

Komparasi Algoritma Machine Learning pada Prediksi Kemenangan Tim VALORANT Berbasis Delta Analysis

Comparison of Machine Learning Algorithms for VALORANT Team Win Prediction Based on Delta Analysis

Bintang Ilham Kurniawan, Sri Winarno*

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Semarang, Indonesia

Email: ¹111202214399@mhs.dinus.ac.id, ^{2*}sri.winarno@dsn.dinus.ac.id

Email Penulis Korespondensi: sri.winarno@dsn.dinus.ac.id

Received: 29/06/2026, Revised: 25/07/2026, Accepted: 01/09/2026, Published: 08/09/2026

Abstrak—Perkembangan ekosistem *esports* Valorant melalui VALORANT Champions Tour (VCT) menciptakan kebutuhan akan analisis data yang objektif. Analisis saat ini sering terjebak bias subjektivitas, berisiko menghasilkan prediksi yang tidak akurat. Untuk mengatasi masalah tersebut, penelitian ini melakukan komparasi terhadap berbagai metode prediksi kemenangan tim pada VCT 2025. Pemilihan dataset VCT 2025 memberikan kebaruan karena merepresentasikan struktur liga *franchise* dengan meta permainan dan kompleksitas taktis yang jauh lebih merata dibandingkan musim sebelumnya. Algoritma yang dikomparasikan meliputi Naïve Bayes, Decision Tree, XGBoost, CatBoost, serta *Stacking Classifier*. Kontribusi utama penelitian ini adalah penerapan teknik ekstraksi fitur diferensial (*Delta Analysis*) guna mengukur selisih performa antar tim secara objektif. Hasil eksperimen komparatif pada 1.507 observasi pertandingan menunjukkan bahwa model *Stacking Classifier* mencapai tingkat akurasi paling optimal (75,72%) dibandingkan XGBoost (75,19%), Naïve Bayes (74,26%), CatBoost (73,59%), dan Decision Tree (72,86%). Temuan ini membuktikan bahwa sinergi *meta-learning* berbasis *Delta Analysis* mampu memberikan generalisasi analitik yang lebih stabil dalam menangani kompleksitas data kompetisi *esports* modern.

Kata Kunci: Valorant; eSports; Stacking Classifier; Prediksi Kemenangan; Naïve Bayes

Abstract—The development of the Valorant esports ecosystem through the VALORANT Champions Tour (VCT) creates a need for objective data analysis. Current analysis is often trapped in subjective bias, risking inaccurate predictions. To address this problem, this research compares various team win prediction methods in VCT 2025. The selection of the VCT 2025 dataset provides novelty as it represents a franchise league structure with much more evenly distributed game meta and tactical complexity than previous seasons. The compared algorithms include Naïve Bayes, Decision Tree, XGBoost, CatBoost, and Stacking Classifier. The main contribution of this research is the application of a differential feature extraction technique (*Delta Analysis*) to objectively measure the performance gap between teams. Comparative experimental results on 1,507 match observations show that the Stacking Classifier achieved the most optimal accuracy (75.72%) compared to XGBoost (75.19%), Naïve Bayes (74.26%), CatBoost (73.59%), and Decision Tree (72.86%). These findings prove that Delta Analysis-based meta-learning synergy can provide more stable analytical generalization in handling modern esports data complexity.

Keywords: Valorant; eSports; Stacking Classifier; Win Prediction; Naïve Bayes

1. PENDAHULUAN

Pertumbuhan pesat ekosistem olahraga elektronik (*esports*) melalui VALORANT Champions Tour (VCT) telah menciptakan kebutuhan mendesak terhadap sistem analitik data yang objektif dan presisi. Dalam lingkungan kompetitif tingkat tinggi, pengambilan keputusan strategis sering kali masih terjebak dalam bias subjektivitas analisis yang cenderung mengevaluasi peluang kemenangan berdasarkan popularitas pemain tertentu atau rekam jejak individu semata. Selain itu, keterbatasan kognitif manusia dalam memproses data historis pertandingan yang sangat masif menjadi kendala utama dalam menghasilkan prediksi yang akurat tanpa bantuan instrumentasi teknologi yang mampu melakukan ekstraksi informasi secara simultan dan mendalam [1].

Dalam praktiknya, ekosistem kompetitif VALORANT ditandai oleh fenomena fluktuasi momentum pertandingan yang sangat tajam. Perubahan jalannya pertandingan dapat terjadi hanya dalam beberapa ronde akibat keberhasilan suatu tim memanfaatkan strategi taktis, rotasi pemain, pengelolaan ekonomi (*economy management*), maupun pemilihan utilitas agen secara efektif. Sebagai contoh, sebuah tim yang berada dalam kondisi tertinggal dapat secara tidak terduga membalikkan keadaan (*comeback*) melalui kombinasi koordinasi tim yang baik, penguasaan posisi strategis, serta performa mekanik individu yang tinggi pada momen-momen krusial pertandingan [2], [3]. Dinamika tersebut menunjukkan bahwa hasil pertandingan tidak hanya dipengaruhi oleh kemampuan individu pemain, tetapi juga oleh interaksi berbagai faktor yang saling memengaruhi selama pertandingan berlangsung. Akibatnya, hubungan antara statistik performa dengan hasil akhir pertandingan menjadi bersifat non-linier dan tidak selalu mengikuti pola yang sederhana. Kondisi ini menyebabkan probabilitas kemenangan menjadi semakin sulit diprediksi apabila hanya mengandalkan observasi manual atau analisis statistik secara kasat mata, sehingga diperlukan pendekatan berbasis *machine learning* yang mampu mengidentifikasi pola-pola kompleks dari data historis pertandingan.

