

## Perbandingan Sistem Prediksi Cuaca Harian Menggunakan Algoritma SVR dan XGBOOST

**Steven Flianto**

Teknik Informatika Universitas Tarumanagara  
*flianto2004@gmail.com*

### **ABSTRACT**

*Mountain climbing activities are highly influenced by dynamic weather conditions; therefore, a system capable of accurately predicting daily weather is essential. This study focuses on comparing the performance of two machine learning algorithms — Support Vector Regression (SVR) and Extreme Gradient Boosting (XGBoost) — in developing a daily weather prediction system. Weather data were obtained from the Meteorology, Climatology, and Geophysics Agency (BMKG) with parameters including minimum temperature, maximum temperature, average temperature, humidity, rainfall, solar radiation, maximum wind speed, and wind direction. The research stages include data collection, preprocessing, model training using SVR and XGBoost, and performance evaluation using Mean Absolute Error (MAE), Root Mean Square Error (RMSE), Accuracy, and  $R^2$  metrics. The results show that the SVR algorithm performs better than XGBoost in predicting daily weather data, particularly for temperature and humidity variables, with more stable accuracy across various observation stations.*

**Keywords :** *Weather Prediction, SVR, XGBoost.*

### **ABSTRAK**

Aktivitas pendakian gunung sangat dipengaruhi oleh kondisi cuaca yang berubah secara dinamis, sehingga diperlukan sistem yang mampu memprediksi cuaca harian secara akurat. Penelitian ini berfokus pada perbandingan performa dua algoritma *machine learning*, yaitu *Support Vector Regression* (SVR) dan *Extreme Gradient Boosting* (XGBoost), dalam membangun sistem prediksi cuaca harian. Data cuaca diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) dengan parameter suhu minimum, suhu maksimum, suhu rata-rata, kelembapan, curah hujan, penyinaran matahari, kecepatan angin maksimum, dan arah angin maksimum. Tahapan penelitian meliputi pengumpulan dan pra-pemrosesan data, pelatihan model menggunakan SVR dan XGBoost, serta evaluasi performa dengan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Accuracy*, dan  $R^2$ . Hasil penelitian menunjukkan bahwa algoritma SVR memiliki performa yang lebih baik dibandingkan dengan XGBoost dalam memprediksi data cuaca harian, khususnya pada variabel suhu dan kelembapan, dengan tingkat akurasi yang lebih stabil di berbagai stasiun pengamatan.

**Kata kunci :** *Prediksi cuaca, SVR, XGBoost.*

### **PENDAHULUAN**

Aktivitas pendakian gunung merupakan salah satu kegiatan wisata alam yang banyak diminati di Indonesia, khususnya di wilayah Pulau Jawa yang memiliki sejumlah gunung berapi aktif dan tidak aktif. Namun, kegiatan pendakian ini sangat dipengaruhi oleh kondisi cuaca yang berubah-ubah. Wilayah pegunungan memiliki karakteristik iklim yang khas, di mana perubahan cuaca dapat terjadi secara tiba-tiba, ekstrem, dan sulit diprediksi [4]. Fenomena cuaca buruk seperti hujan deras, kabut tebal, serta angin kencang dapat meningkatkan risiko kecelakaan, hipotermia,

tersesat, bahkan bencana alam seperti tanah longsor dan banjir bandang. Oleh karena itu, ketersediaan informasi cuaca yang akurat, detail, dan mudah dipahami sangat penting sebagai dasar pertimbangan sebelum melakukan pendakian [5].

Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) telah menyediakan data cuaca terbuka yang dapat diakses oleh publik [6]. Akan tetapi, data tersebut masih bersifat umum dan belum secara langsung diterjemahkan menjadi informasi praktis berupa rekomendasi pendakian pada tiap gunung. Padahal, kondisi cuaca antar gunung di Pulau Jawa dapat sangat berbeda walaupun lokasinya berdekatan. Misalnya, saat Gunung Semeru mengalami hujan deras dan kabut tebal, Gunung Bromo di waktu yang sama justru dapat berada dalam kondisi cerah dan aman untuk didaki [7]. Situasi ini menunjukkan perlunya sistem cerdas yang mampu mengolah data cuaca harian berdasarkan hasil prediksi kondisi cuaca untuk menghasilkan rekomendasi pendakian yang spesifik, kontekstual, dan adaptif terhadap perubahan cuaca [8].

