

PREDIKSI ADSORPSI ZAT WARNA METILENE BIRU PADA KARBON AKTIF MENGUNAKAN *MACHINE LEARNING*

Prediction of Methylene Blue Dye Adsorption on Activated Carbon Using Machine Learning

Tri Hadi Jatmiko

Balai Penelitian Teknologi Bahan Alam, Lembaga Ilmu Pengetahuan Indonesia, Jln. Yogya - Wonosari
km 31,5 Gading, Playen, Gunungkidul, DIY

Korespondensi Penulis

Email : trih011@lipi.go.id

Naskah Masuk : 30 Maret 2021

Revisi : 07 Juni 2021

Disetujui : 09 Juni 2021

Kata kunci: adsorpsi, karbon aktif, *machine learning*, metilen biru

Keywords: activated carbon, adsorption, machine learning, methylene blue

ABSTRAK

Pemanfaatan teknologi informasi dalam mengurangi kegiatan eksperimen di laboratorium semakin meningkat. Pemanfaatan teknologi informasi akan menghemat bahan, waktu dan biaya, serta mengurangi resiko bahaya yang mungkin timbul jika dilakukan eksperimen secara langsung. Salah satu teknologi informasi yang sedang berkembang adalah *machine learning*. Penelitian ini bertujuan untuk mengetahui unjuk kerja model *machine learning* dalam memprediksi adsorpsi metilene biru pada karbon aktif. data set adsorpsi metilene biru menggunakan karbon aktif biji alpukat dibagi menjadi data latihan dan data uji. data set tersebut kemudian digunakan untuk menguji performa model *machine learning* (*neural networks*, *support vector machines*, *random forest*, dan *linear regression*) menggunakan metode *Stratified 10-fold Cross validation*. Model *neural network* merupakan model *machine learning* terbaik untuk memprediksi proses adsorpsi metilene biru pada karbon aktif dibandingkan dengan model SVM, *Random Forest* maupun regresi linier dengan performa prediksi terbaik pada data latihan maupun data uji. Nilai MSE 14.640, RMSE 3.826, MAE 3.178 dan R^2 0.975 pada data latihan dan pada data uji nilai MSE 3.51e-06, RMSE 0.00187, MAE 0.00135 dan R^2 0.999.

ABSTRACT

The use of information technology to reduce experimental activities in the laboratory is increasing. Utilization of information technology will save materials, time, and costs, and will reduce the risk of danger that may arise if the experiment is carried out directly. One of the information technologies that is developing is machine learning. This study aims to determine the performance of a machine learning model in predicting the adsorption of methylene blue on activated carbon. Methylene blue adsorption data set from previous research was divided into training data and test data. This data used to test the performance of machine learning models (neural networks, support vector machines, random forest, and linear regression) using the Stratified 10-fold Cross validation method. Neural network model is the best machine learning model for predicting the methylene blue adsorption process on activated carbon compared to SVM, Random Forest and linear regression models with the best predictive performance on both training and test data. The RMSE value was 3,826 and R^2 was 0.975 in the training data and on the test data the RMSE value was 3.51e-06 and R^2 was 0.999.

PENDAHULUAN

Pencemaran lingkungan oleh zat warna berbahaya, logam maupun bahan organik dan anorganik merupakan masalah lingkungan yang serius. Karena akan berdampak pada keseimbangan lingkungan dan kesehatan masyarakat, sehingga penanganan limbah sangat diperlukan. Limbah dapat diproses baik secara fisika, kimia maupun biologi. *Metilene* biru merupakan salah satu pewarna yang banyak digunakan di industri dan laboratorium yang dapat menimbulkan permasalahan lingkungan dan kesehatan (Ghorai et al., 2014; T. H. Jatmiko & Pratiwi, 2019; Pathania et al., 2017; Patil et al., 2017). Salah satu cara penanganan limbah zat warna yang efektif adalah dengan adsorpsi.

Adsorpsi merupakan salah satu proses penanganan limbah yang efisien, murah, desain sederhana dan operasionalnya mudah (Ahmad et al., 2021; Berkane et al., 2019; Ghorai et al., 2014; T. H. Jatmiko & Pratiwi, 2019). Karbon aktif merupakan salah satu bahan yang umum digunakan sebagai adsorben karena memiliki karakteristik yang sangat sesuai untuk digunakan sebagai adsorben, yaitu porositas yang tinggi, luas permukaan yang tinggi dan gugus fungsional yang dapat digunakan dalam berbagai aplikasi (Ahmed et al., 2019; González-García, 2018; Jaria et al., 2019; T. Jatmiko, 2020).