Kompleksitas pertandingan *esports* menyebabkan proses prediksi kemenangan menjadi tantangan yang tidak sederhana karena hasil pertandingan dipengaruhi oleh berbagai faktor yang saling berinteraksi [1], [2], [3], mulai dari

performa individu pemain, strategi tim, hingga kondisi permainan yang terus berubah. Tantangan analitik serupa juga telah dikonfirmasi pada *genre* FPS taktis lainnya seperti *Counter-Strike: Global Offensive* [4], serta pada ekosistem kompetitif berskala masif seperti *League of Legends* [5]. Untuk mengatasi keterbatasan model tunggal dalam mempelajari pola yang kompleks, pendekatan *ensemble learning* banyak digunakan karena mampu meningkatkan kemampuan generalisasi melalui penggabungan beberapa model pembelajaran yang berbeda [6], [7], [8]. Salah satu pendekatan *ensemble* yang populer adalah *Stacking Classifier* yang mengombinasikan prediksi dari beberapa model dasar ke dalam sebuah *meta-model* untuk menghasilkan keputusan akhir yang lebih stabil [6]. Pemilihan pendekatan *feature engineering* berbasis *Delta Analysis* dalam penelitian ini dinilai lebih superior dibandingkan metode normalisasi fitur standar (seperti *Z-score*). Dalam konteks *esports* berkonsep *zero-sum game*, probabilitas kemenangan lebih logis diukur berdasarkan pengkuantifikasian "jarak kekuatan" (*power gap*) secara langsung antara dua tim yang saling berhadapan pada satu pertandingan, alih-alih hanya mengukur sebaran distribusi metrik secara terisolasi.

Beberapa studi literatur terdahulu telah berupaya memetakan variabel penentu kemenangan dalam permainan ini melalui berbagai sudut pandang. Penelitian sebelumnya telah menginisiasi prediksi tingkat kemenangan menggunakan algoritma *Naïve Bayes* dengan menitikberatkan pada susunan komposisi agen sebagai parameter utama, yang menghasilkan akurasi sebesar 71,79% [9]. Di sisi lain, Dewimurniati dkk. menunjukkan bahwa faktor agresivitas individu yang direpresentasikan melalui *Average Combat Score* (ACS) dan KAST merupakan faktor penentu dengan tingkat akurasi mencapai 82-85% melalui model *Support Vector Machine* dan *Random Forest* [14]. Pada ranah *mobile esports*, optimasi model klasifikasi juga terbukti relevan untuk diimplementasikan [11]. Namun, perkembangan riset global terkini menunjukkan pergeseran tren yang kuat dari penggunaan model tunggal menuju arsitektur *ensemble*. Penelitian oleh Hodge et al. [3] dan Minami et al. [12] menunjukkan bahwa pemanfaatan teknik *machine learning* mampu meningkatkan kemampuan prediksi pada data *esports* yang kompleks dan memiliki variabilitas tinggi. Terlebih lagi, studi terbaru oleh García-Méndez dkk. [1] pada tahun 2025 memvalidasi keandalan dan kemampuan interpretasi model prediktif pada *genre* FPS taktis yang sejenis. Meskipun pendekatan-pendekatan terdahulu telah memberikan kontribusi penting, masih terdapat kesenjangan penelitian dalam mengintegrasikan strategi makro berupa komposisi tim dengan kemampuan mikro individu ke dalam satu model *ensemble* yang kohesif guna menghadapi dinamika *meta* permainan yang terus berkembang.

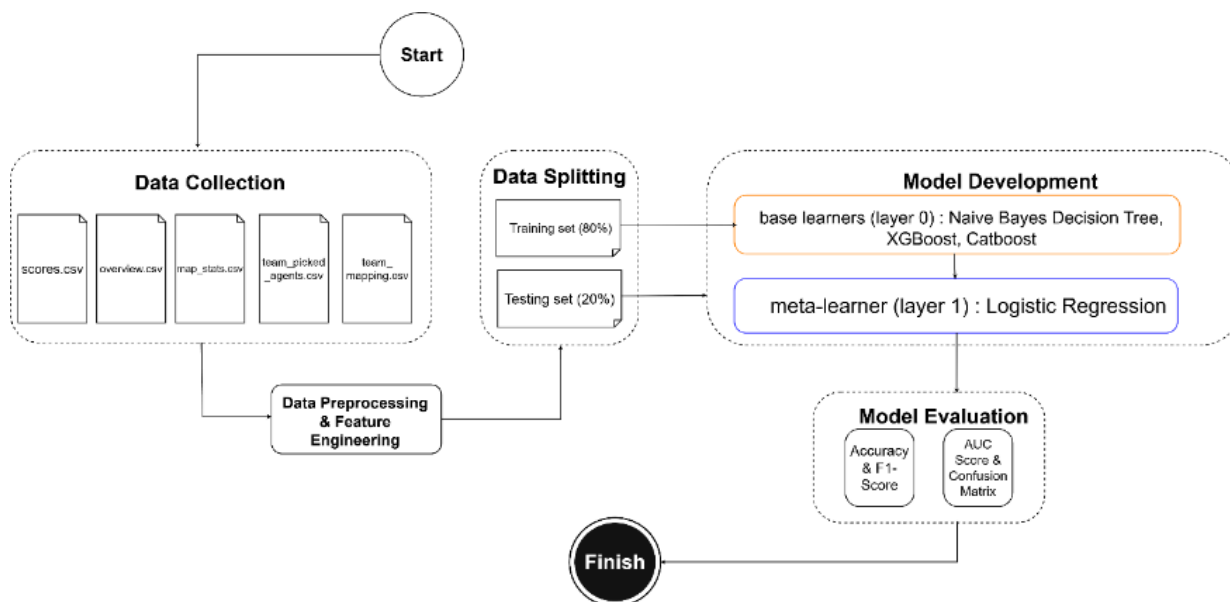
Berdasarkan latar belakang tersebut, penelitian ini berupaya mengisi kesenjangan yang ada dengan mengoptimalkan sistem prediksi hasil pertandingan melalui penerapan arsitektur *Stacking Classifier* yang dipadukan dengan teknik *feature engineering* berbasis analisis diferensial (*Delta Analysis*). Penggunaan metodologi ini diarahkan untuk mengevaluasi dataset longitudinal yang mencakup turnamen VCT dari periode tahun 2021 hingga 2025 secara komprehensif. Melalui penerapan model *ensemble* berlapis dan transformasi fitur selisih performa antar tim, diharapkan penelitian ini mampu memberikan landasan analitik yang jauh lebih objektif, mereduksi bias subjektivitas, serta memberikan wawasan ilmiah baru mengenai evolusi faktor-faktor penentu kemenangan dalam skena profesional *Valorant* mutakhir. Adapun kontribusi utama dari hasil penelitian ini adalah menyediakan kerangka metodologi analitik berbasis diferensial yang lebih tahan terhadap bias subjektivitas, serta menyajikan tolok ukur (*benchmark*) keandalan model *ensemble* hibrida pada *genre* FPS taktis.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Secara keseluruhan, arsitektur metodologi yang diusulkan divisualisasikan pada Gambar 1. Proses penelitian terbagi menjadi empat tahapan utama yang terintegrasi secara sekuensial. Pertama, tahap *Data Collection* menghimpun lima entitas data mentah historis pertandingan dalam format CSV. Kumpulan data ini merepresentasikan statistik kompetisi secara menyeluruh, mencakup rekam jejak performa individu, komposisi taktis agen, hingga persentase keberhasilan peta. Kedua, tahap *Data Preprocessing & Feature Engineering* melakukan pembersihan *noise* statistik. Proses dilanjutkan dengan transformasi data absolut menjadi metrik diferensial berbasis *Delta Analysis* untuk memetakan selisih performa antar tim secara objektif, sehingga model prediktif dapat lebih fokus pada "jarak kekuatan" relatif. Ketiga, tahap *Data Splitting* membagi dataset secara proporsional. Pembagian ini mengalokasikan 80% data latihan (*training set*) untuk proses pembelajaran algoritma, sementara sisa 20% dialokasikan sebagai data uji (*testing set*) murni untuk evaluasi pengujian klasifikasi. Keempat, tahap inti *Model Development* mengeksekusi data latihan menggunakan arsitektur *Stacking Classifier*. Pemrosesan berjalan paralel di mana prediksi dari empat algoritma *base learners* (*Naïve Bayes*, *Decision Tree*, *XGBoost*, dan *CatBoost*) pada *layer 0* dikompilasi dan diteruskan sebagai masukan (*input*) kepada *Logistic Regression*. *Meta-learner* pada *layer 1* ini berfungsi merumuskan keputusan klasifikasi akhir secara logis untuk meminimalisasi risiko *overfitting* yang sering terjadi pada model tunggal. Selanjutnya, hasil prediksi tersebut divalidasi secara ketat pada tahap *Model Evaluation*. Pengujian tahap akhir ini diukur menggunakan instrumen metrik performa klasifikasi guna memastikan ketahanan, keandalan, serta stabilitas generalisasi model saat dihadapkan pada variabilitas data kompetisi yang sesungguhnya. Pendekatan metodologis yang komprehensif ini dirancang secara khusus untuk menjawab tantangan analitik pada ekosistem *esports* modern, sehingga luaran prediktif yang dihasilkan tidak hanya akurat secara komputasi matematis, tetapi juga dapat diinterpretasikan secara taktis oleh analis profesional. Seluruh tahapan operasional dalam kerangka kerja ini

