



**PENGEMBANGAN MODEL PREDIKSI CURAH HUJAN HARIAN DI WILAYAH
JAKARTA MENGGUNAKAN GRADIENT BOOSTING MACHINES (GBMs)
DAN GAME THEORY INTERPRETATION**

***DEVELOPMENT OF A DAILY RAINFALL PREDICTION MODEL IN THE REGION OF
JAKARTA USING GRADIENT BOOSTING MACHINES (GBMs) AND GAME THEORY
INTERPRETATION***

Abiyu Azriel, Departemen Pendidikan Fisika, Universitas Negeri Yogyakarta, Indonesia

Denny Darmawan*, Departemen Pendidikan Fisika, Universitas Negeri Yogyakarta,
Indonesia

Eddy Hermawan, Badan Riset dan Inovasi Nasional, Indonesia

*e-mail: darmawan@uny.ac.id (corresponding author)

Abstrak. Sebagai pusat pemerintahan dan ekonomi negara, Jakarta merupakan wilayah dengan tingkat rentabilitas yang tinggi terhadap kerugian ekonomi akibat bencana banjir. Hal ini menjadi pendorong bahwa perlunya pengembangan model prediksi untuk memberikan informasi lebih akurat terkait potensi curah hujan harian di wilayah Jakarta. Penelitian ini bertujuan untuk mengembangkan model prediksi yang akurat dengan pendekatan *machine learning* dari algoritma *Gradient Boosting Machines* (GBMs) yang mencakup XGBoost, LightGBM dan CatBoost. Dalam penelitian ini juga mengaplikasikan konsep *game theory* untuk memberikan wawasan mendalam tentang faktor-faktor utama pemicu intensitas curah hujan. Data curah hujan harian dikumpulkan bersama dengan berbagai variabel prediktor yang berkaitan dengan kondisi meteorologi. Penerapan teknik GBMs menggunakan model regresi dengan optimalisasi model diperkuat oleh optuna *hyperparameter tuning* dan *features selection* berbasis algoritma SHAP. Evaluasi model dilakukan menggunakan metrik statistik RMSE, MAE dan R^2 untuk mengukur tingkat akurasi prediksi. Hasil penelitian mengungkap bahwa ketiga model GBMs yang dioptimalkan dengan *features selection* dan *hyperparameter tuning* mencapai akurasi testing diatas 70%. XGBoost menunjukkan performa terbaik dalam memprediksi curah hujan harian di wilayah Jakarta. Sementara penerapan *game theory* mengungkap bahwa variabilitas suhu udara pada ketinggian 2 meter di atas permukaan tanah (t2m) sebagai fitur dengan kontribusi terbesar terhadap nilai akurasi ketiga model GBMs. Selain t2m, tiga fitur teratas lainnya adalah kepadatan total air cair dalam kolom udara (trcw), konvergensi aliran kelembaban yang terintegrasi secara vertikal (vimfc) dan kelembaban relatif pada level tekanan 700 hPa (rh700).

Kata Kunci: *Machine learning, gradient boosting machines, curah hujan, game theory*

Abstract. As the center of government and the economy of country, Jakarta is an area with a high level of profitability against economic losses due to flood disasters. This is the driving force for the need to develop a prediction model to provide more accurate information regarding potential daily rainfall in the Jakarta area. This research aims to develop an

accurate prediction model using a machine learning approach from the Gradient Boosting Machines (GBMs) algorithm which includes XGBoost, LightGBM and CatBoost. This research also applies the concept of game theory to provide in-depth insight into the main factors that trigger rainfall intensity. Daily rainfall data is collected along with various predictor variables related to meteorological conditions. The application of the GBMs technique uses a regression model with model optimization strengthened by optuna hyperparameter tuning and features selection based on the SHAP algorithm. Model evaluation was carried out using the statistical metrics RMSE, MAE and R^2 to measure the level of prediction accuracy. The research results reveal that the three GBMs models optimized with feature selection and hyperparameter tuning achieved testing accuracy above 70%. XGBoost shows the best performance in predicting daily rainfall in the Jakarta area. Meanwhile, the application of game theory reveals that air temperature variability at a height of 2 meters above ground level (t2m) is the feature with the largest contribution to the accuracy value of the three GBMs models. Besides t2m, the other top three features are the total density of liquid water in the air column (tcrw), the vertically integrated moisture flow convergence (vimfc) and the relative humidity at the 700 hPa pressure level (rh700).

