

## STUDI LITERATUR: OPTIMASI ALGORITMA MACHINE LEARNING UNTUK PREDIKSI PENERIMAAN MAHASISWA PASCASARJANA

Burhanudin Zuhri<sup>1</sup>, Nisa Hanum Harani<sup>2</sup>

<sup>1,2</sup>Program Studi Teknik Informatika, Sekolah Vokasi, Universitas Logistik dan Bisnis Internasional

<sup>1</sup>burhanudinzuhri25@gmail.com, <sup>2</sup>nisa@ulbi.ac.id

### **Abstract**

*Machine learning algorithms are mathematical procedures used to find complex and hidden patterns in data with a high degree of accuracy and have brought major advances in various fields for fast and precise decision making. One of these fields is the field of education, which is to predict the admissions process for postgraduate students. The purpose of admitting postgraduate students is to select prospective students who are qualified and meet the academic requirements set by the institution concerned based on GRE (Graduate Record Examination) scores, TOEFL (Test of English as a Foreign Language) scores, university rankings, letters of recommendation, GPA bachelor degree, and research experience. Success in postgraduate admissions can open opportunities to earn advanced degrees and acquire more in-depth knowledge and skills in areas of interest. In this study, an analysis was carried out on various machine learning algorithm optimizations used to optimize topics or trends in previous studies. In this case, the researcher compares performance and selects the best algorithm optimization to be applied to the topic of graduate student admissions. The results of this review show that the hybrid algorithm has the best performance in optimizing predictions for most of the data in previous studies. The results of this study indicate that the CNN-LSTM (Convolutional Neural Network - Long Short-Term Memory) hybrid model is expected to be an appropriate alternative in optimizing predictions of postgraduate student admissions. Therefore, further research is needed to develop this algorithm and expand its application to the topic of graduate student admissions.*

**Keywords:** Prediction of Graduate Admissions, Systematic Literature Review, Optimization, Machine Learning, Algorithms.

### **Abstrak**

Algoritma *machine learning* merupakan prosedur matematis yang digunakan untuk menemukan pola yang kompleks dan tersembunyi dalam data dengan tingkat akurasi yang tinggi serta telah membawa kemajuan besar dalam berbagai bidang untuk pengambilan keputusan secara cepat dan tepat. Salah satu bidang tersebut adalah bidang pendidikan yaitu untuk melakukan prediksi pada proses penerimaan mahasiswa pascasarjana. Tujuan penerimaan mahasiswa pascasarjana ini adalah untuk menyeleksi calon mahasiswa yang berkualitas dan memenuhi persyaratan akademik yang ditetapkan oleh institusi yang bersangkutan berdasarkan skor GRE (*Graduate Record Examination*), skor TOEFL (*Test of English as a Foreign Language*), peringkat universitas, surat rekomendasi, IPK sarjana, dan pengalaman penelitian. Keberhasilan dalam penerimaan mahasiswa pascasarjana dapat membuka peluang untuk mendapatkan gelar lebih tinggi dan memperoleh pengetahuan serta keterampilan yang lebih mendalam dalam bidang yang diminati. Pada penelitian ini, dilakukan analisis terhadap berbagai optimasi algoritma *machine learning* yang digunakan untuk melakukan optimasi pada topik atau tren yang ada pada penelitian terdahulu. Dalam hal ini, peneliti membandingkan performa dan memilih optimasi algoritma terbaik untuk diterapkan pada topik penerimaan mahasiswa pascasarjana. Hasil tinjauan ini menunjukkan bahwa algoritma *hybrid* memiliki performa terbaik dalam mengoptimasi prediksi untuk sebagian besar data pada penelitian terdahulu. Hasil dari penelitian ini menunjukkan bahwa model *hybrid CNN-LSTM (Convolutional Neural Network - Long Short-Term Memory)* diperkirakan dapat menjadi alternatif yang tepat dalam mengoptimasi prediksi penerimaan mahasiswa pascasarjana. Oleh karena itu, perlu dilakukan penelitian lebih lanjut untuk mengembangkan algoritma ini dan memperluas penerapannya pada topik penerimaan mahasiswa pascasarjana.

Kata kunci: Prediksi Penerimaan Mahasiswa Pascasarjana, Tinjauan Literatur Sistematis, Optimasi, Pembelajaran Mesin, Algoritma.

## 1. Pendahuluan

Seiring dengan perkembangan teknologi dan perkembangan ekonomi, semakin banyak orang yang tertarik untuk melanjutkan pendidikan ke jenjang pascasarjana dengan tujuan mendapatkan pengetahuan yang lebih dalam pada jalur akademik atau karier mereka dengan persaingan yang sangat kompetitif dan kompleks [1]. Pascasarjana merupakan jenjang pendidikan yang menawarkan program-program studi yang lebih spesifik dan fokus pada pengembangan keahlian tertentu. Untuk diterima pada program pascasarjana, mahasiswa harus memenuhi beberapa kriteria dan mengikuti ujian sebagai syarat untuk melakukan pendaftaran program pascasarjana [2]. Umumnya mahasiswa akan mendaftarkan diri mereka kepada institusi dengan tingkat akreditasi terbaik yang menyediakan beasiswa, pendidikan, dan kesempatan kerja yang lebih menjanjikan dari institusi lainnya [3]. Pada tahap tersebut mahasiswa sering mengalami tantangan yaitu dalam melakukan pemilihan institusi yang sesuai dengan profil dan portofolio mereka karena sebagian besar dari mereka tidak memiliki informasi mengenai profil dan portofolio dari mahasiswa lainnya [4]. Di sisi lain, banyak institusi yang menerima mahasiswa berdasarkan tingkat skor GRE (*Graduate Record Examination*), skor TOEFL (*Test of English as a Foreign Language*), peringkat universitas, surat rekomendasi, IPK sarjana, dan pengalaman penelitian [5].

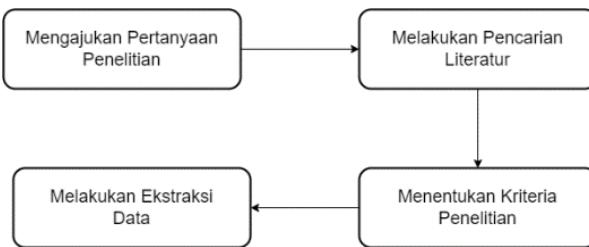
Terdapat beberapa penelitian menganalisis penggunaan algoritma *machine learning* untuk memprediksi penerimaan mahasiswa pascasarjana. Namun, belum ada penelitian mengenai optimasi pada algoritma *machine learning* untuk prediksi penerimaan mahasiswa pascasarjana. Penelitian yang telah dilakukan sebelumnya terkait topik penerimaan mahasiswa pascasarjana yaitu dilakukan oleh Mohan S Acharya et. al [5], Mohd Ajij Khan et. al [6], Amal Al Ghadri et. al [7] dengan membandingkan beberapa algoritma *machine learning* konvensional dan didapatkan hasil terbaik yaitu menggunakan algoritma *Linear Regression* dengan teknik evaluasi yang digunakan yaitu RMSE, MAE, dan R<sup>2</sup>. Namun berdasarkan kesimpulan pada penelitian sebelumnya disebutkan bahwa hasil evaluasi yang dihasilkan masih belum optimal [5]–[7].

