dua model lainnya, dengan AUC 0.94, yang tetap menunjukkan kemampuan klasifikasi yang baik, tetapi tidak seoptimal Logistic Regression atau Decision Tree.

5. KESIMPULAN DAN SARAN

Pada penelitian ini, pendekatan Stack Ensemble Learning terbukti lebih unggul dibandingkan model individu, terutama dalam menjaga keseimbangan antara presisi dan recall, serta memberikan generalisasi yang lebih baik terhadap data. Secara keseluruhan, kombinasi SMOTE untuk menangani ketidakseimbangan kelas dan Stack Ensemble Learning sebagai metode klasifikasi menghasilkan model dengan performa optimal, yang mampu mencapai akurasi tinggi dan stabil dengan nilai 97,4% untuk semua meta learning yang digunakan. Selain itu, nilai AUC tertinggi (1.00) diperoleh oleh meta learning Logistic Regression, menunjukkan bahwa model ini memiliki kemampuan klasifikasi yang sangat baik.

DAFTAR PUSTAKA

- [1] H. Sung et al., "Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries," *CA: a Cancer Journal for Clinicians*, vol. 71, no. 3, pp. 209–249, Feb. 2021, doi: <https://doi.org/10.3322/caac.21660>.
- [2] J. B. Shank, C. Are, and C. D. Wenos, "Thyroid Cancer: Global Burden and Trends," *Indian Journal of Surgical Oncology*, vol. 13, no. 1, pp. 40–45, Sep. 2021, doi: <https://doi.org/10.1007/s13193-021-01429-y>.
- [3] Arif Fatahillah, Miftahul Jannah, Susi Setiawani, T. B. Setiawan, and Arika Indah Kristiana, "Numerical Analysis of Airflow in Trachea Affected by Thyroid Cancer Using Finite Volume Method," *CAUCHY Jurnal Matematika Murni dan Aplikasi*, vol. 9, no. 1, pp. 82–93, May 2024, doi: <https://doi.org/10.18860/ca.v9i1.24376>.
- [4] A. Avagliano et al., "Thyroid Cancer and Fibroblasts," *Cancers*, vol. 14, no. 17, pp. 4172–4172, Aug. 2022, doi: <https://doi.org/10.3390/cancers14174172>.
- [5] N. A. B. A. Amir, H. N. Kasprata, P. D. Priyahita, and T. Syahla, "Clinical Diagnosis and Management of Thyroid Cancer," *Jurnal kedokteran/Jurnal Kedokteran*, vol. 12, no. 3, pp. 240–246, Oct. 2023, doi: <https://doi.org/10.29303/jku.v12i3.963>.
- [6] Y. Liu, Y. Wang, and W. Zhang, "Scoring system and a simple nomogram for predicting radioiodine refractory differentiated thyroid cancer: a retrospective study," *EJNMMI*

- Research, vol. 12, no. 1, Jul. 2022, doi: <https://doi.org/10.1186/s13550-022-00917-8>.
- [7] 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: <https://doi.org/10.19127/mbsjohs.1498383>.
- [8] S. Alkilany et al., "Recurrence Risk in Thyroid Cancer Patients after Thyroidectomy," *Minia Journal of Medical Research*, vol. 0, no. 0, Dec. 2023, doi: <https://doi.org/10.21608/mjmr.2023.237786.1559>.
- [9] D. Lv, Z. Ma, S. Yang, X. Li, Z. Ma, and F. Jiang, "The Application of SMOTE Algorithm for Unbalanced Data," *Proceedings of the 2018 International Conference on Artificial Intelligence and Virtual Reality*, pp. 10–13, Nov. 2018, doi: <https://doi.org/10.1145/3293663.3293686>.
- [10] E. Akkur, S. Cizmeciogullari, and A. C. Öztürk, "Prediction of Recurrence of Differentiated Thyroid Cancer with Hybrid SMOTE-Stacking Model," *International Trend of Tech Symposium Proceedings*, pp. 33–37, Dec. 2024, doi: <https://doi.org/10.36287/sets.21.6.033>.
- [11] D. E. Sinaga, A. P. Windarto, and R. A. Nasution, "Analisis Data Mining Algoritma Decision Tree Pada Prediksi Persediaan Obat (Studi Kasus : Apotek Franch Farma)," *Kajian Ilmiah Informatika dan Komputer*, vol. 2, no. 4, pp. 123–131, Feb. 2022, doi: <https://doi.org/10.30865/klik.v2i4.328>.
- [12] M. Faruqziddan, E. H. S. Aulia, S. D. Azzahra, and P. B. Utomo, "View of Perbandingan Skenario Balancing Oversampling dan Undersampling dalam Klasifikasi Resiko Kambuh Kanker Tiroid menggunakan Algoritma SVM Linear," *Akb.ac.id*, Dec. 02, 2024. <https://journal.akb.ac.id/index.php/jami/article/view/320/129> (accessed Feb. 20, 2025).
- [13] M. A. Chandra and S. S. Bedi, "Survey on SVM and their application in image classification," *International Journal of Information Technology*, vol. 13, Jan. 2018, doi: <https://doi.org/10.1007/s41870-017-0080-1>.
- [14] CH. Bhavani and A. Govardhan, "Cervical cancer prediction using stacked ensemble algorithm with SMOTE and RFERF," *Materials Today: Proceedings*, Jul. 2021, doi: <https://doi.org/10.1016/j.matpr.2021.07.269>.
- [15] Nurfia Oktaviani Syamsiah and Indah Purwandani, "Penerapan Metode Stacking Untuk Meningkatkan Akurasi Hasil Peramalan Konsumsi Listrik," *Journal of System and Computer Engineering*, vol. 4, no. 1, pp. 15–25, Jan. 2023, doi: <https://doi.org/10.47650/jsce.v4i1.665>.
- [16] S. Zian, S. A. Kareem, and K. D. Varathan, "An Empirical Evaluation of Stacked Ensembles With Different Meta-Learners in Imbalanced Classification," *IEEE Access*, vol. 9, pp. 87434–87452, 2021, doi: <https://doi.org/10.1109/access.2021.3088414>.
- [17] S. Borzooei and A. Tarokhian, "Differentiated Thyroid Cancer Recurrence," *UCI Machine Learning Repository*, 2023, doi: <https://doi.org/10.24432/C5632J>.