Keywords: *Machine learning, gradient boosting machines, rainfall, game theory*

PENDAHULUAN

Indonesia, dengan karakteristik geografis uniknya, mengalami variasi curah hujan harian yang dipengaruhi oleh faktor beragam (Lee, 2015). Jakarta sebagai Ibu Kota Indonesia, rawan terhadap banjir akibat curah hujan ekstrem (Setiawan & Ma'mun, 2021). Penelitian menunjukkan peningkatan tren curah hujan ekstrem di Indonesia (Siswanto et al., 2022), terutama tragedi pada awal 2020 yang mengakibatkan dampak signifikan (Berlinger & Yee, 2020). Curah hujan menjadi parameter penting dalam manajemen sumber daya air dan mitigasi bencana di Jakarta (Lubis et al., 2022).

Prediksi curah hujan menggunakan machine learning di Indonesia telah menjadi topik penelitian yang banyak dijelajahi. Namun, keakuratan prediksi tetap menjadi tantangan utama, memerlukan pengembangan model dengan resolusi harian yang cepat (harian). Jakarta dihadapkan pada tantangan cuaca ekstrem, membutuhkan model prediksi yang mampu mengatasi perubahan cepat dalam sistem atmosfer (Kulkarni et al., 2023).

Algoritma Gradient Boosting Machines (GBMs), seperti XGBoost, LightGBM, dan CatBoost, telah menjadi fokus utama dalam meningkatkan akurasi prediksi (Saputra & Oktarina, 2023). Kajian sebelumnya telah membandingkan kinerja ketiga algoritma GBMs untuk prediksi curah hujan (Boldini et al., 2023).

Prediksi curah hujan memerlukan pemodelan multivariat dengan mempertimbangkan faktor seperti angin, suhu, tekanan, dan kelembapan. Game theory digunakan untuk memahami interaksi dan pemilihan subset fitur yang strategis dalam prediksi curah hujan (Jing, 2022; Wang et al., 2021). Gabungan algoritma GBMs dan interpretasi game theory diharapkan memberikan prediksi yang lebih akurat dan menyoroti faktor pendorong utama curah hujan harian di Jakarta.

METODE

Data curah hujan beserta prediktor diperoleh dari ERA-5, sementara beberapa prediktor tambahan kami peroleh dari MERRA-2. Langkah-langkah teknis yang diterapkan meliputi pengumpulan data, preprocessing data mentah, eksplorasi data, pembangunan model dengan GBM, optimisasi model dengan menggunakan metode SHAP dan penyetulan *hyperparameter tuning* menggunakan Optuna. Tiga algoritma GBMs, yaitu XGBoost,

lightGBM, dan Catboost dilatih pada data pelatihan yang telah diproses sebelumnya. Pemrosesan model GBMs diurutkan sebagai berikut:


1. *Default* model: langkah pertama komputasi model dimulai dengan membangun model tanpa adanya perlakuan khusus untuk meningkatkan akurasi. Model *default* dibangun sebagai tolak ukur pertama terhadap perubahan optimalisasi model selanjutnya.
2. Optimasi model menggunakan *features selection*: Pada model *default*, semua prediktor sebanyak 54 fitur dimasukan tanpa pengecualian. Fitur-fitur prediktor yang terlalu banyak dapat memperumit pemahaman model. Dalam proses optimasi dengan *features selection*, fokus utama adalah untuk mengurangi kompleksitas dengan memilih fitur yang paling relevan dan signifikan dalam memprediksi curah hujan. Hal ini membantu model untuk lebih fokus pada informasi yang benar-benar penting, memungkinkan pemodelan yang lebih efisien dan peningkatan kinerja dalam prediksi curah hujan harian.
3. Optimasi model dengan penyetalan *hyperparameter tuning*: *Hyperparameter* setiap model dioptimalkan menggunakan optuna. Optuna merumuskan optimasi *hyperparameter* sebagai proses meminimalkan atau memaksimalkan fungsi tujuan dengan *input* berupa pendefinisian ruang fungsi parameter dan mengembalikannya sebagai *output* berdasarkan skor validasi yang diperoleh (Akiba *et al.*, 2019).

Evaluasi model dilakukan menggunakan metrik statistik RMSE, MAE, dan *R-Squared* untuk menilai performa dan akurasi prediksi. Integrasi *game theory* dalam proses interpretasi model prediksi berperan dalam mengidentifikasi faktor krusial yang memengaruhi prediksi curah hujan harian di wilayah Jakarta.