Seiring dengan perkembangan teknologi digital, penerapan metode *machine learning* menjadi solusi potensial untuk membantu proses prediksi serta klasifikasi data cuaca. Berbagai algoritma telah digunakan dalam bidang klimatologi modern, salah satunya adalah *Support Vector Regression* (SVR) dan *Extreme Gradient Boosting* (XGBoost), yang terbukti efektif menghasilkan prediksi akurat pada kasus-kasus kompleks [9][10][11]. Kedua algoritma ini mampu mengolah data historis cuaca dari BMKG dan mengklasifikasikan kondisi pendakian menjadi kategori tertentu seperti “layak” atau “tidak layak” [12]. Hasil klasifikasi tersebut dapat dimanfaatkan oleh pendaki sebagai acuan pengambilan keputusan, sekaligus mendukung pengelolaan kawasan konservasi serta mitigasi risiko bencana di wilayah pegunungan [13].

Berdasarkan latar belakang tersebut, penelitian ini difokuskan pada perbandingan performa algoritma *Support Vector Regression* (SVR) dan *Extreme Gradient Boosting* (XGBoost) dalam memprediksi data cuaca harian untuk menghasilkan sistem klasifikasi kelayakan pendakian gunung di Pulau Jawa. Dengan adanya sistem rekomendasi berbasis prediksi cuaca ini, diharapkan pendaki dapat memperoleh alternatif pilihan gunung yang lebih aman sesuai dengan kondisi cuaca terkini. Selain itu, sistem ini juga berperan dalam mendukung pengembangan pariwisata berkelanjutan serta peningkatan keselamatan aktivitas pendakian.

## **METODE PENELITIAN**

*Support Vector Regression* (SVR) merupakan algoritma *supervised learning* yang digunakan untuk memprediksi nilai numerik atau kontinu dengan menerapkan konsep yang serupa dengan *Support Vector Machine* (SVM) [14]. Tujuan utama SVR adalah menentukan *hyperplane* yang paling sesuai untuk memodelkan data, sehingga sebanyak mungkin titik data berada dalam batas toleransi tertentu. Berbeda dengan metode regresi konvensional yang berusaha meminimalkan selisih antara nilai aktual dan prediksi, SVR fokus pada menyesuaikan *hyperplane* terbaik di dalam margin toleransi yang telah ditetapkan, sehingga prediksi berada dalam jarak yang dapat diterima dari *hyperplane* [15].

*Hyperplane* adalah garis yang memisahkan kelas data dalam ruang dengan dimensi lebih tinggi daripada dimensi aslinya. Dalam *Support Vector Regression*, *hyperplane* digunakan untuk memperkirakan nilai target yang bersifat kontinu, dan titik-titik data yang paling dekat dengan *hyperplane* disebut sebagai *support vector*

Dalam penerapan metode algoritma *Support Vector Regression* (SVR), *hyperplane* tersebut dapat didefinisikan sebagai fungsi regresi dengan persamaan sebagai berikut [16].

$$\hat{y} = w^T \phi(x) + b \quad (2.1)$$

Keterangan:

$w$  = bobot dari fitur

$x$  = nilai *input* fitur

$b$  = bias yang menggeser *hyperlane*

$\hat{y}$  = hasil dari perhitungan

Selanjutnya kita wajib menentukan jenis kernel yang akan digunakan. Kernel merupakan sekumpulan fungsi matematika yang menerima data sebagai masukan lalu mentransformasikannya ke dalam bentuk lain sesuai kebutuhan. Fungsi kernel berperan penting dalam membantu menemukan *hyperplane* pada ruang berdimensi lebih tinggi. Beberapa jenis kernel yang umum digunakan dalam SVR antara lain kernel RBF, kernel sigmoid, kernel polinomial, dan kernel Gaussian [15]. Untuk kernel yang digunakan adalah kernel *Radial Basis Function* (RBF) dengan fungsi sebagai berikut

$$K(x_i, x_j) = \exp\left(-\gamma \|x_i - x_j\|^2\right) \quad (2.2)$$

Keterangan:

$K(x_i, x_j)$  = nilai kernel antara dua titik data

$\|x_i - x_j\|$  = jarak euclidean

$\gamma$  = parameter kernel yang mengontrol seberapa jauh pengaruh satu data terhadap data lain

Setelah mencari kernel, maka digunakan persamaan prinsip *structural risk minimization* dalam SVR dengan tujuan memperoleh vektor bobot dan bias yang membentuk model dengan kesalahan prediksi serendah mungkin. Fungsi objektif yang digunakan adalah.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\epsilon k + \epsilon k^*) \quad (2.3)$$