Penelitian ini bertujuan untuk melakukan prediksi adsorpsi *metilene* biru pada karbon aktif menggunakan metode *machine learning* serta membandingkan performa model *machine learning* yang digunakan. Pemanfaatan *machine learning* sangat membantu dalam membangun sebuah model prediksi yang akurat (Ahmad

et al., 2021; Jiang et al., 2019). Penyusunan model dapat dilakukan dengan data yang sudah ada. Pemanfaatan model dan simulasi komputer tentunya akan sangat membantu mengurangi kegiatan eksperimen dan pengamatan di laboratorium, sehingga akan dapat menghemat bahan, waktu dan biaya. Serta tentunya akan mengurangi resiko bahaya yang mungkin timbul jika dilakukan percobaan secara langsung di laboratorium (T. H. Jatmiko et al., 2018). Pemanfaatan *machine learning* juga akan membantu mengurangi jumlah limbah yang dihasilkan oleh percobaan langsung di laboratorium.

Model *machine learning* yang banyak digunakan untuk memprediksi adsorpsi zat warna adalah *neural network* (NN) (Ahmad et al., 2021; Albalasmeh et al., 2020; Ghaedi & Vafaei, 2017; Kooh et al., 2018; Pauletto et al., 2020). Sedangkan model *machine learning* lainnya yang juga umum digunakan antara lain *Random Forest* (RF) (de Miranda Ramos Soares et al., 2020; Jiang et al., 2019; Kooh et al., 2018), *support vector machine* (SVM) (Asfaram et al., 2016; Jiang et al., 2019).

Neural Network adalah metode yang dikembangkan dengan meniru cara kerja jaringan syaraf otak manusia. Informasi dikirim ke neuron melalui input berbobot melalui fungsi propagasi, yang akan meningkatkan nilai bobot input. Kemudian hasilnya dibandingkan dengan ambang batas melalui fungsi aktivasi. Jika input ditemukan melebihi ambang batas, maka neuron akan diaktifkan, sebaliknya neuron akan dihambat. Jika neuron diaktifkan, neuron tersebut akan mengirimkan output ke neuron lain dengan pembobotan output, dan seterusnya sampai model yang

dihasilkan oleh NN mendekati target keluaran yang diinginkan (Ahmad et al., 2021; Albalasmeh et al., 2020; Drajana, 2017; Pauletto et al., 2020).


Random Forest adalah metode pembelajaran yang terintegrasi. RF menggunakan beberapa pohon regresi selama pelatihan. Pemisahan variabel setiap node dipilih berdasarkan pengacakan. Algoritma RF memulai pembelajaran dengan membagi data pelatihan menjadi beberapa subset menggunakan sampling terpandu. Selanjutnya, setiap pohon regresi ditetapkan untuk setiap subset dengan menggunakan subset fitur yang dipilih secara acak. Setelah *fitting* model pada seluruh set data pelatihan, respon dari set data uji biasanya diprediksi berdasarkan nilai rata-rata prediksi individu (Hafsa et al., 2020; Jiang et al., 2019; Kooh et al., 2018).

SVM merupakan metode klasifikasi data yang menggunakan *hyperplane* untuk mengelompokkan data. Metode SVM membagi data menjadi beberapa bagian sesuai dengan *hyperplane* yang dihasilkan, sehingga setiap bagian hanya berisi satu jenis data. Metode SVM biasanya sangat berguna untuk data dengan ketidakteraturan atau data dengan distribusi yang tidak diketahui. Konsep SVM menitikberatkan pada meminimalkan resiko, yaitu mengestimasi suatu fungsi dengan meminimalkan ambang batas atas kesalahan, sehingga SVM dapat mengatasi masalah *overfitting* (Asfaram et al., 2016; Jiang et al., 2019). Regresi linier adalah prosedur untuk menginduksi korelasi statistik antara dua atau lebih variabel di mana perubahan dalam variabel dependen dikaitkan dan bergantung pada perubahan dalam satu atau lebih variabel independen

secara linier. Koefisien digunakan untuk menggambarkan perubahan ini (Hocking, 2003; Prakash et al., 2021).

METODOLOGI PENELITIAN

Tahapan penelitian yang dilakukan secara garis besar dapat disajikan seperti pada Gambar 1.