HASIL DAN PEMBAHASAN

Korelasi Fitur

Korelasi antar variabel adalah ukuran statistik yang digunakan untuk mengukur sejauh mana dua variabel berinteraksi atau berhubungan satu sama lain dalam suatu *dataset*.



Gambar 1. Korelasi Fitur Prediktor terhadap Target.

Loss by eliminated features menunjukkan sebanyak 30 fitur dieliminasi berdasarkan nilai *loss value* kepada model. Tersisa 25 fitur terpilih yang dimasukkan tahap. Tabel 1 memperlihatkan adanya peningkatan akurasi pada model GBMs setelah tahap *features selection* berbasis SHAP. Akurasi berdasarkan *R-Squared* pada XGBoost naik sebesar 6,35%, LightGBM naik sebesar 4,48% dan CatBoost naik sebesar 4,41%. Pada tahap ini, evaluasi algoritma CatBoost masih memiliki akurasi tertinggi dibanding dua model lainnya.

Tabel 1. Evaluasi *R-Squared* GBMs Setelah Menerapkan *Features Selection*

<i>Stages</i>	XGBoost R^2 (testing set)	LightGBM R^2 (testing set)	CatBoost R^2 (testing set)
<i>Default</i>	0,63	0,67	0,68
<i>Features Selection</i>	0,67	0,70	0,71

Hyperparameter Tuning

Tahap kedua dalam optimalisasi model GBMs adalah dengan mengatur parameter algoritma GBMs. Dalam upaya untuk mengoptimalkan model GBMs, digunakan *framework* optuna untuk penyetelan *hyperparameter* yang efisien. Optuna menguji berbagai kombinasi parameter ini secara otomatis dalam setiap iterasi dengan melatih model GBMs berulang kali dan mengukur performanya menggunakan metrik evaluasi *R-Squared* (R^2). Selama proses ini, Optuna akan mencatat hasil dari setiap percobaan, kemudian iterasi berikutnya ditentukan berdasarkan hasil-hasil sebelumnya. Tabel 2 memperlihatkan peningkatan akurasi pada model GBMs dengan implementasi *hyperparameter tuning* menggunakan Optuna.

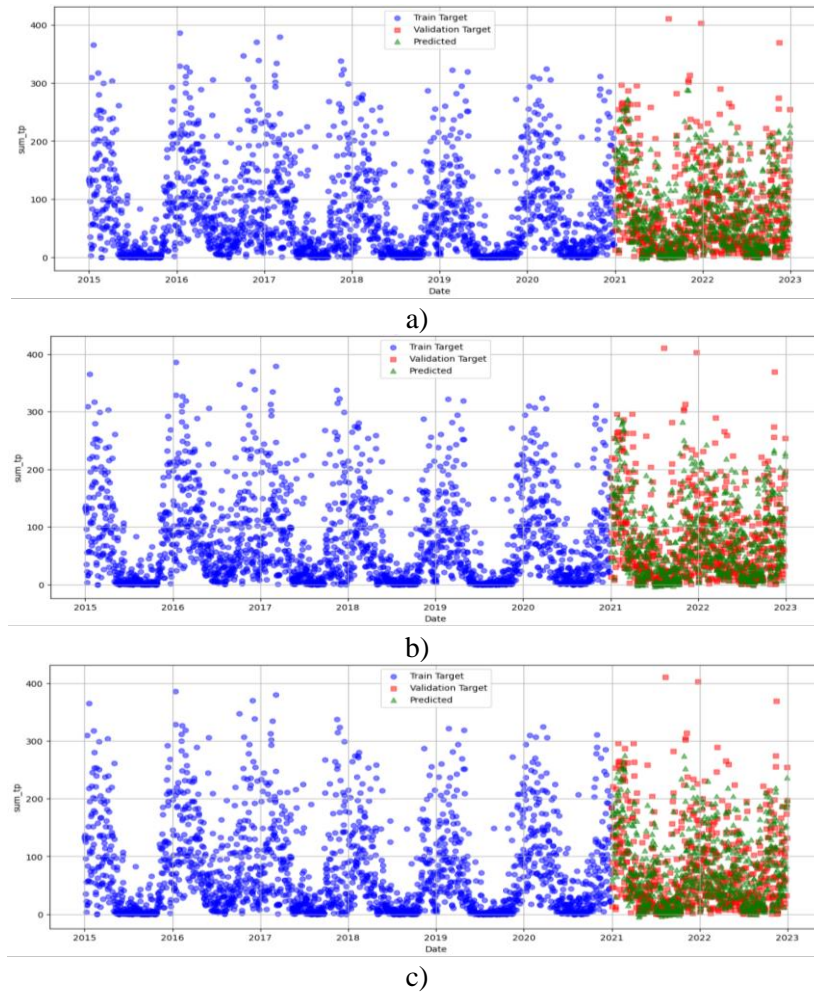
Tabel 2. Evaluasi *R-Squared* GBMs Setelah Menerapkan *Features Selection* dan *Hyperparameter Tuning*