dieksekusi secara terstruktur guna mencegah terjadinya kebocoran informasi (*data leakage*) yang sering menjadi kelemahan pada pemodelan prediktif konvensional. Melalui integrasi pemrosesan data yang sistematis dan pemodelan berlapis ini, hasil akhir diharapkan mampu memberikan wawasan yang valid, transparan, dan dapat direproduksi untuk mendukung skena kompetitif yang lebih luas.



Gambar 1. Arsitektur Metodologi Penelitian Prediksi Kemenangan VCT

2.2 Pengumpulan Data

Penelitian ini menggunakan dataset sekunder yang dihimpun secara komprehensif dari riwayat pertandingan resmi turnamen VALORANT Champions Tour (VCT) yang mencakup periode tahun kompetisi 2021 hingga 2025. Data mentah ini diperoleh melalui repositori publik Kaggle pada kumpulan data berjudul "*Valorant Champion Tour 2021-2026 Data*", yang merupakan hasil ekstraksi (*web scraping*) dari platform analitik esports global, vlr.gg. Pengambilan dan pengunduhan data dilakukan pada bulan Desember 2025, yang membatasi cakupan analisis pada periode sebelum pembaruan musim kompetisi 2026 diintegrasikan. Struktur data mentah yang diekstraksi mencakup tiga entitas utama, yaitu riwayat pertandingan (*matches*), komposisi agen (*agents*), serta rekam jejak performa pemain (*player stats*), yang secara keseluruhan menghasilkan 1.507 observasi pertandingan valid. Seluruh data tersebut kemudian disusun dan diintegrasikan ke dalam format *comma-separated values* (CSV) guna memastikan konsistensi pada tahapan pemrosesan komputasi. Dataset sekunder tersebut dapat diakses secara publik melalui platform Kaggle pada repositori kumpulan data berjudul Valorant Champion Tour 2021-2026 Data (<https://www.kaggle.com/datasets/ryanluong1/valorant-champion-tour-2021-2023-data>). Pendekatan ekstraksi fitur dalam penelitian ini menggunakan nilai agregat historis, di mana rata-rata performa tim pada serangkaian pertandingan sebelumnya digunakan sebagai variabel masukan untuk memprediksi pertandingan target (*target match*). Untuk mencegah celah kebocoran data (*data leakage*), ekstraksi nilai rata-rata historis tidak dikalkulasikan menggunakan rata-rata agregat dari keseluruhan musim. Penghitungan dilakukan secara ketat menggunakan metode *rolling average* (rata-rata bergerak), di mana fitur input sebuah tim hanya diekstrak dari kumpulan data pertandingan masa lalu yang terjadi secara kronologis sebelum pertandingan target (*target match*) berlangsung.