Gambar 1. Diagram alir tahapan penelitian

Tahap pertama adalah pengumpulan data adsorpsi *metilene* biru pada karbon

aktif. Data adsorpsi *metilene* biru diambil dari penelitian sebelumnya oleh Regti (Regti et al., 2017) seperti yang disajikan pada Tabel 1, dimana karbon aktif yang digunakan dibuat dari biji alpukat yang telah dikeringkan dan diaktivasi menggunakan asam fosfat dengan rasio 1:4 dan dipanaskan pada suhu 500°C selama 1 jam.

Proses adsorpsi *metilene* biru dilakukan secara batch pada suhu 293 atau 323 K, pH 2 atau 10, konsentrasi awal 25 atau 50 mg/L dan jumlah adsorben 0,1 atau 0,4 g/L. Proses adsorpsi dilakukan selama 30 menit, kemudian metilen biru tersisa dianalisa dengan *spectrophotometer UV-visible* pada panjang gelombang 664 nm.

Tabel 1. Data adsorpsi *metilene* biru

Suhu (K)	pH	Konsentrasi (mg/L)	Adsorben (g/L)	MB teradsorp (%)
293	2	25	0,1	46
323	2	25	0,1	68,97
293	10	25	0,1	69,77
323	10	25	0,1	74
293	2	50	0,1	25,77
323	2	50	0,1	38,66
293	10	50	0,1	48
323	10	50	0,1	73,12
293	2	25	0,4	96
323	2	25	0,4	96,22
293	10	25	0,4	94,2
323	10	25	0,4	97,53
293	2	50	0,4	88,47
323	2	50	0,4	94,81
293	10	50	0,4	97,12
323	10	50	0,4	97,39

data set berupa kapasitas adsorpsi *metilene* biru pada karbon aktif dibagi menjadi data latihan dan data test. data set adsorpsi *metilene* biru menggunakan

karbon aktif dari biji alpukat kemudian diolah dengan menggunakan beberapa metode *machine learning* menggunakan *Software Orange* dengan parameter untuk setiap model yang dioptimasi secara manual dan hasil optimum seperti tercantum pada Tabel 2.

Semua model *machine learning* dibandingkan performanya menggunakan metode *Stratified 10-fold Cross validation* dimana data dibagi menjadi 10 bagian subset data, 9 bagian digunakan untuk proses pembelajaran dan 1 bagian data digunakan untuk menguji model (Chibani & Coudert, 2020; Fanourgakis et al., 2020; Li et al., 2019). Kemudian model dievaluasi nilai *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *R-Squared* (R^2) (Asfaram et al., 2016; de Miranda Ramos Soares et al., 2020; Ghaedi & Vafaei, 2017; Jiang et al., 2019).

$$R^2 = 1 - \sum_{i=1}^n \left(\frac{(y_{i,pred} - y_{i,exp})^2}{(y_{i,pred} - y_n)^2} \right) \quad (1)$$

$$MSE = \frac{\sum_{i=1}^n ((y_{i,pred} - y_{i,exp})^2)}{n} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n ((y_{i,pred} - y_{i,exp})^2)}{n}} \quad (3)$$

$$MAE = \frac{\sum_{i=1}^n |y_{i,pred} - y_{i,exp}|}{n} \quad (4)$$

dimana n adalah jumlah eksperimen, y_{pred} dan y_{exp} masing-masing adalah data prediksi model dan data eksperimen.

Tabel 2. Parameter model *machine learning*

Model	Parameter
Neural Network	Hidden layers: 100 Activation: Logistic Solver: L-BFGS-B Alpha: 0.0001 Max iterations: 1000 Replicable training: True
SVM	SVM type: SVM, C=10.0, $\epsilon=1.0$ Kernel: Polynomial, (auto x·y + 10.0) ^{4.0} Numerical tolerance: 0.001 Iteration limit: 1000
Random Forest	Number of trees: 3 Maximal number of considered features: unlimited Replicable training: Yes Maximal tree depth: unlimited Stop splitting nodes with maximum instances: 5
Linear Regression	Regularization: No Regularization Fit intercept: Yes