Oleh karena itu, dibutuhkan optimasi algoritma *machine learning* untuk mengoptimalkan prediksi proses penerimaan mahasiswa pascasarjana untuk memaksimalkan peluang keberhasilan calon mahasiswa dapat diterima dalam suatu institusi dalam program penerimaan mahasiswa pascasarjana tersebut dengan lebih akurat. Dalam hal ini, diperlukan pengetahuan dengan cara mengkaji penelitian yang sudah ada menggunakan metode SLR (*Systematic Literatur Review*). Dengan menggunakan SLR, peneliti dapat mengetahui optimasi algoritma *machine learning* terbaik yang dapat diterapkan pada topik penerimaan

mahasiswa pascasarjana. Untuk mengetahui optimasi algoritma *machine learning* memiliki performa yang baik, maka kinerjanya dapat diukur menggunakan metrik evaluasi seperti RMSE (*Root Mean Squared Error*), MAE (*Mean Absolute Error*), dan R<sup>2</sup> (*R-Squared Score*). Berdasarkan pernyataan di atas, peneliti akan melakukan literature review pada literatur menggunakan metode SLR untuk mengetahui optimasi algoritma *machine learning* terbaik dan dapat diimplementasikan pada topik penerimaan mahasiswa pascasarjana. Sehingga, dapat menghasilkan prediksi peluang mahasiswa secara lebih akurat untuk diterima di suatu institusi pada program pascasarjana [8].

## 2. Metode Penelitian

Penelitian ini menerapkan metodologi SLR (*Systematic Literatur Review*) yang merupakan sebuah pendekatan penelitian untuk mengidentifikasi dan mengevaluasi literatur atau sumber bacaan tertentu mengenai topik yang ditentukan [9]. Metodologi SLR terdiri dari pertanyaan penelitian, pencarian literatur, kriteria literatur, dan pengumpulan data. Tujuan utama dari metodologi ini adalah untuk melakukan tinjauan komprehensif optimasi prediksi penerimaan mahasiswa pascasarjana yang mencakup pendekatan algoritma dan evaluasi data. Gambar 1. mengilustrasikan langkah-langkah metodologi SLR yang dijelaskan lebih rinci dalam diagram alur berikut.



Gambar 1. Diagram Alur Metodologi Penelitian

### 2.1. Mengajukan Pertanyaan Penelitian

Dalam tahap perencanaan, pertanyaan penelitian ditentukan untuk kontribusi penelitian dengan menjawab pertanyaan penelitian (PP):

- 1) PP1: Apa saja optimasi algoritma *machine learning* yang telah diterapkan/diusulkan untuk topik prediksi penerimaan mahasiswa pascasarjana?
- 2) PP2: Apa saja metrik evaluasi model yang telah diterapkan/diusulkan untuk optimasi topik penerimaan mahasiswa pascasarjana?

### 2.2. Melakukan Pencarian Literatur

Setelah menentukan pertanyaan penelitian, kata kunci dan sumber data harus spesifik. Pertama, untuk mengidentifikasi kata kunci, pertanyaan penelitian dianalisis sebagai berikut: “Optimization”, “Prediction”, “Algorithm”, “Machine Learning”, dan “Graduate

*Admission*". Selain itu dengan menambahkan "ATAU" dan "DAN" yang digunakan untuk mencari semua kemungkinan kombinasi dari kata kunci ini.

Pencarian kajian literatur menggunakan aplikasi *Publish or Perish* (POP) yang digunakan untuk membantu peneliti dalam mencari, menganalisis, dan mengevaluasi jurnal, paper, serta publikasi ilmiah lainnya yang telah diterbitkan. POP mengambil database akademik dari: ScienceDirect/Elsevier, IEE Explorer, Springer, dan MDPI. Judul, abstrak, dan kata kunci dari semua artikel yang diindeks dapat dicari menggunakan istilah pencarian yang sudah ditentukan berdasarkan PP, dan pencarian dilakukan pada studi dari tahun 2018 hingga 2023. Pada Tabel 1. Merupakan *database* yang diambil dari POP dan hasil dari pencarian jurnal yang relevan terkait dengan topik.

Tabel 1. Hasil Pencarian Penelitian

Database	Hasil pencarian yang relevan
ScienceDirect /Elsevier	54
IEE Explorer	6
Springer	5
MDPI	5
Total	70

### 2.3. Menentukan Kriteria Penelitian

Pada tahap ini dilakukan penyaringan penelitian untuk menilai secara menyeluruh relevansi dari kajian literatur ini adalah:

- 1) Menyertakan artikel yang membahas tentang optimasi algoritma machine learning dan prediksi penerimaan pascasarjana.
- 2) Menyertakan artikel Bahasa Inggris dan Bahasa Indonesia.
- 3) Menyertakan jurnal dan buku.
- 4) Menyertakan artikel yang diterbitkan dari 2018 hingga 2023.
- 5) Membuang artikel yang duplikat.

### 2.4. Melakukan Ekstraksi Data

Terdapat 20 artikel yang dipilih untuk ditinjau setelah data dari database dikumpulkan. Kemudian artikel terkait akan diekstraksi sesuai dengan kriteria penelitian. Hasil pencarian penelitian ditunjukkan pada Tabel 1. yaitu artikel tersebut diklasifikasikan berdasarkan jenis dan tahun penerbitan. Dari tahun 2018 hingga 2023, tercatat peningkatan jumlah literatur yang diterbitkan dari tahun 2018 hingga tahun 2020, lalu mengalami penurunan hingga 2023, seperti yang ditunjukkan pada Gambar 2.



Gambar 2. Grafik Publikasi Pertahun

## 3. Hasil dan Pembahasan

Pada bab hasil dan pembahasan, akan ditampilkan hasil dari tiap temuan penelitian sebelumnya mengenai optimasi algoritma untuk melakukan prediksi. Hasil yang ditampilkan adalah nama peneliti, tahun terbit, nama publisher, dan negara tempat penelitian dilakukan. Penelitian yang telah dilakukan memperoleh hasil literatur yang terkait dengan topik seperti seperti pada Tabel 2.