2.3 Feature Engineering

Proses rekayasa fitur dilakukan melalui teknik *Delta Analysis*, yakni mentransformasi statistik absolut menjadi metrik diferensial guna menonjolkan keunggulan relatif antar tim yang bertanding. Fitur-fitur utama yang dikembangkan dalam penelitian ini meliputi *ACS_Delta* yang merepresentasikan selisih nilai *Average Combat Score* rata-rata antara kedua tim yang bertanding pada satu peta pertandingan, dan *Rating_Delta* yang memetakan selisih nilai rating performa secara keseluruhan antar tim guna mencerminkan efektivitas permainan agregat. Selain itu, dikembangkan pula fitur *Role_Delta* untuk mengukur perbedaan kuantitatif dalam komposisi peran agen yang digunakan oleh masing-masing tim (meliputi kategori Duelist, Initiator, Sentinel, dan Controller) yang secara konsep sejalan dengan pendekatan analitik klasifikasi peran pemain pada game berbasis tim [13], serta fitur *Map_Context* yang mengintegrasikan data persentase kemenangan historis pada sisi *Attacker* dan *Defender* di peta (*map*) tertentu untuk menyertakan karakteristik lingkungan pertandingan ke dalam model.

Secara matematis, proses rekayasa fitur diferensial (*Delta Analysis*) untuk setiap parameter statistik diekstraksi menggunakan Persamaan (1).

$$\Delta F = F_A - F_B \quad (1)$$

Berdasarkan Persamaan (1), komponen ΔF merepresentasikan nilai metrik diferensial atau selisih performa akhir yang dihasilkan (seperti *ACS_Delta* atau *Rating_Delta*). Komponen F_A mewakili nilai agregat atau rata-rata statistik performa historis dari Tim A, sedangkan komponen F_B mewakili nilai agregat statistik serupa dari Tim B yang menjadi lawannya pada pertandingan target. Pendekatan diferensial ini memastikan model tidak berfokus pada seberapa besar skor mutlak suatu tim, melainkan seberapa jauh jarak keunggulan relatif tim tersebut dibandingkan musuhnya guna meminimalkan bias angka absolut.

Pendekatan Delta Analysis dipilih karena hasil pertandingan esports pada umumnya lebih dipengaruhi oleh perbedaan kekuatan relatif antar tim dibandingkan nilai absolut masing-masing statistik. Sebagai ilustrasi, dua tim dapat memiliki nilai ACS rata-rata yang sama tinggi, namun peluang kemenangan lebih dipengaruhi oleh selisih performa di antara keduanya daripada besarnya nilai tersebut secara terpisah. Oleh karena itu, transformasi berbasis selisih (delta) digunakan untuk menonjolkan keunggulan relatif masing-masing tim sehingga model memperoleh representasi data yang lebih informatif dalam membedakan peluang kemenangan.

2.4 Arsitektur dan Pelatihan Model

Penelitian ini melakukan studi komparatif dengan mengevaluasi beberapa algoritma klasifikasi. Secara khusus, arsitektur *Stacking Classifier* yang pada mulanya diperkenalkan oleh Wolpert [6] diimplementasikan untuk mengoptimalkan hasil prediksi akhir. Secara teoretis, arsitektur ini merujuk pada pemanfaatan algoritma klasifikasi yang kuat pada penelitian terdahulu seperti Random Forest [14] atau LightGBM [15]. Namun, dalam rancangan eksperimen penelitian ini, pada tahap level pertama (base-learners), pemrosesan data dilakukan secara independen oleh Naïve Bayes, Decision Tree, XGBoost [16], dan CatBoost [17]. Untuk memastikan model tidak terjebak pada *local optima* dan mencapai konfigurasi terbaik, proses pencarian hyperparameter diinisiasi menggunakan metode Grid Search [18]. Konsep ini diterapkan untuk mencegah risiko *overfitting* yang sering terjadi pada model tunggal serta guna meningkatkan akurasi generalisasi. Dalam proses pelatihan, dataset dibagi (*split*) secara sistematis menjadi data latih (*training set*) untuk pembangunan model dan data uji (*testing set*) untuk memvalidasi performa prediksi terhadap data baru.

Pada penelitian ini, Stacking Classifier dibangun menggunakan empat model dasar (base learner), yaitu Naïve Bayes, Decision Tree, XGBoost, dan CatBoost. Keempat algoritma tersebut dipilih karena memiliki karakteristik pembelajaran yang berbeda sehingga diharapkan mampu menghasilkan prediksi yang saling melengkapi. Prediksi dari masing-masing model dasar kemudian digunakan sebagai masukan bagi meta-classifier untuk menghasilkan keputusan akhir. *Logistic Regression* dipilih sebagai *meta-learner* pada lapis akhir karena kemampuannya dalam memberikan kalibrasi probabilitas yang sederhana dan stabil, guna mereduksi risiko *overfitting* yang mungkin timbul dari pengombinasian prediksi model non-linear kompleks seperti XGBoost dan CatBoost. Melalui mekanisme tersebut, kelemahan setiap algoritma tunggal dapat dikompensasi oleh algoritma lainnya sehingga meningkatkan kemampuan generalisasi model terhadap data pertandingan profesional yang memiliki karakteristik kompleks. Dalam arsitektur *Stacking Classifier*, proses pengambilan keputusan akhir tidak dilakukan secara tunggal, melainkan dikalkulasikan melalui dua tahap lapisan pembelajaran. Formulasi prediksi akhir dari model *ensemble* berlapis ini dirumuskan secara matematis pada Persamaan (2).

$$\hat{y} = M(h_1(x), h_2(x), \dots, h_n(x)) \quad (2)$$

Melalui Persamaan (2), komponen $\hat{y}$ merepresentasikan probabilitas hasil akhir pertandingan (kelas menang atau kalah) yang menjadi target estimasi. Komponen M menandakan fungsi keputusan dari *meta-learner* (*Logistic Regression*), sedangkan komponen $h_n(x)$ mewakili nilai prediksi hibrida atau *output* probabilitas dari masing-masing *base-learner* ke- n (yaitu Naïve Bayes, Decision Tree, XGBoost, dan CatBoost) yang memproses data secara independen pada lapis pertama, dengan variabel x bertindak sebagai vektor input dari seluruh fitur diferensial hasil rekayasa data. Proses pengujian model dalam penelitian ini menerapkan pendekatan evaluasi ganda untuk memastikan tingkat validitas yang tinggi. Pertama, performa komparatif antar algoritma divalidasi menggunakan mekanisme *5-Fold Cross-Validation* untuk menghasilkan nilai rata-rata metrik yang stabil dan tahan terhadap bias variansi sampling data. Kedua, untuk keperluan visualisasi klasifikasi, model juga diuji melalui skenario *hold-out single split* dengan proporsi 80% data latih dan 20% data uji. Evaluasi kinerja diukur menggunakan metrik Akurasi, *Precision*, *Recall*, dan *F1-Score*, di mana nilai *F1-Score* dihitung berdasarkan rerata harmonik menggunakan Persamaan (3).