HASIL DAN PEMBAHASAN

Metode konvensional untuk mempelajari hubungan antara kondisi operasi adsorpsi dengan kemampuan adsorpsi suatu adsorben pada umumnya hanya ditunjukkan dengan kapasitas adsorpsi sebagai fungsi dari konsentrasi zat terserap dalam kondisi kesetimbangan. Kemudian dipilih persamaan adsorpsi isotherm yang paling sesuai, seperti persamaan Langmuir, Freundlich atau Temkin. Akan tetapi persamaan-persamaan tersebut belum bisa menjelaskan pengaruh parameter operasi adsorpsi yang tidak hanya terbatas pada konsentrasi awal adsorbate dan jumlah adsorben, seperti pH,

suhu dan karakteristik adsorben (Hafsa et al., 2020; Kiraz et al., 2019). Sehingga berkembanglah metode statistik (Hafsa et al., 2020; Pauletto et al., 2020) seperti *response surface method* (RSM) yang banyak digunakan untuk mengatasi kelemahan metode tradisional. Akan tetapi metode RSM, pada banyak kasus, belum dapat menunjukkan korelasi non linier dengan baik (Ghaedi & Vafaei, 2017; Hafsa et al., 2020). Metode *machine learning* dapat dengan mudah melakukan prediksi dengan berbagai masukan atau variabel yang diberikan berdasarkan data yang sudah ada tanpa terikat dengan desain percobaan seperti pada metode konvensional maupun RSM (Asfaram et al., 2016; Ghaedi & Vafaei, 2017; Hafsa et al., 2020).

Evaluasi model *machine learning* menggunakan metode *Stratified 10-fold Cross validation* menjamin estimasi akurasi yang tidak bias. Metode ini membagi data menjadi 10 bagian subset data, dimana 9 bagian digunakan untuk proses pembelajaran dan 1 bagian data digunakan untuk menguji model. Proses ini dilakukan sebanyak 10 kali dimana setiap pengulangan menggunakan subset data yang berbeda-beda, baik untuk proses pembelajaran maupun untuk proses pengujian. Kinerja setiap model dihitung dari rata-rata proses yang telah dilakukan (Chibani & Coudert, 2020; Fanourgakis et al., 2020).

Tabel 3, Tabel 4 dan Gambar 2 menunjukkan perbandingan performa model *machine learning* dengan metode *Stratified 10-fold Cross validation*, terlihat bahwa model *machine learning* dapat digunakan untuk melakukan prediksi adsorpsi *metilene*

biru pada karbon aktif dengan tingkat akurasi yang berbeda-beda. Model *neural network* menunjukan performa terbaik dibandingkan dengan model SVM, *Random Forest* dan *Linear Regression*. Hal ini ditunjukan dengan nilai MSE, RMSE dan MAE terkecil dan nilai terbesar pada R^2 . Hal ini sejalan dengan hasil penelitian sebelumnya yang menyatakan bahwa model NN dan SVM memiliki performa yang baik dalam memprediksi adsorpsi zat warna, bahkan lebih baik daripada metode *response surface central composite design* (Asfaram et al., 2016; Ghaedi & Vafaei, 2017).

Waktu eksekusi pada tahap latihan menunjukan bahwa model *neural network* memerlukan waktu yang lebih lama dibandingkan dengan model yang lain. Hal ini berkaitan dengan proses pembentukan sambungan syaraf baru yang membutuhkan waktu. Akan tetapi dengan proses pembelajaran yang dilakukan secara berulang maka tingkat kesalahan yang ditunjukan menjadi kecil ditunjukan oleh nilai MSE, RMSE dan MAE yang kecil dan nilai korelasi R^2 yang mendekati satu.

Model regresi linier menunjukan hasil yang kurang baik dibandingkan dengan model-model prediksi yang lainnya. Hal ini menunjukan bahwa proses adsorpsi metilen biru merupakan proses yang kompleks (Ghaedi & Vafaei, 2017; Pauletto et al., 2020; Vargas et al., 2011) sehingga model linier tidak dapat digunakan untuk memprediksi dengan baik (Ahmad et al., 2021).


Proses adsorpsi *metilene* biru pada karbon aktif dapat terjadi secara fisika dan kimia (Vargas et al., 2011; Yu & Luo, 2014). Proses adsorpsi *metilene* biru oleh karbon aktif terdiri dari beberapa tahapan yaitu perpindahan molekul *metilene* biru dari larutan ke permukaan luar karbon aktif (difusi film) yang terjadi karena interaksi cincin aromatic metilen biru dengan struktur aromatic pada permukaan karbon aktif (Vargas et al., 2011). Kemudian dilanjutkan dengan difusi intra partikel atau difusi pori, penyerapan molekul adsorbate ke dalam permukaan pori dan ruang kapiler adsorben yang terjadi karena interaksi elektro statik dan perpindahan elektron (Vargas et al., 2011; Yu & Luo, 2014).