Tabel 2. Literatur Terkait

Peneliti	Tahun	Publisher	Negara
Shom Prasad Das, et al. [10]	2018	Springer	India
Wei Chen, et al. [11]	2021	Elsevier	China
Xu Ping, et al. [12]	2021	Elsevier	China
J. Uthayakumar, et al. [13]	2018	Springer	Germany
Saeed Samadianfard, et al. [14]	2020	Elsevier	Iran
Nan Jing, et al. [15]	2021	Elsevier	China
Hui Liu, et al. [16]	2020	Elsevier	China
Dieu Tien Buia, et al. [17]	2019	Elsevier	Vietnam
Hongfang Lu, et al. [18]	2019	Elsevier	USA
Jianzhou Wang, et al. [19]	2020	Elsevier	China
Zherui Ma, et al. [20]	2020	Elsevier	China
Jie Chen, et al. [21]	2018	Elsevier	China
Hui Liu, et al. [22]	2020	Elsevier	China
Jui-Sheng Chou, et al. [23]	2018	Elsevier	Taiwan
Hossein Abbasimehr, et al. [24]	2021	Elsevier	Iran
Vu Viet Nguyen, et al. [25]	2019	MDPI	Vietnam
Hai-Bang Ly, et al. [26]	2020	MDPI	Vietnam
Ghulam Hafeeza, et al. [27]	2020	Elsevier	Pakistan
Jian Zhou, et al. [28]	2021	Elsevier	China

Ruoheng Wang, et al. [29]	2019	IEE Explorer	China	Taihao Han, et al. [64]	2020	Elsevier	USA
Xue-Bo Jin, et al. [30]	2021	MDPI	China	Zhong-kai Feng, et al. [65]	2020	Elsevier	China
Zhenhao Tang, et al. [31]	2021	Elsevier	China	Hui Liu, et al. [66]	2018	Elsevier	China
Hui Liu, et al. [32]	2018	Elsevier	China	Mohil Maheshkumar Patel, et al. [67]	2020	Elsevier	India
Wenlong Fu, et al. [33]	2020	Elsevier	China	Abolfazl Jaafari, et al. [68]	2019	Elsevier	Iran
Shahab Shamshirband, et al. [34]	2019	IEE Explorer	Norway	Gergo Pinter, et al. [69]	2020	MDPI	Hungary
Binh Thai Phama, et al. [35]	2019	Elsevier	Vietnam	Weibiao Qiao, et al. [70]	2019	IEE Explorer	China
Sina Ardabili, et al. [36]	2020	Springer	Hungary	Binh Thai Phama, et al. [71]	2018	Elsevier	India
Miodrag Zivkovic, et al. [37]	2021	Elsevier	Serbia	Rahim Barzegar, et al. [72]	2020	Springer	Canada
Duie Tien Bui, et al. [38]	2020	Elsevier	Vietnam	George Sideratos, et al. [73]	2020	Elsevier	Greece
Yazid Tikhamarine, et al. [39]	2020	Elsevier	Algeria	Jinliang Zhang, et al. [74]	2020	Elsevier	China
Lifeng Wu, et al. [40]	2019	Elsevier	China	Zhongshan Yang, et al. [75]	2018	Elsevier	China
Hongfang Lu, et al. [41]	2020	Elsevier	China	Chongchong Qi, et al. [76]	2020	Elsevier	China
Rahim Barzegar, et al. [42]	2021	Elsevier	Iran	Ammar H. Elsheikha, et al. [77]	2021	Elsevier	Egypt
Nivethitha Somu, et al. [43]	2020	Elsevier	India	Zihan Chang, et al. [78]	2019	Elsevier	China
Wenlong Fu, et al. [44]	2021	Elsevier	China	Ying-Yi Hong, et al. [79]	2019	Elsevier	Taiwan
Jinliang Zhang, et al. [45]	2018	Elsevier	China				
Xiaohui He, et al. [46]	2020	IEE Explorer	China				
Hui Liu, et al. [47]	2018	Elsevier	China				
Panagiotis G. Asteris, et al. [48]	2021	Elsevier	Greece				
Shiyu Yang, et al. [49]	2020	Elsevier	Singapore				
Aytaç Altan, et al. [50]	2021	Elsevier	Turkey				
Hui Liu, et al. [51]	2019	Elsevier	China				
Jui-Sheng Chou, et al. [52]	2018	IEE Explorer	Vietnam				
Jian Zhou, et al. [53]	2021	Elsevier	China				
Dieu Tien Bui, et al. [54]	2019	MDPI	Vietnam				
Huaizhi Wang, et al. [55]	2019	Elsevier	China				
Abdulaziz Almalaq, et al. [56]	2018	IEE Explorer	USA				
Ahmed Abdelaziz, et al. [57]	2018	Elsevier	Egypt				
Hui Liu, et al. [58]	2018	Elsevier	China				
Rasool Alizadeh, et al. [59]	2021	Elsevier	Iran				
Feifei He, et al. [60]	2019	Elsevier	China				
Yingui Qiu, et al. [61]	2021	Springer	China				
Yong Qin, et al. [62]	2019	Elsevier	China				
Mingzhang Pan, et al. [63]	2020	Elsevier	China				

Setelah memperoleh hasil penelitian, selanjutnya dilakukan analisis data dengan memilih hasil penelitian yang paling sesuai untuk menentukan model terbaik untuk optimasi prediksi penerimaan mahasiswa pascasarjana. Pemilihan inti berdasarkan evaluasi model untuk RMSE, MAE, dan  $R^2$  yang memiliki nilai terbaik. Evaluasi ini dilakukan untuk mengetahui kinerja model dalam memprediksi data baru yang diinputkan. Metode evaluasi yang digunakan yaitu metrik evaluasi untuk data regresi linear *Root Mean Squared Error* (RMSE) yang digunakan untuk mengukur akar kuadrat dari MSE dan mengukur kesalahan prediksi dalam unit yang sama dengan variabel target, *Mean Absolute Error* (MAE) yang digunakan untuk mengukur rata-rata dari selisih absolut antara nilai yang diprediksi oleh model dan nilai sebenarnya dari variabel target dengan ketentuan semakin rendah nilai MAE maka semakin baik kinerja model, *R-Squared* ( $R^2$ ) yang digunakan untuk mengukur sejauh mana variasi variabel target dapat dijelaskan oleh model dengan ketentuan rentang nilai antara 0 hingga 1 dengan nilai 1 menunjukkan bahwa model secara sempurna menjelaskan variabilitas data [80]. Pustaka yang terpilih disajikan pada Tabel 3.