Keterangan:

$\epsilon$  = margin toleransi, yaitu batas kesalahan yang masih dapat diterima tanpa dihitung sebagai *error*

$C$  = parameter regularisasi, mengontrol keseimbangan antara kerataan model dengan penalti terhadap *error*

$\epsilon k$  = variabel *slack* (*slack variable*) untuk *error* data yang jatuh di atas batas margin  $\epsilon$

$\epsilon k^*$  = variabel *slack* untuk *error* data yang jatuh di bawah batas margin  $\epsilon$

Dengan kendala sebagai berikut [16].

$$y_i - w^T \phi(x) + b \leq \epsilon + \epsilon k$$

$$\begin{aligned} w^T \phi(x) + b - y_i &\leq \epsilon + \epsilon k^* \\ \epsilon k, \epsilon k^* &\geq 0 \end{aligned} \quad (2.4)$$

Keterangan:

$\epsilon$  = margin toleransi, yaitu batas kesalahan yang masih dapat diterima tanpa dihitung sebagai *error*.

Tahap terakhir untuk melakukan optimasi hasil menggunakan persamaan sebagai berikut [17].

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (2.5)$$

Keterangan:

$f(x)$  = Nilai prediksi

$\alpha_i$  = Margin atas dari hyperplane

$\alpha_i^*$  = Margin bawah dari hyperplane

$K(x_i, x)$  = Kesamaan antara titik data

$b$  = Nilai Bias

## 2.2 Extreme Gradient Boosting (XGBoost)

XGBoost (*Extreme Gradient Boosting*) adalah algoritma *machine learning* berbasis *ensemble* yang mengimplementasikan metode *gradient boosting* untuk membangun model prediksi yang kuat dan efisien. Dikembangkan oleh Tianqi Chen dan Carlos Guestrin padatahun 2016, XGBoost dirancang untuk menangani dataset besar dan kompleks dengan meningkatkan kecepatan dan akurasi model melalui optimasi paralel dan regularisasi pohon keputusan. Algoritma ini telah digunakan secara luas dalam berbagai kompetisi *machine learning* dan aplikasi industri karena kemampuannya dalam menghasilkan model yang akurat dan dapat diinterpretasikan [18].

Metode XGBoost menjalankan proses pembelajaran dengan menyusun beberapa pohon keputusan secara berurutan, sehingga setiap pohon selanjutnya berupaya memperbaiki kesalahan pohon sebelumnya.

Pada setiap iterasi, model XGBoost membangun pohon keputusan yang mengoptimalkan fungsi *loss*. Fungsi *loss* yang umum digunakan adalah sebagai berikut [19].

$$Obj = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (2.6)$$

Keterangan:

$l(y_i, \hat{y}_i)$  = loss yang mengukur selisih antara nilai aktual dan prediksi

$\Omega(f_k)$  = regularisasi pohon keputusan ke- $k$

$n$  = jumlah data

$K$  = Jumlah decision tree

Fungsi regularisasi pada XGBoost dirumuskan untuk mengendalikan jumlah daun dan bobot pada setiap pohon keputusan, sehingga model tidak menjadi terlalu kompleks.

$$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \tag{2.7}$$

$T$  = Jumlah leaf

$w_j$  = bobot prediksi pada leaf

$\gamma$  = penalti untuk menambah jumlah leaf

$\lambda$  = regularisasi L2 untuk mencegah bobot terlalu besar

Prediksi akhir XGBoost adalah hasil penjumlahan dari semua pohon keputusan yang telah dibangun, sehingga model dapat memperbaiki kesalahan secara bertahap [20].

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in F \tag{2.8}$$

$\hat{y}_i$  = nilai prediksi untuk data ke- $i$

$f_k(x_i)$  = output dari pohon keputusan

$F$  = himpunan semua pohon keputusan yang dapat dibangun

$K$  = jumlah pohon keputusan yang digunakan dalam model

### Klasifikasi Thresold

*Threshold* atau ambang batas adalah istilah yang digunakan dalam berbagai bidang, seperti fisika, ekonomi, teknologi, hingga psikologi, yang merujuk pada batas tertentu yang harus dicapai untuk memicu suatu proses, menghasilkan efek, atau mencapai hasil tertentu. Dalam praktiknya, *threshold* berfungsi sebagai pengukur kriteria untuk menentukan apakah suatu kondisi memenuhi syarat, sebagai alat pengendalian risiko dalam manajemen, serta sebagai pemicu aksi yang dapat memulai suatu proses otomatis. Selain itu, *threshold* juga membantu menyederhanakan analisis dengan cara mengabaikan data yang terlalu kecil atau tidak signifikan sehingga fokus dapat diarahkan pada informasi yang lebih penting.