$$F1 - Score = 2 \times \left(\frac{(Precision \times Recall)}{(Precision + Recall)} \right) \quad (3)$$

Berdasarkan Persamaan (3), nilai metrik *F1-Score* diperoleh melalui perkalian konstanta dua dengan hasil pembagian antara perkalian komponen *Precision* (representasi tingkat ketepatan prediksi positif model) dan *Recall* (representasi tingkat keberhasilan model menemukan kembali seluruh kelas positif), terhadap penjumlahan dari kedua komponen metrik tersebut. Penjelasan komponen ini menegaskan bahwa model dievaluasi secara seimbang pada kedua kelas target guna menghindari bias klasifikasi akibat fluktuasi distribusi data pertandingan resmi.

2.5 Tools dan Framework

Seluruh tahapan penelitian, mulai dari akuisisi data, prapemrosesan, rekayasa fitur berbasis Delta Analysis, pelatihan model, optimasi hyperparameter, hingga evaluasi performa model, diimplementasikan menggunakan bahasa

pemrograman Python. Pemilihan Python didasarkan pada ketersediaan berbagai pustaka machine learning yang telah banyak digunakan dalam penelitian ilmiah sehingga mampu mendukung proses analisis data secara efisien dan reproduktif. Pada tahap pengolahan data, pustaka Pandas digunakan untuk melakukan pembersihan data, transformasi atribut, penggabungan data pertandingan, serta pembentukan fitur-fitur baru yang digunakan sebagai masukan model. Selanjutnya, pustaka Scikit-Learn [19] dimanfaatkan untuk membangun arsitektur Stacking Classifier, melakukan pembagian data menggunakan train-test split, menerapkan Grid Search dalam proses optimasi hyperparameter, serta menghitung metrik evaluasi seperti accuracy, precision, recall, dan F1-score. Adapun algoritma XGBoost dan CatBoost diimplementasikan menggunakan pustaka resminya masing-masing untuk memperoleh proses pembelajaran yang lebih optimal pada data pertandingan profesional VALORANT yang memiliki karakteristik kompleks dan dinamis.

Selain Pandas dan Scikit-Learn, penelitian ini juga memanfaatkan pustaka XGBoost dan CatBoost untuk membangun model boosting, sedangkan proses visualisasi hasil eksperimen dilakukan menggunakan Matplotlib. Seluruh eksperimen dijalankan dalam lingkungan Python sehingga setiap tahapan, mulai dari prapemrosesan data, pembentukan fitur, pelatihan model, hingga evaluasi performa dapat dilakukan secara konsisten dan bersifat reproduktif. Pendekatan ini memudahkan proses validasi hasil penelitian apabila diterapkan kembali pada dataset atau musim kompetisi yang berbeda.

3. HASIL DAN PEMBAHASAN


3.1 Hasil

Evaluasi performa prediktif dilakukan terhadap 1.507 observasi pertandingan VCT 2025. Berdasarkan hasil pengujian komparatif menggunakan skenario 5-Fold Cross-Validation, algoritma Stacking Classifier mencapai performa yang paling optimal secara menyeluruh, sebagaimana disajikan pada Tabel 1. Model ini mencatatkan rata-rata tingkat akurasi sebesar 75,72% dan nilai F1-Score mencapai 77,14%, yang mengindikasikan kemampuan generalisasi komputasi yang sangat kompetitif dalam merespons variabilitas meta kompetisi terbaru.

Tabel 1. Evaluasi Model

Model	Accuracy(%)	Precision(%)	Recall(%)	F1-Score(%)	AUC Score
Naïve Bayes	74.26	75.94	75.29	75.57	0.782
Decision Tree	72.86	75.24	72.4	73.77	0.761
XGBoost	75.19	76.29	77.05	76.65	0.788
CatBoost	73.59	74.95	75.29	75.09	0.779
Stacking Classifier	75.72	76.79	77.55	77.14	0.791

Selain akurasi, evaluasi juga mempertimbangkan nilai precision, recall, dan F1-Score untuk memastikan bahwa model tidak hanya memiliki tingkat prediksi yang tinggi secara keseluruhan, tetapi juga mampu mengklasifikasikan kedua kelas secara seimbang. Penggunaan beberapa metrik evaluasi menjadi penting karena distribusi karakteristik pertandingan profesional dapat berubah pada setiap musim kompetisi, sehingga penilaian model tidak cukup hanya berdasarkan satu metrik akurasi.




Gambar 2. Grafik *Learning Curve* (Loss dan Akurasi) Selama Pelatihan Model


Untuk memvalidasi stabilitas komputasi dan mengevaluasi potensi overfitting, proses pembelajaran model divisualisasikan melalui grafik *Learning Curve* pada Gambar 2. Berdasarkan grafik Log Loss maupun Accuracy, terlihat bahwa kurva data latih (Train) dan data uji (Test) bergerak konvergen menuju kondisi yang relatif stabil. Kesenjangan (gap) yang relatif kecil antara kedua kurva tersebut mengindikasikan bahwa model memiliki kemampuan

generalisasi yang baik dan tidak menunjukkan gejala overfitting yang signifikan. Hasil ini menunjukkan bahwa konfigurasi hyperparameter yang diperoleh melalui proses Grid Search mampu menghasilkan model yang stabil dalam mempelajari pola data kompetitif Valorant tanpa terlalu bergantung pada karakteristik spesifik data latih.