Tabel 2. Literatur Terpilih

Topik	Model	RMSE	MAE	R <sup>2</sup> Score	Prediksi kecepatan angin [66]	Deep Learning (WPD-CNNLSTM-CNN)	0.22	0.17	0.016
Prediksi kualitas udara [19]	Hybrid Learning (HI-VMD-SCA-ELM)	0.5336	0.4539	0.6057	Prediksi konsumsi gas [70]	Hybrid Learning (IOWA-RVM)	0.9064	0.82	0.02
	Hybrid Learning (CEEMDAN-error-VMD-LSTM)	0.111	0.0831	0.0321	Prediksi kualitas air [72]	Hybrid Learning (CNN-LSTM)	0.682	0.526	-
Prediksi kecepatan angin [20]	Hybrid Learning (SARIMA-MetaFA-LSSVR)	0.164	0.028	0.1565	Prediksi kecepatan angin [74]	Hybrid Learning (VMD-FOA)	0.37	0.29	0.0619
	Hybrid Learning (EWT-RELM-IEWT)	0.1584	0.123	0.1293	Prediksi kecepatan angin [75]	Hybrid Learning (MWDO-CEEMD-BP)	0.3713	0.2772	0.0478
Prediksi kecepatan angin [32]	Hybrid Learning (KELM-Conv-LSTM)	0.148	0.11	0.2288	Prediksi harga listrik [78]	Hybrid Learning (WT-Adam-LSTM)	0.114	0.081	0.0215
	Hybrid Learning (LSSVM-PSO)	0.5565	0.2293	-	Prediksi kualitas udara [19]	Hybrid Learning (HI-VMD-SCA-ELM)	0.5336	0.4539	0.6057
Prediksi evapotranspirasi [40]	Hybrid Learning (ELM-FPA)	0.1589	0.1188	-	Berdasarkan Tabel 2, peneliti mengumpulkan 70 literatur yang berhubungan dengan optimasi algoritma machine learning berdasarkan literatur yang sesuai dengan kriteria inklusi dan ekslusi sehingga menghasilkan 20 literatur terpilih yang terdapat pada Tabel 3. Seperti penelitian [19] yang menggunakan pendekatan <i>Hybrid Learning</i> dengan model HI-VMD-SCA-ELM untuk mengoptimasi prediksi kualitas udara. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.5336, MAE sebesar 0.4539. Penelitian [20] yang menggunakan pendekatan <i>Hybrid Learning</i> dengan model CEEMDAN-error-VMD-LSTM untuk mengoptimasi prediksi kecepatan angin. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.111, MAE sebesar 0.0831. Penelitian [23] yang menggunakan pendekatan <i>Hybrid Learning</i> dengan model SARIMA-MetaFA-LSSVR untuk mengoptimasi prediksi konsumsi energi. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.164, MAE sebesar 0.028. Penelitian [32] yang menggunakan pendekatan <i>Hybrid Learning</i> dengan model EWT-RELM-IEWT untuk mengoptimasi prediksi kecepatan angin. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.1584, MAE sebesar 0.123. Penelitian [33] yang menggunakan pendekatan <i>Hybrid Learning</i> dengan model KELM-Conv-LSTM untuk mengoptimasi prediksi kecepatan angin. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.148, MAE sebesar 0.11.				
Prediksi ketinggian air danau [42]	Hybrid Learning (CNN-LSTM)	0.035	0.026	-					
Prediksi konsumsi energi [43]	Hybrid Learning (ISCOA-LSTM)	0.0559	0.0369	0.3315					
Prediksi kecepatan angin [46]	Deep Learning (EEMD-LSTM)	0.3153	0.2259	0.3527					
Prediksi kecepatan angin [47]	Deep Learning (EMD-LSTM-Elman)	0.74	0.57	0.662					
Prediksi kecepatan angin [50]	Hybrid Learning (ICEEMDAN-LSTM-GWO)	0.1219	0.0863	0.0474					
Prediksi harga saham [52]	Hybrid Learning (MetaFA-LSSVR)	0.182	0.127	0.613					
Prediksi kecepatan angin [58]	Deep Learning (VMD-SSA-LSTM-ELM)	0.71	0.53	0.047					
Prediksi beban jangka pendek [60]	Hybrid Learning (VMD-LSTM)	0.1967	0.1515	0.8177					

Penelitian [39] yang menggunakan pendekatan *Hybrid Learning* dengan model LSSVM-PSO untuk mengoptimasi prediksi curah hujan. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.5565, MAE sebesar 0.2293,  $R^2$  Score sebesar 0.8594. Penelitian [40] yang menggunakan pendekatan *Hybrid Learning* dengan model ELM-FPA untuk mengoptimasi prediksi evapotranspirasi. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.1589, MAE sebesar 0.1188,  $R^2$  Score sebesar 0.993. Penelitian [42] yang menggunakan pendekatan *Hybrid Learning* dengan model CNN-LSTM untuk mengoptimasi prediksi ketinggian air dana. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.035, MAE sebesar 0.026,  $R^2$  Score sebesar 0.99. Penelitian [43] yang menggunakan pendekatan *Hybrid Learning* dengan model ISCOA-LSTM untuk mengoptimasi prediksi konsumsi energi. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.0559, MAE sebesar 0.0369. Penelitian [46] yang menggunakan pendekatan *Deep Learning* dengan model EEMD-LSTM untuk mengoptimasi prediksi kecepatan angin. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.3153, MAE sebesar 0.2259.

Penelitian [47] yang menggunakan pendekatan *Deep Learning* dengan model EMD-LSTM-Elman untuk mengoptimasi prediksi kecepatan angin. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.74, MAE sebesar 0.57. Penelitian [50] yang menggunakan pendekatan *Hybrid Learning* dengan model ICEEMDAN-LSTM-GWO untuk mengoptimasi prediksi kecepatan angin. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.1219, MAE sebesar 0.0863. Penelitian [52] yang menggunakan pendekatan *Hybrid Learning* dengan model MetaFA-LSSVR untuk mengoptimasi prediksi harga saham. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.182, MAE sebesar 0.127. Penelitian [58] yang menggunakan pendekatan *Deep Learning* dengan model VMD-SSA-LSTM-ELM untuk mengoptimasi prediksi kecepatan angin. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.71, MAE sebesar 0.53. Penelitian [60] yang menggunakan pendekatan *Hybrid Learning* dengan model VMD-LSTM untuk mengoptimasi prediksi beban jangka pendek. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.1967, MAE sebesar 0.1515,  $R^2$  Score sebesar 0.9871. Penelitian [66] yang menggunakan pendekatan *Deep Learning* dengan model WPD-CNNLSTM-CNN untuk mengoptimasi prediksi kecepatan angin [64]. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.22, MAE sebesar 0.17. Penelitian [70] yang menggunakan pendekatan *Hybrid Learning* dengan model IOWA-RVM untuk mengoptimasi prediksi konsumsi gas. Penelitian tersebut menunjukkan kinerja

0.82. Penelitian [72] yang menggunakan pendekatan *Hybrid Learning* dengan model CNN-LSTM untuk mengoptimasi prediksi kualitas air. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.682, MAE sebesar 0.526,  $R^2$  Score sebesar 0.96. Penelitian [74] yang menggunakan pendekatan *Hybrid Learning* dengan model VMD-FOA untuk mengoptimasi prediksi kecepatan angin. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.37, MAE sebesar 0.29. Penelitian [75] yang menggunakan pendekatan *Hybrid Learning* dengan model MWDO-CEEMD-BP untuk mengoptimasi prediksi kecepatan angin. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.3713, MAE sebesar 0.2772. Penelitian [78] yang menggunakan pendekatan *Hybrid Learning* dengan model WT-Adam-LSTM untuk mengoptimasi prediksi harga listrik. Penelitian tersebut menunjukkan kinerja model dengan RMSE sebesar 0.114, MAE sebesar 0.081.