Meskipun memiliki peran penting, penggunaan *threshold* tidak terlepas dari masalah. Penentuan ambang batas yang tidak akurat dapat menyebabkan hasil yang menyimpang, sedangkan sifatnya yang kaku membuat *threshold* kurang fleksibel terhadap perubahan kondisi. Kesalahpahaman juga dapat muncul jika tidak ada kejelasan mengenai cara penetapan ambang batas. Lebih jauh, ketergantungan berlebihan pada *threshold* berisiko mengabaikan faktor lain yang relevan, sementara proses kalibrasi untuk menemukan nilai *threshold* yang ideal sering kali rumit dan memerlukan waktu, terutama saat berhadapan dengan data yang kompleks [21]. Berikut ambang batas kelayakan pendakian untuk mengukur akurasi.

**Tabel 1** Tabel Kelayakan Pendakian

Variabel	LAYAK	TIDAK LAYAK
Suhu Minimum	> 8°C	≤ 8°C

Suhu Maksimum	< 35°C	≥ 35°C
Suhu Rata-rata	10°C – 30°C	≤10°C atau ≥30°C
Kelembapan Rata-rata	40% – 95%	<40% atau >95%
Curah Hujan Harian	< 50 mm/hari	≥ 50 mm/hari
Lama Penyinaran Matahari	> 1.5 jam/hari	≤ 1.5 jam/hari
Kecepatan Angin Maksimum	< 20 km/jam	≥ 20 km/jam
Rata-rata Kecepatan Angin	<10 km/jam	≥ 10 km/jam

## HASIL DAN PEMBAHASAN

### Hasil SVR

Setelah dilakukannya 7 percobaan hasil evaluasi dari algoritma Support Vector Regression (SVR) menunjukkan performa yang stabil dan akurat dalam memprediksi data cuaca harian di berbagai stasiun. Berdasarkan serangkaian percobaan yang dilakukan, konfigurasi parameter terbaik diperoleh pada percobaan ke-6, yaitu dengan nilai  $C = 100$ ,  $\epsilon = 0.01$ , dan  $\gamma = 0.001$ . Berikut hasil evaluasi yang didapat terhadap 14 *dataset* stasiun pada **Tabel 2**.

**Tabel 2** Rata-rata Hasil Evaluasi SVR 14 Stasiun

Lokasi Stasiun	MAE	RMSE	Akurasi	$R^2$
Pasuruan	0.193	0.233	99.5%	0.996
Kertajati	0.197	0.267	99.7%	0.998
Citeko	0.156	0.196	99.8%	0.996
Banyuwangi	0.127	0.175	99.8%	0.997
Dhoho	0.330	0.553	99.3%	0.994

Sleman	0.141	0.183	99.7%	0.998
Bandung	0.200	0.238	99.7%	0.997
Banjarnegara	0.191	0.220	99.8%	0.964
Maritim Serang	0.195	0.267	99.9%	0.997
Jawa Barat	0.201	0.237	99.8%	0.997
Malang	0.133	0.176	99.8%	0.998
Maritim Tegal	0.167	0.218	99.8%	0.998
Nganjuk	0.203	0.245	99.8%	0.995
Jawa Tengah	0.191	0.249	99.5%	0.998

Model SVR dengan parameter tersebut memberikan hasil prediksi yang konsisten dengan nilai kesalahan yang relatif rendah serta akurasi yang tinggi pada sebagian besar variabel cuaca, seperti suhu dan kelembapan. Hasil ini menunjukkan bahwa SVR efektif digunakan untuk menangani pola data cuaca yang bersifat nonlinier dan berfluktuasi.

### Hasil XGBoost

Berdasarkan dilakukannya 17 percobaan pada algoritma Extreme Gradient Boosting (XGBoost), hasil evaluasi menunjukkan performa yang kompetitif namun sedikit di bawah SVR dalam hal kestabilan prediksi antar stasiun. Parameter terbaik diperoleh pada **percobaan ke-10**, dengan konfigurasi **learning\_rate = 0.01**, **n\_estimators = 1200**, **max\_depth = 4**, **min\_child\_weight = 1**, **subsample = 0.9**, **colsample\_bytree = 0.9**, **gamma = 0**, **reg\_alpha = 0**, dan **reg\_lambda = 1**. Berikut hasil evaluasi yang didapat terhadap 14 *dataset* stasiun pada **Tabel 3**.