Analisis lebih mendalam terkait persebaran kelas prediksi divisualisasikan melalui *Confusion Matrix* (Gambar 3) yang diekstraksi dari skenario evaluasi *hold-out single split* (20% data uji sebanyak 302 observasi target). Pada pengujian spesifik ini, model tercatat berhasil memprediksi *True Positive* sebanyak 123 pertandingan dan *True Negative* sebanyak 112 pertandingan, yang menghasilkan akurasi *single-split* sebesar 77,81%. Sebaran kesalahan pada *False Positive* dan *False Negative* terpantau seimbang. Adanya perbedaan marginal antara akurasi uji *single-split* (77,81%) dengan rata-rata akurasi *Cross-Validation* (75,72%) merupakan karakteristik wajar dalam pemodelan probabilistik. Hal ini justru mengonfirmasi bahwa performa model berada pada rentang yang stabil, tidak mengalami indikasi bias ekstrem terhadap salah satu kelas, serta memiliki keandalan yang konsisten dalam mengidentifikasi pola kemenangan maupun kekalahan.



Gambar 3. Confusion Matrix



Gambar 4. Feature Importance

Untuk memberikan interpretasi yang lebih terukur, bobot kontribusi dari masing-masing fitur dalam memengaruhi keputusan klasifikasi disajikan pada Tabel 2.

Tabel 2. Skor *Feature Importance* berdasarkan *Delta Analysis*


Nama Fitur	Metrik	Importance Score
ACS_Delta	Daya Tembak (Mekanik)	25,10
Rating_Delta	Penilaian Performa Agregat	23,47
Attacker Side Win %	Konteks Penguasaan Peta	13,24
Defender Side Win %	Konteks Penguasaan Peta	13,11
Initiator_Delta	Komposisi Peran Agen	8,20

Nama Fitur	Metrik	Importance Score
Sentinel_Delta	Komposisi Peran Agen	6,34
Duelist_Delta	Komposisi Peran Agen	5,82
Controller_Delta	Komposisi Peran Agen	5,03

Meskipun secara teori taktis peran agen sering dianggap sangat vital, bobot rendah pada fitur *Role_Delta* mengindikasikan kontradiksi yang rasional di level profesional. Komposisi susunan agen yang sangat ideal tidak akan memberikan kontribusi maksimal apabila tidak diimbangi dengan eksekusi mekanik mentah (*aim*) individu yang superior.

3.2 Pembahasan

Analisis Kinerja Algoritma dan Konfigurasi Stacking. Merujuk pada Tabel 1, model *Stacking Classifier* berhasil mengungguli keempat algoritma dasar lainnya. Hal yang menarik untuk dianalisis adalah signifikansi implementasi *Grid Search* yang sukses mendongkrak performa XGBoost menjadi algoritma dasar terbaik kedua (75,19%), mengatasi keterbatasan performa konfigurasi *default*-nya. Arsitektur *Stacking Classifier* kemudian membuktikan keunggulannya dengan tidak hanya membandingkan, melainkan mensinergikan model-model tersebut. Berdasarkan ekstraksi koefisien *meta-model* yang divisualisasikan pada Gambar 5, keputusan akhir *Stacking* sangat didominasi oleh kepercayaan terhadap XGBoost (bobot 1,85) dan Naïve Bayes (bobot 1,25). Sinergi ini sangat ideal: XGBoost bertugas menangkap pola non-linier yang kompleks dari metrik performa pemain, sementara Naïve Bayes menyediakan estimasi probabilistik yang sederhana dan stabil guna mengimbangi kompleksitas tersebut serta mereduksi risiko *overfitting*. Pendekatan *ensemble* ini sejalan dengan temuan Hodge *et al.* [3], yang mengonfirmasi bahwa arsitektur hibrida lebih optimal dalam menangani variabilitas data kompetitif *esports*.



Gambar 5. Bobot Kepercayaan *Meta-Model* terhadap Algoritma Dasar (*Base Learners*)

Signifikansi Metrik Diferensial (Delta Analysis). Interpretasi terhadap Tabel 2 memberikan pemahaman mendalam mengenai hierarki variabel. Variabel selisih daya tembak (ACS_Delta) dan keunggulan mekanik agregat (Rating_Delta) secara konsisten menempati peringkat teratas. Dominasi ACS_Delta mengindikasikan bahwa efektivitas eksekusi mekanik mentah (raw firepower) tetap merupakan salah satu faktor dominan. Sebaliknya, perbedaan komposisi peran agen (*Role_Delta*) berada di peringkat terbawah. Secara statistik, hasil ini mengindikasikan bahwa komposisi agen saja belum cukup untuk memberikan performa prediksi yang optimal apabila tidak diimbangi dengan keunggulan mekanik individu. Hasil ini juga mendukung riset terbaru dari García-Méndez dkk. [1], serta prinsip dasar interpretasi prediksi model [20], yang memvalidasi bahwa ekstraksi fitur statistik performa pemain memiliki kontribusi dominan terhadap keandalan dan *explainability* prediksi pada *genre* FPS taktis.

Pengaruh Konteks Peta (Map Context) dan Analisis Kesalahan. Selain variabel mekanik, faktor lingkungan berupa persentase kemenangan pada sisi *Attacker* dan *Defender* menunjukkan bobot pengaruh yang signifikan. Hal ini menunjukkan bahwa tim yang mampu mengeksploitasi karakteristik asimetris dari sebuah peta memiliki probabilitas kemenangan yang stabil. Meskipun model menghasilkan tingkat akurasi yang baik, analisis pada matriks kebingungan tetap mencatatkan sebagian kecil kesalahan klasifikasi. Kegagalan prediksi pada anomali pertandingan ini merupakan karakteristik wajar dalam ekosistem *esports*, di mana pertandingan sering kali dipengaruhi oleh faktor momentum tak terduga atau aksi heroik individu (*clutch moments*) yang tidak sepenuhnya direkam oleh statistik agregat pasca-pertandingan.

Perbandingan Kinerja dan Studi Longitudinal. Untuk memvalidasi performa metodologi yang diusulkan, model dievaluasi dan dibandingkan dengan pelaporan metrik pada studi-studi terdahulu. Pendekatan komparatif melalui *Stacking Classifier* yang diusulkan pada penelitian ini mencatatkan akurasi 75,72%, sebuah angka yang

merepresentasikan stabilitas generalisasi, bukan sekadar *overfitting* artifisial. Jika dikomparasikan dengan A. Iskandar dan J. Pratama [9] yang menggunakan Naïve Bayes (71,79%) dengan fokus tunggal pada pemilihan agen, hasil ekstraksi *Feature Importance* pada penelitian ini justru membuktikan bahwa komposisi agen (*Role_Delta*) memiliki bobot terendah. Hal ini menegaskan bahwa penggunaan algoritma tunggal probabilistik berbasis agen tidak cukup kuat untuk menangkap dinamika Valorant modern jika tidak dikalibrasi dengan keunggulan mekanik individu.