#### 4. Kesimpulan

Berdasarkan penelitian yang telah dilakukan dapat disimpulkan bahwa optimasi algoritma *machine learning* yang paling banyak digunakan pada area penelitian ini adalah *Hybrid Learning* dengan model yang memiliki kinerja paling baik adalah CNN-LSTM (*Convolutional Neural Network - Long-Short Term Memory*). Hasil penelitian menunjukkan bahwa penggunaan model CNN-LSTM dapat menghasilkan performa yang paling baik dalam mengoptimasi algoritma *machine learning* untuk memprediksi ketinggian air danau pada penelitian sebelumnya yang dibuktikan dengan metrik evaluasi yang banyak digunakan untuk mengukur kinerja model yaitu RMSE (*Root Mean Squared Error*), MAE (*Mean Absolute Error*),  $R^2$  (*R-Squared*) *Score*. Meskipun demikian, diperlukan penelitian lebih lanjut untuk mengembangkan model CNN-LSTM tersebut dan memperluas penerapannya pada topik penerimaan mahasiswa pascasarjana.

#### Daftar Rujukan

- [1] A. Bag, “A Comparative Study of Regression Algorithms for Predicting Graduate Admission to a University,” *Research Gate*, 2020, doi: 10.13140/RG.2.2.13501.69605/1.
- [2] M. O. F. Goni, A. Matin, T. Hasan, M. A. I. Siddique, O. Jyoti, and F. M. S. Hasnain, “Graduate Admission Chance Prediction Using Deep Neural Network,” in *Proceedings of 2020 IEEE International Women in Engineering (WIE) Conference on Electrical and Computer Engineering, WIECON-ECE 2020*, Institute of Electrical and Electronics Engineers Inc., Dec. 2020, pp. 259–262. doi: 10.1109/WIECON-ECE5138.2020.9397988.
- [3] A. Sulich, M. Rutkowska, and U. S. Singh, “Decision towards green careers and sustainable development,” in *Procedia Computer Science*, Elsevier B.V., 2021, pp. 2291–2300. doi: 10.1016/j.procs.2021.09.002.

- [4] S. Jeganathan, S. Parthasarathy, A. R. Lakshminarayanan, P. [16]  
 M. Ashok Kumar, and M. K. A. Khan, "Predicting the post graduate admissions using classification techniques," in *2021 International Conference on Emerging Smart Computing and Informatics, ESCI 2021*, Institute of Electrical and Electronics Engineers Inc., Mar. 2021, pp. 346–350. doi: 10.1109/ESCI50559.2021.9396815.
- [5] Mohan S Acharya, Asfia Armaan, and Aneeta S Antony, "A Comparison of Regression Models for Prediction of Graduate Admissions," *Second International Conference on Computational Intelligence in Data Science (ICCIDS-2019)*, 2019.
- [6] Mohd Ajaj Khan, Manish Dixit, and Aaradhy Dixit, "Demystifying and Anticipating Graduate School Admissions using Machine Learning Algorithms," 2020.
- [7] A. Alghamdi, A. Barsheed, H. Almshjary, and H. Alghamdi, "A Machine Learning Approach for Graduate Admission [19] Prediction," in *ACM International Conference Proceeding Series*, Association for Computing Machinery, Mar. 2020, pp. 155–158. doi: 10.1145/3388818.3393716.
- [8] M. A. A. Walid, S. M. M. Ahmed, M. Zeyad, S. M. S. Galib, and M. Nesa, "Analysis of machine learning strategies for prediction of passing undergraduate admission test," [20] *International Journal of Information Management Data Insights*, vol. 2, no. 2, Nov. 2022, doi: 10.1016/j.jjimei.2022.100111.
- [9] T. Alqurashi, "Arabic Sentiment Analysis for Twitter Data: A Systematic Literature Review," *Engineering, Technology & Applied Science Research*, vol. 13, no. 2, pp. 10292–10300, Apr. 2023, doi: 10.48084/etasr.5662.
- [10] S. P. Das and S. Padhy, "A novel hybrid model using teaching-learning-based optimization and a support vector machine for commodity futures index forecasting," [22] *International Journal of Machine Learning and Cybernetics*, vol. 9, no. 1, pp. 97–111, 2018, doi: 10.1007/s13042-015-0359-0.
- [11] W. Chen, H. Zhang, M. K. Mehlawat, and L. Jia, "Mean– [23] variance portfolio optimization using machine learning-based stock price prediction," *Appl Soft Comput*, vol. 100, p. 106943, 2021, doi: https://doi.org/10.1016/j.asoc.2020.106943.
- [12] X. Ping, F. Yang, H. Zhang, J. Zhang, W. Zhang, and G. [24] Song, "Introducing machine learning and hybrid algorithm for prediction and optimization of multistage centrifugal pump in an ORC system," *Energy*, vol. 222, p. 120007, 2021, doi: https://doi.org/10.1016/j.energy.2021.120007.
- [13] J. Uthayakumar, N. Metawa, K. Shankar, and S. K. [25] Lakshmanaprabu, "Intelligent hybrid model for financial crisis prediction using machine learning techniques," *Information Systems and e-Business Management*, vol. 18, no. 4, pp. 617–645, 2020, doi: 10.1007/s10257-018-0388-9.
- [14] S. Samadianfar et al., "Wind speed prediction using a hybrid model of the multi-layer perceptron and whale optimization algorithm," *Energy Reports*, vol. 6, pp. 1147–1159, 2020, doi: https://doi.org/10.1016/j.egyr.2020.05.001.
- [15] N. Jing, Z. Wu, and H. Wang, "A hybrid model integrating deep learning with investor sentiment analysis for stock price prediction," *Expert Syst Appl*, vol. 178, p. 115019, 2021, doi: https://doi.org/10.1016/j.eswa.2021.115019.
- [16] H. Liu, C. Yu, H. Wu, Z. Duan, and G. Yan, "A new hybrid ensemble deep reinforcement learning model for wind speed short term forecasting," *Energy*, vol. 202, p. 117794, 2020, doi: https://doi.org/10.1016/j.energy.2020.117794.
- [17] D. Tien Bui, N.-D. Hoang, and P. Samui, "Spatial pattern analysis and prediction of forest fire using new machine learning approach of Multivariate Adaptive Regression Splines and Differential Flower Pollination optimization: A case study at Lao Cai province (Viet Nam)," *J Environ Manage*, vol. 237, pp. 476–487, 2019, doi: https://doi.org/10.1016/j.jenvman.2019.01.108.
- [18] H. Lu, M. Azimi, and T. Iseley, "Short-term load forecasting of urban gas using a hybrid model based on improved fruit fly optimization algorithm and support vector machine," *Energy Reports*, vol. 5, pp. 666–677, 2019, doi: https://doi.org/10.1016/j.egyr.2019.06.003.
- [19] J. Wang, P. Du, Y. Hao, X. Ma, T. Niu, and W. Yang, "An innovative hybrid model based on outlier detection and correction algorithm and heuristic intelligent optimization algorithm for daily air quality index forecasting," *J Environ Manage*, vol. 255, p. 109855, 2020, doi: https://doi.org/10.1016/j.jenvman.2019.109855.
- [20] Z. Ma et al., "Application of hybrid model based on double decomposition, error correction and deep learning in short-term wind speed prediction," *Energy Convers Manag*, vol. 205, p. 112345, 2020, doi: https://doi.org/10.1016/j.enconman.2019.112345.
- [21] J. Chen, G.-Q. Zeng, W. Zhou, W. Du, and K.-D. Lu, "Wind speed forecasting using nonlinear-learning ensemble of deep learning time series prediction and extremal optimization," *Energy Convers Manag*, vol. 165, pp. 681–695, 2018, doi: https://doi.org/10.1016/j.enconman.2018.03.098.
- [22] H. Liu and Z. Long, "An improved deep learning model for predicting stock market price time series," *Digit Signal Process*, vol. 102, p. 102741, 2020, doi: https://doi.org/10.1016/j.dsp.2020.102741.
- [23] J.-S. Chou and D.-S. Tran, "Forecasting energy consumption time series using machine learning techniques based on usage patterns of residential householders," *Energy*, vol. 165, pp. 709–726, 2018, doi: https://doi.org/10.1016/j.energy.2018.09.144.
- [24] H. Abbasimehr and R. Paki, "Prediction of COVID-19 confirmed cases combining deep learning methods and Bayesian optimization," *Chaos Solitons Fractals*, vol. 142, p. 110511, 2021, doi: https://doi.org/10.1016/j.chaos.2020.110511.
- [25] V. V. Nguyen et al., "Hybrid machine learning approaches for landslide susceptibility modeling," *Forests*, vol. 10, no. 2, Feb. 2019, doi: 10.3390/f10020157.
- [26] H. B. Ly, T. T. Le, H. L. T. Vu, V. Q. Tran, L. M. Le, and B. T. Pham, "Computational hybrid machine learning based prediction of shear capacity for steel fiber reinforced concrete beams," *Sustainability (Switzerland)*, vol. 12, no. 7, Apr. 2020, doi: 10.3390/su12072709.
- [27] G. Hafeez, K. S. Alimgeer, and I. Khan, "Electric load forecasting based on deep learning and optimized by heuristic algorithm in smart grid," *Appl Energy*, vol. 269, p. 114915, 2020, doi: https://doi.org/10.1016/j.apenergy.2020.114915.