**Tabel 1** Rata-rata Hasil Evaluasi XGBoost 14 Stasiun

Lokasi Stasiun	MAE	RMSE	Akurasi	$R^2$
Pasuruan	0.291	0.654	99.3%	0.980
Kertajati	0.295	0.857	99.4%	0.976

Citeko	0.333	0.824	99.3%	0.973
Banyuwangi	0.218	0.563	99.3%	0.982
Dhoho	0.937	2.232	96.6%	0.863
Sleman	0.322	1.064	99.2%	0.966
Bandung	0.270	0.539	99.7%	0.978
Banjarnegara	0.339	0.681	99.7%	0.955
Maritim Serang	0.312	0.603	99.3%	0.965
Jawa Barat	0.486	0.809	98.8%	0.942
Malang	0.275	0.818	99.5%	0.961
Maritim Tegal	0.255	0.752	99.3%	0.978
Nganjuk	0.369	0.753	99.5%	0.980
Jawa Tengah	0.291	0.742	99.1%	0.979

Dengan parameter tersebut, XGBoost mampu menghasilkan prediksi dengan tingkat akurasi tinggi, terutama pada variabel curah hujan dan penyinaran. Namun, dibandingkan dengan SVR, XGBoost memiliki sedikit penurunan performa pada variabel kecepatan angin rata-rata (FF\_AVG), yang menunjukkan bahwa model ini kurang optimal dalam menangani fluktuasi ekstrem pada data tersebut.

#### **KESIMPULAN**

Hasil pengujian model menunjukkan bahwa algoritma *Support Vector Regression* (SVR) secara konsisten memberikan performa yang lebih baik dibandingkan dengan XGBoost pada hampir seluruh stasiun yang diuji. Berdasarkan hasil evaluasi menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), akurasi, dan koefisien determinasi ( $R^2$ ), model SVR menunjukkan nilai eror yang lebih rendah dan tingkat akurasi yang lebih tinggi secara keseluruhan.

Nilai MAE dan RMSE yang diperoleh SVR umumnya berada pada kisaran 0,12 hingga 0,33 dan 0,17 hingga 0,55, sementara XGBoost memiliki kisaran eror yang lebih tinggi, yaitu 0,21 hingga 0,93 untuk MAE dan 0,56 hingga 2,23 untuk RMSE. Tingkat akurasi yang dihasilkan SVR berkisar antara 99,3% hingga 99,9%, sedangkan XGBoost sedikit lebih rendah dengan kisaran 96,6% hingga 99,7%. Selain itu, nilai  $R^2$

SVR berada pada rentang 0,994 hingga 0,998, menunjukkan kemampuan model yang sangat baik dalam menjelaskan variabilitas data target, sementara XGBoost memiliki nilai  $R^2$  yang lebih bervariasi, antara 0,863 hingga 0,982.