<i>Stages</i>	XGBoost R^2 (testing set)	LightGBM R^2 (testing set)	CatBoost R^2 (testing set)
<i>Default</i>	0,63	0,67	0,68
<i>Features Selection</i>	0,67	0,70	0,71
<i>Hyperparameter Tuning</i>	0,73	0,72	0,72

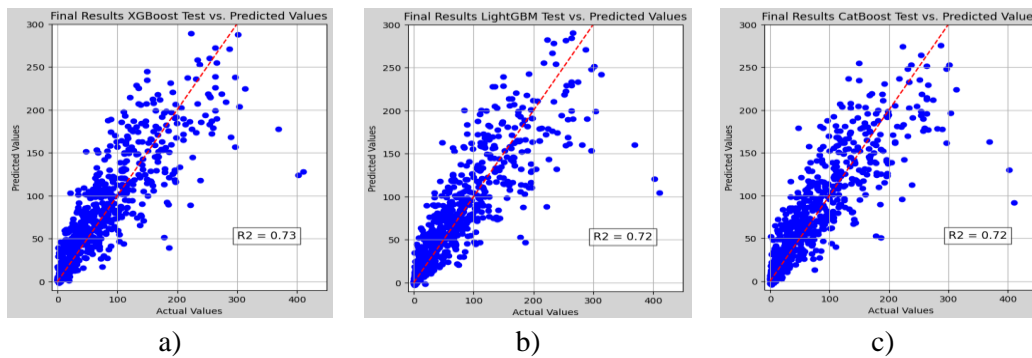
Akurasi berdasarkan *R-Squared* pada XGBoost naik sebesar 8,96%, LightGBM naik sebesar 2,86% dan CatBoost naik sebesar 1,41%. Pada tahap ini, evaluasi metrik R^2 masing-masing model yang telah dioptimalkan menunjukkan bahwa algoritma XGBoost memiliki akurasi tertinggi.

Model Optimal GBMs

Secara umum, model-model telah menghasilkan prediksi yang lebih akurat daripada model *default*. Peningkatan dalam hasil prediksi tercermin dalam metrik evaluasi *R-Squared* (R^2). Hal ini mengindikasikan bahwa model-model yang dioptimalkan lebih mendekati nilai sebenarnya dalam memprediksi curah hujan harian di wilayah Jakarta. Gambar 5 dan 6 memperlihatkan grafik prediksi model akhir GBMs dan metrik evaluasi *R-Squared* (R^2) setelah optimalisasi dengan *features selection* dan *hyperparameter tuning*.



Gambar 5. (a) Grafik Prediksi Model Optimal XGBoost, (b) Grafik Prediksi Model Optimal LightGBM dan (c) Grafik Prediksi Model Optimal CatBoost.




Gambar 6. (a) Grafik R^2 Model Optimal XGBoost, (b) Grafik R^2 Model Optimal LightGBM dan (c) Grafik R^2 Model Optimal CatBoost.

Gambar 5 menunjukkan bahwa hasil prediksi tahap *testing* (titik berwarna hijau) oleh ketiga model GBMs cukup mampu mensimulasikan curah hujan harian di wilayah Jakarta. Koefisien determinasi R^2 pada Gambar 6 menunjukkan kecocokan data prediksi (*testing*) ketiga model GBMs dengan data aktual (*validation*) telah melebihi 70%. Tabel 3 memperlihatkan bahwa saat pelatihan (*training set*), ketiga model GBMs mempunyai akurasi yang tinggi.