- [28] J. Zhou, Y. Qiu, M. Khandelwal, S. Zhu, and X. Zhang, “Developing a hybrid model of Jaya algorithm-based extreme gradient boosting machine to estimate blast-induced ground vibrations,” *International Journal of Rock Mechanics and Mining Sciences*, vol. 145, p. 104856, 2021, doi: <https://doi.org/10.1016/j.ijrmms.2021.104856>. [40]
- [29] R. Wang, C. Li, W. Fu, and G. Tang, “Deep Learning Method Based on Gated Recurrent Unit and Variational Mode Decomposition for Short-Term Wind Power Interval Prediction,” *IEEE Trans Neural Netw Learn Syst*, vol. 31, no. 10, pp. 3814–3827, 2020, doi: [10.1109/TNNLS.2019.2946414](https://doi.org/10.1109/TNNLS.2019.2946414). [41]
- [30] X. B. Jin *et al.*, “Deep-learning forecasting method for electric power load via attention-based encoder-decoder with bayesian optimization,” *Energies (Basel)*, vol. 14, no. 6, Mar. 2021, doi: [10.3390/en14061596](https://doi.org/10.3390/en14061596). [42]
- [31] Z. Tang, G. Zhao, and T. Ouyang, “Two-phase deep learning model for short-term wind direction forecasting,” *Renew Energy*, vol. 173, pp. 1005–1016, 2021, doi: <https://doi.org/10.1016/j.renene.2021.04.041>. [43]
- [32] H. Liu, H. Wu, and Y. Li, “Smart wind speed forecasting using EWT decomposition, GWO evolutionary optimization, RELM learning and IEWT reconstruction,” *Energy Convers Manag*, vol. 161, pp. 266–283, 2018, doi: <https://doi.org/10.1016/j.enconman.2018.02.006>. [44]
- [33] W. Fu, K. Wang, J. Tan, and K. Zhang, “A composite framework coupling multiple feature selection, compound prediction models and novel hybrid swarm optimizer-based synchronization optimization strategy for multi-step ahead short-term wind speed forecasting,” *Energy Convers Manag*, vol. 205, p. 112461, 2020, doi: <https://doi.org/10.1016/j.enconman.2019.112461>. [45]
- [34] S. Shamshirband, T. Rabczuk, and K.-W. Chau, “A Survey of Deep Learning Techniques: Application in Wind and Solar Energy Resources,” *IEEE Access*, vol. 7, pp. 164650–164666, 2019, doi: [10.1109/ACCESS.2019.2951750](https://doi.org/10.1109/ACCESS.2019.2951750). [46]
- [35] B. T. Pham, M. D. Nguyen, K.-T. T. Bui, I. Prakash, K. Chapi, and D. T. Bui, “A novel artificial intelligence approach based on Multi-layer Perceptron Neural Network and Biogeography-based Optimization for predicting coefficient of consolidation of soil,” *Catena (Amst)*, vol. 173, pp. 302–311, 2019, doi: <https://doi.org/10.1016/j.catena.2018.10.004>. [47]
- [36] S. Ardabili, A. Mosavi, and A. R. Várkonyi-Kóczy, “Systematic Review of Deep Learning and Machine Learning Models in Biofuels Research,” in *Engineering for Sustainable Future*, A. R. Várkonyi-Kóczy, Ed., Cham: Springer International Publishing, 2020, pp. 19–32. [48]
- [37] M. Zivkovic *et al.*, “COVID-19 cases prediction by using hybrid machine learning and beetle antennae search approach,” *Sustain Cities Soc*, vol. 66, p. 102669, 2021, doi: <https://doi.org/10.1016/j.scs.2020.102669>. [49]
- [38] D. T. Bui, K. Khosravi, J. Tiefenbacher, H. Nguyen, and N. Kazakis, “Improving prediction of water quality indices using novel hybrid machine-learning algorithms,” *Science of The Total Environment*, vol. 721, p. 137612, 2020, doi: <https://doi.org/10.1016/j.scitotenv.2020.137612>. [50]
- [39] Y. Tikhamarine *et al.*, “Rainfall-runoff modelling using improved machine learning methods: Harris hawks optimizer vs. particle swarm optimization,” *J Hydrol (Amst)*, vol. 589, p. 125133, 2020, doi: <https://doi.org/10.1016/j.jhydrol.2020.125133>.
- L. Wu, H. Zhou, X. Ma, J. Fan, and F. Zhang, “Daily reference evapotranspiration prediction based on hybridized extreme learning machine model with bio-inspired optimization algorithms: Application in contrasting climates of China,” *J Hydrol (Amst)*, vol. 577, p. 123960, 2019, doi: <https://doi.org/10.1016/j.jhydrol.2019.123960>.
- H. Lu and X. Ma, “Hybrid decision tree-based machine learning models for short-term water quality prediction,” *Chemosphere*, vol. 249, p. 126169, 2020, doi: <https://doi.org/10.1016/j.chemosphere.2020.126169>.
- R. Barzegar, M. T. Aalami, and J. Adamowski, “Coupling a hybrid CNN-LSTM deep learning model with a Boundary Corrected Maximal Overlap Discrete Wavelet Transform for multiscale Lake water level forecasting,” *J Hydrol (Amst)*, vol. 598, p. 126196, 2021, doi: <https://doi.org/10.1016/j.jhydrol.2021.126196>.
- N. Somu, G. R. M R, and K. Ramamirtham, “A hybrid model for building energy consumption forecasting using long short term memory networks,” *Appl Energy*, vol. 261, p. 114131, 2020, doi: <https://doi.org/10.1016/j.apenergy.2019.114131>.
- W. Fu, K. Zhang, K. Wang, B. Wen, P. Fang, and F. Zou, “A hybrid approach for multi-step wind speed forecasting based on two-layer decomposition, improved hybrid DE-HHO optimization and KELM,” *Renew Energy*, vol. 164, pp. 211–229, 2021, doi: <https://doi.org/10.1016/j.renene.2020.09.078>.
- J. Zhang, Y.-M. Wei, D. Li, Z. Tan, and J. Zhou, “Short term electricity load forecasting using a hybrid model,” *Energy*, vol. 158, pp. 774–781, 2018, doi: <https://doi.org/10.1016/j.energy.2018.06.012>.
- X. He, Y. Nie, H. Guo, and J. Wang, “Research on a Novel Combination System on the Basis of Deep Learning and Swarm Intelligence Optimization Algorithm for Wind Speed Forecasting,” *IEEE Access*, vol. 8, pp. 51482–51499, 2020, doi: [10.1109/ACCESS.2020.2980562](https://doi.org/10.1109/ACCESS.2020.2980562).
- H. Liu, X. Mi, and Y. Li, “Wind speed forecasting method based on deep learning strategy using empirical wavelet transform, long short term memory neural network and Elman neural network,” *Energy Convers Manag*, vol. 156, pp. 498–514, 2018, doi: <https://doi.org/10.1016/j.enconman.2017.11.053>.
- P. G. Asteris, A. D. Skentou, A. Bardhan, P. Samui, and K. Pilakoutas, “Predicting concrete compressive strength using hybrid ensembling of surrogate machine learning models,” *Cem Concr Res*, vol. 145, p. 106449, 2021, doi: <https://doi.org/10.1016/j.cemconres.2021.106449>.
- S. Yang, M. P. Wan, W. Chen, B. F. Ng, and S. Dubey, “Model predictive control with adaptive machine-learning-based model for building energy efficiency and comfort optimization,” *Appl Energy*, vol. 271, p. 115147, 2020, doi: <https://doi.org/10.1016/j.apenergy.2020.115147>.
- A. Altan, S. Karasu, and E. Zio, “A new hybrid model for wind speed forecasting combining long short-term memory neural network, decomposition methods and grey wolf