#### DAFTAR PUSTAKA

- A. N. Innayah, D. I. Sulistiana, M. Y. Febrian, dan F. Kartiasih, "UTILIZING THE SARIMA MODEL AND SUPPORT VECTOR REGRESSION TO FORECAST MONTHLY RAINFALL IN BANDUNG CITY," *Jurnal Ilmiah Teknologi Infomasi Terapan*, vol. 10, no. 2, Apr 2024, doi: 10.33197/jitter.vol10.iss2.2024.1663.
- A. Nugroho, "Risiko Pendakian Gunung di Indonesia," *Geografi Indonesia*, vol. 9, no. 1, hlm. 88–95, 2021.
- A. R. I. Pratama, S. A. Latipah, dan B. N. Sari, "OPTIMASI KLASIFIKASI CURAH HUJAN MENGGUNAKAN SUPPORT VECTOR MACHINE (SVM) DAN RECURSIVE FEATURE ELIMINATION (RFE)," *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 7, no. 2, hlm. 314–324, Mei 2022, doi: 10.29100/jipi.v7i2.2675.
- Badan Nasional Penanggulangan Bencana, "Pedoman Mitigasi Bencana di Wilayah Pegunungan," Jakarta, 2020.
- Balai Besar Taman Nasional Gunung Gede Pangrango, "Laporan Kunjungan Wisatawan," 2022.
- F. Syarif dan S. Darmanto, "Perbandingan XGBoost dan Random Forest dalam Prediksi Hujan," *Jurnal Teknologi Informatika*, 2020.
- Firga, "Threshold: Pengertian, Fungsi, dan Tantangan dalam Berbagai Konteks," Tanah.com. Diakses: 19 September 2025. [Daring]. Tersedia pada: <https://tanah.com/info/threshold-pengertian-fungsi-dan-tantangan-dalam-berbagai-konteks/>
- K. dan G. Badan Meteorologi, "Data Cuaca Harian," Badan Meteorologi, Klimatologi, dan Geofisika
- Kantinit, "Support Vector Machine (SVM): Pengertian, Jenis, dan Cara Kerja," Kantinit. Diakses: 5 September 2025. [Daring]. Tersedia pada: [https://kantinit.com/kecerdasan-buatan/support-vector-machine-svm-pengertian-jenis-dan-cara-kerja/#google\\_vignette](https://kantinit.com/kecerdasan-buatan/support-vector-machine-svm-pengertian-jenis-dan-cara-kerja/#google_vignette)
- Kementerian Pariwisata, "Statistik Wisata Alam Indonesia," Jakarta, 2022.
- M. Yuliani, "Variabilitas Cuaca Mikro di Pegunungan Jawa Barat," *Jurnal Meteorologi Indonesia*, vol. 15, no. 2, hlm. 135–142, 2022.
- N. Fadhil, "Perbandingan Akurasi Algoritma XGBoost dan SVR dalam Prediksi Harga Cryptocurrency," Universitas Tarumanagara, Jakarta, 2024. Diakses: 8 Agustus 2025. [Daring]. Tersedia pada: <http://repository.untar.ac.id/46066/>
- NVIDIA, "What Is XGBoost and Why Does It Matter?," NVIDIA. Diakses: 29 Agustus 2025. [Daring]. Tersedia pada: <https://www.nvidia.com/en-us/glossary/xgboost/>
- P. ; L. Y. ; W. Z. Zhang, "A review of machine learning algorithms for big data analytics," *J Algorithm Comput Technol*, vol. 16, hlm. 1–20, 2022.

- Pahrul, "Perbandingan Metode Klasifikasi Random Forest, XGBoost, dan SVM Pada Analisis Sentimen Aplikasi Kredit dan Pinjaman Online," Universitas Hasanuddin, Gowa, 2023. Diakses: 2 September 2025. [Daring]. Tersedia pada: [https://repository.unhas.ac.id/id/eprint/31467/2/D121191020\\_skripsi\\_04-08-2023%20bab%201-2.pdf](https://repository.unhas.ac.id/id/eprint/31467/2/D121191020_skripsi_04-08-2023%20bab%201-2.pdf)
- Rachman, "Tren Wisata Alam dan Pendakian di Indonesia," *Jurnal Pariwisata Nusantara*, vol. 8, no. 2, hlm. 112–120, 2021.
- S. F. N. Islam, A. Sholahuddin, dan A. S. Abdullah, "Extreme gradient boosting (XGBoost) method in making forecasting application and analysis of USD exchange rates against rupiah," *J Phys Conf Ser*, vol. 1722, no. 1, hlm. 012016, Jan 2021, doi: 10.1088/1742-6596/1722/1/012016.
- T. Chen dan C. Guestrin, "XGBoost: A Scalable Tree Boosting System," Jun 2016, doi: 10.1145/2939672.2939785.
- Trivusi, "Algoritma Support Vector Regression (SVR): Jenis SVM untuk Regresi," Trivusi. Diakses: 16 September 2025. [Daring]. Tersedia pada: <https://www.trivusi.web.id/2022/08/algoritma-svr.html>
- U. N. Christanto, "Prediksi Suhu Maksimum Harian di Indonesia Berbasis Kluster Menggunakan Algoritma K-Means Clustering, Support Vector Regression, Random Forest, dan Extreme Gradient Boosting," Universitas Internasional Semen Indonesia, Gresik, 2025. Diakses: 15 September 2025. [Daring]. Tersedia pada: <https://repository.uisi.ac.id/id/eprint/7697>
- Y. Rombe, "Penggunaan Metode XGBoost Untuk Klasifikasi Status Obesitas di Indonesia," *Jurnal Ilmiah Teknologi Informasi & Komunikasi (JITIKA)*, vol. 12, no. 2, 2021, Diakses: 2 September 2025. [Daring]. Tersedia pada: [https://repository.unhas.ac.id/id/eprint/13027/2/H12115303\\_skripsi\\_24-01-2022%201-2.pdf](https://repository.unhas.ac.id/id/eprint/13027/2/H12115303_skripsi_24-01-2022%201-2.pdf)