Tabel 3. Metrik Evaluasi Kinerja Model GBMs dari Kumpulan Data Pelatihan dan Pengujian

<i>Data Type</i>	<i>Metrics</i>	GBMs		
		XGBoost	LightGBM	CatBoost
<i>Training Set</i>	RMSE	5,97	2,29	3,31
	MAE	4,49	1,63	2,42
	R^2	0,99	0,99	0,99
<i>Testing Set</i>	RMSE	37,15	37,50	37,69
	MAE	24,37	24,09	24,65
	R^2	0,73	0,72	0,72

Model GBMs (XGBoost, LightGBM, dan CatBoost) cenderung "menghafal" pola data training, menangkap noise atau fluktuasi kecil yang mungkin tidak berlaku secara umum. Ini mengakibatkan kesulitan model dalam menggeneralisasi dan menerapkan pengetahuan pada data yang belum pernah dilihat sebelumnya, menyebabkan penurunan akurasi saat diuji pada dataset baru. Temuan ini sejalan dengan penelitian sebelumnya oleh Saputra & Oktarina (2023) dan Boldini et al. (2023). Gambar 7 memperlihatkan perbandingan ketiga nilai residu (*residual plot*) model optimal GBMs.



Gambar 7. a) Grafik Residual Model Optimal XGBoost, b) Grafik Residual Model Optimal LightGBM dan c) Grafik Residual Model Optimal CatBoost.

Sebagian besar nilai residu berada dalam jangkauan yang wajar dari nilai nol, dan nilai-nilai ekstrem jarang terjadi. Namun, beberapa nilai terjauh residu ketiga model berada pada titik positif (Tabel 4). Hal ini mengindikasikan bahwa ketiga model tersebut cenderung melakukan prediksi yang lebih rendah daripada nilai sebenarnya.

Tabel 4. Residual Maksimum dan Minimum Model GBMs

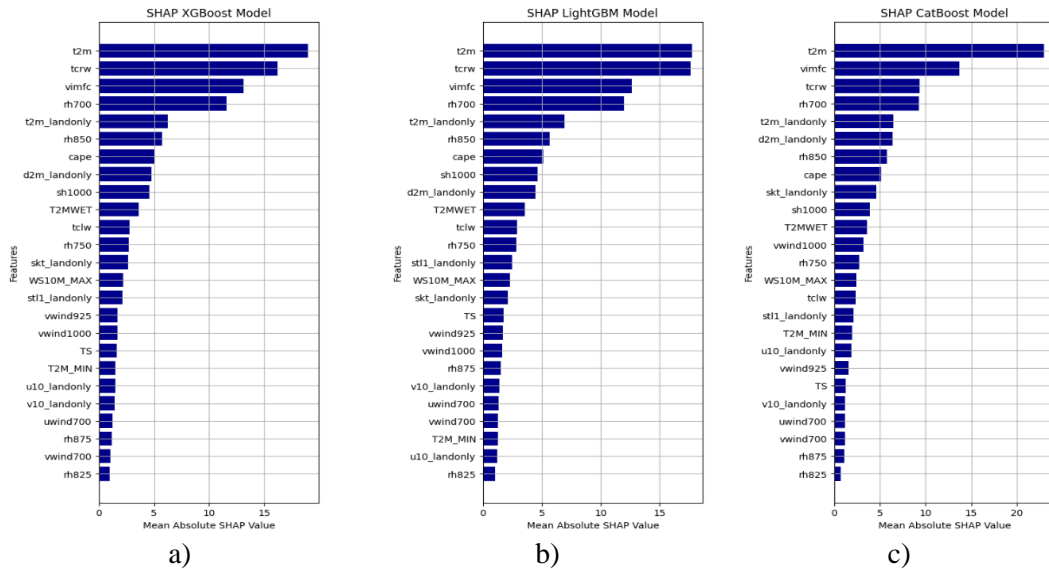
GBMs Model	<i>Maximum Residual</i>	<i>Minimum Residual</i>
XGBoost	282,99	-104,36
LightGBM	306,62	-116,53
CatBoost	318,80	-132,18

Sesuai dengan akurasi metrik R^2 , model XGBoost memiliki sebaran residu maksimum dan minimum paling kecil dari dua model lainnya.

Game Theory Interpretation

Gambar 8 memperlihatkan bahwa kontribusi individual dari fitur suhu udara pada ketinggian 2 meter di atas permukaan tanah (t2m) adalah yang terbesar terhadap akurasi model diukur menggunakan SHAP values. Dalam konsep *game theory*, fitur "t2m" adalah pemain yang paling berkontribusi besar dalam permainan kooperatif XGBoost, LightGBM

dan Catboost. Hal ini mengisyaratkan bahwa variabilitas suhu udara pada ketinggian 2 meter di atas permukaan tanah berkontribusi secara kritis dalam memahami fenomena hujan harian yang diamati. Selain mendapat informasi tentang fitur kunci “t2m” sebagai prediktor utama, dapat diamati pula bahwa model XGBoost dan LightGBM memiliki kemiripan dalam hal urutan fitur prediktor terpenting yang berkontribusi kepada akurasi.