- optimizer,” *Appl Soft Comput*, vol. 100, p. 106996, 2021, doi: <https://doi.org/10.1016/j.asoc.2020.106996>.
- [51] H. Liu, X. Mi, Y. Li, Z. Duan, and Y. Xu, “Smart wind speed [63] deep learning based multi-step forecasting model using singular spectrum analysis, convolutional Gated Recurrent Unit network and Support Vector Regression,” *Renew Energy*, vol. 143, pp. 842–854, 2019, doi: <https://doi.org/10.1016/j.renene.2019.05.039>.
- [52] J.-S. Chou and T.-K. Nguyen, “Forward Forecast of Stock Price Using Sliding-Window Metaheuristic-Optimized Machine-Learning Regression,” *IEEE Trans Industr Inform*, vol. 14, no. 7, pp. 3132–3142, 2018, doi: 10.1109/TII.2018.2794389.
- [53] J. Zhou *et al.*, “Optimization of support vector machine through the use of metaheuristic algorithms in forecasting TBM advance rate,” *Eng Appl Artif Intell*, vol. 97, p. 104015, 2021, doi: <https://doi.org/10.1016/j.engappai.2020.104015>.
- [54] D. T. Bui *et al.*, “Shallow landslide prediction using a novel hybrid functional machine learning algorithm,” *Remote Sens (Basel)*, vol. 11, no. 8, Apr. 2019, doi: 10.3390/rs11080931.
- [55] H. Wang, Z. Lei, X. Zhang, B. Zhou, and J. Peng, “A review of deep learning for renewable energy forecasting,” *Energy Convers Manag*, vol. 198, p. 111799, 2019, doi: <https://doi.org/10.1016/j.enconman.2019.111799>.
- [56] A. Almalaq and J. J. Zhang, “Evolutionary Deep Learning-Based Energy Consumption Prediction for Buildings,” *IEEE Access*, vol. 7, pp. 1520–1531, 2019, doi: 10.1109/ACCESS.2018.2887023.
- [57] A. Abdelaziz, M. Elhoseny, A. S. Salama, and A. M. Riad, “A machine learning model for improving healthcare services on cloud computing environment,” *Measurement*, vol. 119, pp. 117–128, 2018, doi: <https://doi.org/10.1016/j.measurement.2018.01.022>.
- [58] H. Liu, X. Mi, and Y. Li, “Smart multi-step deep learning [69] model for wind speed forecasting based on variational mode decomposition, singular spectrum analysis, LSTM network and ELM,” *Energy Convers Manag*, vol. 159, pp. 54–64, 2018, doi: <https://doi.org/10.1016/j.enconman.2018.01.010>.
- [59] R. Alizadeh *et al.*, “A machine learning approach to the prediction of transport and thermodynamic processes in multiphysics systems - heat transfer in a hybrid nanofluid flow in porous media,” *J Taiwan Inst Chem Eng*, vol. 124, pp. 290–306, 2021, doi: <https://doi.org/10.1016/j.jtice.2021.03.043>.
- [60] F. He, J. Zhou, Z. Feng, G. Liu, and Y. Yang, “A hybrid short-term load forecasting model based on variational mode decomposition and long short-term memory networks considering relevant factors with Bayesian optimization algorithm,” *Appl Energy*, vol. 237, pp. 103–116, 2019, doi: <https://doi.org/10.1016/j.apenergy.2019.01.055>.
- [61] Y. Qiu, J. Zhou, M. Khandelwal, H. Yang, P. Yang, and C. Li, “Performance evaluation of hybrid WOA-XGBoost, GWO-XGBoost and BO-XGBoost models to predict blast-induced ground vibration,” *Eng Comput*, vol. 38, no. 5, pp. 4145–4162, 2022, doi: 10.1007/s00366-021-01393-9.
- [62] Y. Qin *et al.*, “Hybrid forecasting model based on long short term memory network and deep learning neural network for [73] wind signal,” *Appl Energy*, vol. 236, pp. 262–272, 2019, doi: <https://doi.org/10.1016/j.apenergy.2018.11.063>.
- [63] M. Pan *et al.*, “Photovoltaic power forecasting based on a support vector machine with improved ant colony optimization,” *J Clean Prod*, vol. 277, p. 123948, 2020, doi: <https://doi.org/10.1016/j.jclepro.2020.123948>.
- [64] T. Han, A. Siddique, K. Khayat, J. Huang, and A. Kumar, “An ensemble machine learning approach for prediction and optimization of modulus of elasticity of recycled aggregate concrete,” *Constr Build Mater*, vol. 244, p. 118271, 2020, doi: <https://doi.org/10.1016/j.conbuildmat.2020.118271>.
- [65] Z. Feng *et al.*, “Monthly runoff time series prediction by variational mode decomposition and support vector machine based on quantum-behaved particle swarm optimization,” *J Hydrol (Amst)*, vol. 583, p. 124627, 2020, doi: <https://doi.org/10.1016/j.jhydrol.2020.124627>.
- [66] H. Liu, X. Mi, and Y. Li, “Smart deep learning based wind speed prediction model using wavelet packet decomposition, convolutional neural network and convolutional long short term memory network,” *Energy Convers Manag*, vol. 166, pp. 120–131, 2018, doi: <https://doi.org/10.1016/j.enconman.2018.04.021>.
- [67] M. M. Patel, S. Tanwar, R. Gupta, and N. Kumar, “A Deep Learning-based Cryptocurrency Price Prediction Scheme for Financial Institutions,” *Journal of Information Security and Applications*, vol. 55, p. 102583, 2020, doi: <https://doi.org/10.1016/j.jisla.2020.102583>.
- [68] A. Jaafari, E. K. Zenner, M. Panahi, and H. Shahabi, “Hybrid artificial intelligence models based on a neuro-fuzzy system and metaheuristic optimization algorithms for spatial prediction of wildfire probability,” *Agric For Meteorol*, vol. 266–267, pp. 198–207, 2019, doi: <https://doi.org/10.1016/j.agrformet.2018.12.015>.
- [69] G. Pinter, I. Felde, A. Mosavi, P. Ghamisi, and R. Gloaguen, “COVID-19 pandemic prediction for Hungary; A hybrid machine learning approach,” *Mathematics*, vol. 8, no. 6, 2020, doi: 10.3390/math8060890.
- [70] W. Qiao, K. Huang, M. Azimi, and S. Han, “A Novel Hybrid Prediction Model for Hourly Gas Consumption in Supply Side Based on Improved Whale Optimization Algorithm and Relevance Vector Machine,” *IEEE Access*, vol. 7, pp. 88218–88230, 2019, doi: 10.1109/ACCESS.2019.2918156.
- [71] B. T. Pham, A. Shirzadi, D. Tien Bui, I. Prakash, and M. B. Dholakia, “A hybrid machine learning ensemble approach based on a Radial Basis Function neural network and Rotation Forest for landslide susceptibility modeling: A case study in the Himalayan area, India,” *International Journal of Sediment Research*, vol. 33, no. 2, pp. 157–170, 2018, doi: <https://doi.org/10.1016/j.ijsrc.2017.09.008>.
- [72] R. Barzegar, M. T. Aalami, and J. Adamowski, “Short-term water quality variable prediction using a hybrid CNN-LSTM deep learning model,” *Stochastic Environmental Research and Risk Assessment*, vol. 34, no. 2, pp. 415–433, 2020, doi: 10.1007/s00477-020-01776-2.
- [73] G. Sideratos, A. Ikonopoulos, and N. D. Hatzigaryiou, “A novel fuzzy-based ensemble model for load forecasting using hybrid deep neural networks,” *Electric Power Systems Research*, vol. 178, p. 106025, 2020, doi: <https://doi.org/10.1016/j.epsr.2019.106025>.