Di sisi lain, meskipun Dewimurniati dkk. [10] melaporkan akurasi hingga 85,00% menggunakan Random Forest, pendekatan tersebut memiliki kelemahan fundamental karena menggunakan metrik statistik absolut (mentah). Dalam ekosistem kompetitif, probabilitas kemenangan lebih dipengaruhi oleh perbedaan kekuatan relatif (selisih), bukan angka mutlak. Oleh karena itu, penelitian ini memperkenalkan inovasi komparatif. Transformasi *Delta Analysis* secara logis memetakan jarak kekuatan antar tim, sementara arsitektur *Stacking Classifier* bertugas mengomparasikan dan mengevaluasi tebakan dari keempat algoritma *base-learners* untuk menutupi kelemahan masing-masing model (seperti asumsi independensi pada Naïve Bayes dan kerentanan *overfitting* pada model pohon berbasis absolut). Angka 75,72% yang dihasilkan oleh komparasi arsitektur hibrida ini menunjukkan kapabilitas prediksi yang paling realistis karena diuji secara khusus pada dataset liga *franchise* mutakhir (2025) yang memiliki tingkat kompetisi jauh lebih merata dan kompleksitas taktis yang sangat tinggi. Untuk memperkuat analisis tersebut, performa arsitektur *Stacking Classifier* juga dievaluasi secara konsisten melintasi dataset tahun kompetisi terpilih (2021, 2024, dan 2025), yang terintegrasi dari gabungan tabel historis. Hasil evaluasi ini disajikan pada Tabel 4.

Tabel 3. Tren Prediktabilitas Hasil Pertandingan VCT pada Tahun Terpilih

Tahun Kompetisi	Total Sampel Pertandingan	Akurasi Stacking Classifier
VCT 2021	18.676 observasi	83,62%
VCT 2024	1.307 observasi	76,97%
VCT 2025	1.507 observasi	75,72%

Transisi pengujian model dari VCT 2021 (83,62%) menuju VCT 2025 (75,72%) menunjukkan adanya tren penurunan prediktabilitas. Hal ini merepresentasikan adanya ketidakstabilan model sekaligus sensitivitas berlebihan terhadap distribusi data spesifik pada musim tertentu. Penyusutan drastis dari 18.676 observasi ke 1.507 observasi di era liga *franchise*, dipadukan dengan dinamika perubahan *patch/meta* permainan, membuat kekuatan antar tim elit menjadi jauh lebih merata. Akibatnya, hasil pertandingan di musim mutakhir menjadi lebih fluktuatif, sehingga menuntut *Stacking Classifier* untuk bekerja lebih keras mencegah *overfitting* di tengah data yang semakin dipenuhi *noise*.

4. KESIMPULAN

Penelitian ini berhasil merancang arsitektur *Stacking Classifier* teroptimasi *Grid Search* dalam memprediksi kemenangan pertandingan profesional VALORANT dengan capaian akurasi terbaik sebesar 75,72% pada lanskap data VCT 2025. Kontribusi utama penelitian ini adalah pembuktian empiris bahwa teknik *feature engineering* berbasis *Delta Analysis* (selisih performa) memberikan representasi data dan stabilitas generalisasi yang jauh lebih objektif dan realistis dibandingkan penggunaan statistik mentah tunggal pada arsitektur model dasar. Namun demikian, fluktuasi akurasi secara longitudinal lintas tahun kompetisi (2021 hingga 2025) menunjukkan bahwa model memiliki kerentanan terhadap distribusi pergeseran meta spesifik pada ekosistem *esports* modern yang kian kompetitif. Keterbatasan utama pada metodologi penelitian ini adalah arsitektur yang dirancang masih sebatas instrumen analisis pasca-pertandingan (*post-match analysis*) yang bergantung pada agregasi data historis, sehingga belum dapat diandalkan untuk prediksi temporal secara langsung (*real-time prediction*) di tengah jalannya ronde. Untuk penelitian selanjutnya, ruang pengembangan disarankan pada integrasi metrik performa ronde-per-ronde (*round-by-round statistics*) dan penggunaan arsitektur *Deep Learning* yang lebih adaptif terhadap perkembangan ekosistem *esports* profesional.

5. PERNYATAAN PENULIS

5.1 Kontribusi Penulis

Konseptualisasi: B.I.K., dan S.W.;
 Metodologi: B.I.K., dan S.W.;
 Perangkat Lunak: B.I.K.;
 Validasi: B.I.K., dan S.W.;
 Analisis Formal: B.I.K., dan S.W.;
 Investigasi: B.I.K., dan S.W.;
 Sumber Daya: B.I.K., dan S.W.;
 Kurasi Data: B.I.K.;
 Penulisan Draf Awal: B.I.K., dan S.W.;

Penulisan, Peninjauan, dan Penyuntingan: B.I.K., dan S.W.;

Visualisasi: B.I.K., dan S.W.;

Seluruh penulis telah membaca dan menyetujui versi manuskrip yang telah diterbitkan.

5.2 Ketersediaan Data

Data yang disajikan dalam penelitian ini tersedia berdasarkan permintaan kepada penulis pertama.

5.3 Pendanaan

Penelitian ini tidak menerima pendanaan eksternal.

5.4 Pernyataan Dewan Peninjau Institusional

Tidak Berlaku (Not applicable).

5.5 Pernyataan Persetujuan Berdasarkan Informasi

Tidak Berlaku (Not applicable).

5.6 Pernyataan Konflik Kepentingan

Para penulis menyatakan bahwa mereka tidak memiliki kepentingan keuangan yang bersaing atau hubungan pribadi yang diketahui yang dapat dianggap memengaruhi pekerjaan yang dilaporkan dalam artikel ini.