Gambar 8. a) SHAP Values Model XGBoost, b) SHAP Values Model LightGBM dan c) SHAP Values Model CatBoost.

SIMPULAN

Setelah melakukan penelitian mengenai pengembangan model prediksi curah hujan menggunakan GBMs, kesimpulan yang diambil dapat dituliskan sebagai berikut:

1. Performa model prediksi GBMs yang telah dioptimalkan diukur menggunakan metrik evaluasi dengan data training 75 % pada algoritma: XGBoost menghasilkan nilai RMSE = 5.97, MAE = 4.49 dan $R^2 = 0.99$, LightGBM menghasilkan nilai RMSE = 2.29, MAE = 1.62 dan $R^2 = 0.99$ dan CatBoost menghasilkan nilai RMSE = 13.31, MAE = 2.42 dan $R^2 = 0.99$. Sedangkan pada tahap testing 25%, performa model GBMs pada algoritma XGBoost menghasilkan nilai RMSE = 37.15, MAE = 24.37 dan $R^2 = 0.73$, LightGBM menghasilkan nilai RMSE = 37.69, MAE = 24.65 dan $R^2 = 0.72$ dan CatBoost menghasilkan nilai RMSE = 37.50, MAE = 24.09 dan $R^2 = 0.72$.
2. Berdasarkan metrik evaluasi, algoritma GBMs yang memiliki akurasi terbaik pada tahap testing untuk model prediksi curah hujan adalah XGBoost.
3. Game theory telah meningkatkan akurasi prediksi tahap testing berdasarkan metrik evaluasi R
4. Pada algoritma XGBoost dari akurasi default sebesar 0.63 menjadi 0.67, LightGBM dari akurasi default sebesar 0.67 menjadi 0.7 dan CatBoost dari akurasi default sebesar 0.68 menjadi 0.71. Game theory mengoptimalkan model melalui features selection dengan mengeliminasi fitur-fitur lemah dan mempertahankan fitur-fitur kuat terhadap model. Fitur yang memiliki kontribusi paling besar terhadap nilai akurasi ketiga model GBMs untuk memprediksi curah hujan adalah variabilitas suhu udara pada ketinggian 2 meter di atas permukaan tanah (t2m). Setelah t2m, fitur lainnya

yang memiliki kontribusi 4 teratas adalah kepadatan total air cair dalam kolom udara (tcw), konvergensi aliran kelembaban yang terintegrasi secara vertikal (vimfc) dan kelembaban relatif pada level tekanan 700 hPa (rh700).

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Dosen Pembimbing dan pihak-pihak yang telah berperan penting dalam pelaksanaan penelitian.

DAFTAR PUSTAKA

- Saputra, A. H., & Oktarina, S. (2023a). Comparing the Performance of Three Decision Tree Models for Precipitation Prediction in Cengkareng Soekarno Hatta. *Jurnal Aplikasi Meteorologi*, 1(2). <https://doi.org/10.36754/jam.v1i2.318>
- Boldini, D., Grisoni, F., Kuhn, D., Friedrich, L., & Sieber, S. A. (2023). Practical guidelines for the use of gradient boosting for molecular property prediction. *Journal of Cheminformatics*, 15(1). <https://doi.org/10.1186/s13321-023-00743-7>
- Wang, S. S. C., Qian, Y., Leung, L. R., & Zhang, Y. (2021). Identifying Key Drivers of Wildfires in the Contiguous US Using Machine Learning and Game Theory Interpretation. *Earth's Future*, 9(6). <https://doi.org/10.1029/2020EF001910>
- Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). *Optuna: A Next-generation Hyperparameter Optimization Framework*. <http://arxiv.org/abs/1907.10902>
- Aldrian, E., & Dwi Susanto, R. (2003). Identification of three dominant rainfall regions within Indonesia and their relationship to sea surface temperature. *International Journal of Climatology*, 23(12), 1435–1452. <https://doi.org/10.1002/joc.950>
- Anghel, A., Papandreou, N., Parnell, T., De Palma, A., & Pozidis, H. (2018). *Benchmarking and Optimization of Gradient Boosting Decision Tree Algorithms*. <http://arxiv.org/abs/1809.04559>