- [74] J. Zhang, Y. Wei, and Z. Tan, “An adaptive hybrid model for short term wind speed forecasting,” *Energy*, vol. 190, p. 115615, 2020, doi: <https://doi.org/10.1016/j.energy.2019.06.132>.
- [75] Z. Yang and J. Wang, “A hybrid forecasting approach applied in wind speed forecasting based on a data processing strategy and an optimized artificial intelligence algorithm,” *Energy*, vol. 160, pp. 87–100, 2018, doi: <https://doi.org/10.1016/j.energy.2018.07.005>.
- [76] C. Qi, H.-B. Ly, Q. Chen, T.-T. Le, V. M. Le, and B. T. Pham, “Flocculation-dewatering prediction of fine mineral tailings using a hybrid machine learning approach,” *Chemosphere*, vol. 244, p. 125450, 2020, doi: <https://doi.org/10.1016/j.chemosphere.2019.125450>.
- [77] A. H. Elsheikh *et al.*, “Deep learning-based forecasting model for COVID-19 outbreak in Saudi Arabia,” *Process Safety and Environmental Protection*, vol. 149, pp. 223–233, 2021, doi: <https://doi.org/10.1016/j.psep.2020.10.048>.
- [78] Z. Chang, Y. Zhang, and W. Chen, “Electricity price prediction based on hybrid model of adam optimized LSTM neural network and wavelet transform,” *Energy*, vol. 187, p. 115804, 2019, doi: <https://doi.org/10.1016/j.energy.2019.07.134>.
- [79] Y.-Y. Hong and C. L. P. P. Rioflorido, “A hybrid deep learning-based neural network for 24-h ahead wind power forecasting,” *Appl Energy*, vol. 250, pp. 530–539, 2019, doi: <https://doi.org/10.1016/j.apenergy.2019.05.044>.
- [80] G. An *et al.*, “Using machine learning for estimating rice chlorophyll content from in situ hyperspectral data,” *Remote Sens (Basel)*, vol. 12, no. 18, Sep. 2020, doi: 10.3390/RS12183104.