5.7 Penggunaan AI Generatif dan Teknologi Berbantuan AI dalam Proses Penulisan

Para penulis menggunakan AI Generatif untuk meningkatkan kejelasan penulisan dalam artikel ini. Para penulis telah meninjau dan menyunting konten yang dihasilkan dengan bantuan AI serta bertanggung jawab penuh atas versi akhir publikasi.

REFERENCES

- [1] S. García-Méndez and F. de Arriba-Pérez, "Explainable E-Sports Win Prediction Through Machine Learning Classification in Streaming," *Entertain. Comput.*, vol. 55, p. 101027, 2025, doi: 10.1016/j.entcom.2025.101027.
- [2] N. Hayakawa, K. Shimari, K. Yamasaki, H. Hoshikawa, R. Tsuchida and K. Matsumoto, "Round Outcome Prediction in VALORANT Using Tactical Features from Video Analysis," *2025 IEEE Conference on Games (CoG)*, Lisbon, Portugal, 2025, pp. 1-4, doi: 10.1109/CoG64752.2025.11114177.
- [3] V. Hodge, S. Devlin, N. Sephton, F. Block, and P. Cowling, "Win Prediction in Esports: Mixed-Rank Match Prediction in Multi-Player Online Battle Arena Games," *IEEE Trans. Games*, vol. 13, no. 4, pp. 368–379, 2021, doi: 10.1109/TG.2019.2948469.
- [4] P. Xenopoulos, B. Coelho, and C. Silva, "Valuing Actions in Counter-Strike: Global Offensive," in *2022 IEEE International Conference on Big Data (Big Data)*, 2022, pp. 3283–3292. doi: 10.1109/BigData55660.2022.10020558.
- [5] P. Z. Maymin, "Smart Kills and Worthless Deaths: eSports Analytics for League of Legends," *J. Quant. Anal. Sports*, vol. 17, no. 1, pp. 11–27, 2021, doi: 10.1515/jqas-2019-0096.
- [6] D. H. Wolpert, "Stacked Generalization," *Neural Networks*, vol. 5, no. 2, pp. 241–259, 1992, doi: 10.1016/S0893-6080(05)80023-1.
- [7] S. Yangibaev, J. Mattiev, and S. Mokwena, "DotA 2 Match Outcome Prediction System Using Decision Tree Ensemble Algorithms," *Big Data and Cognitive Computing*, vol. 9, no. 12, p. 302, 2025, doi: 10.3390/bdcc9120302.
- [8] Z. Fan, Z. Yu, K. Yang, W. Chen, X. Liu, G. Li, X. Yang, and C. L. P. Chen, "Diverse Models, United Goal: A Comprehensive Survey of Ensemble Learning," *CAAI Transactions on Intelligence Technology*, vol. 10, no. 4, pp. 959–982, 2025, doi: 10.1049/cit2.70030.
- [9] A. Iskandar and J. Pratama, "Prediksi Win Rate pada Game VALORANT Melalui Pemilihan Agent Menggunakan Algoritma Naïve Bayes," *Journal of Data Analytics, Information, and Computer Science*, vol. 3, no. 1, pp. 33–44, 2026, doi: 10.70248/jdaics.v3i1.2062. [Online]. Available: <https://journal.ppmi.web.id/index.php/jdaics/article/view/2062>
- [10] Putri Ayu Dewimurniati, "Prediksi Kemenangan Tim Dalam Turnamen Valorant Champions Tour 2024 Berdasarkan Statistik Performa Pemain," Universitas Mercu Buana, Jakarta, Indonesia, 2025. [Online]. Available: <https://repository.mercubuana.ac.id/97872/>
- [11] F. X. K. Lile and I. Suharjo, "Optimalisasi Perbandingan Algoritma K-Nearest Neighbors dan Decision Tree untuk Prediksi Kemenangan di MPL Season 13 Mobile Legend," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 4, pp. 7553–7560, 2024, doi: 10.36040/jati.v8i4.10343.
- [12] S. Minami, H. Koyama, K. Watanabe, N. Saijo, and M. Kashino, "Prediction of esports competition outcomes using EEG data from expert players," *Comput. Human Behav.*, vol. 160, p. 108351, 2024, doi: 10.1016/j.chb.2024.108351.
- [13] A. S. Paramita and Jusak, "Predicting Player Performance in Valorant E-Sports Using Random Forest Algorithm," *International Journal Research on Metaverse*, vol. 2, no. 4, 2025, doi: 10.47738/ijrm.v2i4.39.
- [14] L. Breiman, "Random Forests," *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/A:1010933404324.
- [15] M. N. Al-Andoli, A. A. Al-Saffar, and M. A. Al-Juboori, "A Hybrid Parallel Ensemble Learning Framework with Fuzzy ARTMAP to Improve Outcome Prediction in Professional Esports," *International Journal of Distributed Sensor Networks*, vol. 21, no. 6, 2025, doi: 10.1177/15501477251355649.
- [16] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016, pp. 785–794. doi: 10.1145/2939672.2939785.



- [17] L. Ostroumova Prokhorenkova, G. Gusev, A. Vorobev, A. V. Dorogush, and A. Gulin, "CatBoost: unbiased boosting with categorical features," *Neural Information Processing Systems*, vol. 31, pp. 6639–6649, Dec. 2018, [Online]. Available: <https://proceedings.neurips.cc/paper/2018/file/14491b756b3a51daac41c24863285549-Paper.pdf>
- [18] C. B. Widiyatmoko, A. S. Wibowo, and D. H. Pratama, "Unstacking the Stack: Synthesis of Optimization Strategies for Stacked Ensemble Models," *Jurnal Sisfokom*, vol. 15, no. 1, 2025, doi: 10.32736/sisfokom.v15i01.2545.
- [19] F. Pedregosa et al., "Scikit-Learn: Machine Learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011. [Online]. Available: <https://www.jmlr.org/papers/v12/pedregosa11a.html>
- [20] C. Zhao, J. Liu, and E. Parilina, "The Shapley Value Contribution to Explainable Artificial Intelligence: A Comprehensive Survey," *Dynamic Games and Applications*, 2025, doi: 10.1007/s13235-025-00670-2.