Tabel 3. Perbandingan performa model *machine learning* pada data latihan

Model	MSE	RMSE	MAE	R^2	Waktu Train (s)
SVM	94.147	9.703	8.126	0.842	0.067
Random Forest	189.126	13.752	9.370	0.684	0.114
Neural Network	14.640	3.826	3.178	0.976	2.060
Linear Regression	194.343	13.941	12.155	0.675	0.251

Tabel 4. Perbandingan performa model *machine learning* pada tes data

Model	MSE	RMSE	MAE	R^2	Waktu Test (s)
SVM	0.951	0.975	0.970	0.998	0.012
Random Forest	133.676	11.561	7.756	0.776	0.052
Neural Network	3.51e-06	0.00187	0.00135	0.999	0.013
Linear Regression	73.571	8.577	7.788	0.876	0.009



Gambar 2. Grafik perbandingan jumlah *metilene* biru teradsorpsi antara data percobaan dengan prediksi hasil perhitungan model *machine learning* (a) *Neural Network*, (b) *SVM*, (c) *LR* dan (d) *RF*

KESIMPULAN DAN SARAN

Proses adsorpsi *metilene* biru pada karbon aktif dari biji alpukat merupakan proses yang kompleks sehingga tidak dapat diprediksi dengan model linier. Model *neural network* merupakan model *machine learning* terbaik untuk memprediksi proses adsorpsi *metilene* biru pada karbon aktif dari biji alpukat yang diaktivasi menggunakan asam fosfat dibandingkan dengan model *SVM*, *Random Forest*, regresi linier maupun model statistik konvensional.

KONTRIBUSI PENULIS

Penulis merupakan kontributor utama dalam penelitian ini.

DAFTAR PUSTAKA

- Ahmad, M. B., Soomro, U., Muqet, M., & Ahmed, Z. (2021). Adsorption of Indigo Carmine dye onto the surface-modified adsorbent prepared from municipal waste and simulation using deep neural network. *Journal of Hazardous Materials*, 408, 124433. <https://doi.org/10.1016/j.jhazmat.2020.124433>
- Ahmed, M. B., Hasan Johir, M. A., Zhou, J. L., Ngo, H. H., Nghiem, L. D., Richardson, C., Moni, M. A., & Bryant, M. R. (2019). Activated carbon preparation from biomass feedstock: Clean production and carbon dioxide adsorption. *Journal of Cleaner Production*, 225, 405–413. <https://doi.org/10.1016/j.jclepro.2019.03.342>
- Albalasmeh, A., Gharaibeh, M. A., Mohawesh, O., Alajlouni, M., Quzaih, M., Masad, M., & El Hanandeh, A. (2020). Characterization and

- Artificial Neural Networks Modelling of methylene blue adsorption of biochar derived from agricultural residues: Effect of biomass type, pyrolysis temperature, particle size. *Journal of Saudi Chemical Society*, 24(11), 811–823. <https://doi.org/10.1016/j.jscs.2020.07.005>
- Asfaram, A., Ghaedi, M., Azqhandi, M. H. A., Goudarzi, A., & Dastkhoon, M. (2016). Statistical experimental design, least squares-support vector machine (LS-SVM) and artificial neural network (ANN) methods for modeling the facilitated adsorption of methylene blue dye. *RSC Advances*, 6(46), 40502–40516. <https://doi.org/10.1039/C6RA01874B>
- Berkane, N., Meziane, S., & Aziri, S. (2019). Optimization of Congo red removal from aqueous solution using Taguchi experimental design. *Separation Science and Technology*, 1–11. <https://doi.org/10.1080/01496395.2019.1577442>
- Chibani, S., & Coudert, F.-X. (2020). Machine learning approaches for the prediction of materials properties. *APL Materials*, 8(8), 080701. <https://doi.org/10.1063/5.0018384>
- de Miranda Ramos Soares, A. P., de Oliveira Carvalho, F., de Farias Silva, C. E., da Silva Gonçalves, A. H., & de Souza Abud, A. K. (2020). Random Forest as a promising application to predict basic-dye biosorption process using orange waste. *Journal of Environmental Chemical Engineering*, 8(4), 103952. <https://doi.org/10.1016/j.jece.2020.103952>
- Drajana, I. C. R. (2017). Metode Support Vector Machine dan Forward Selection Prediksi Pembayaran Pembelian Bahan Baku Kopra. *ILKOM Jurnal Ilmiah*, 9(2), 116–123. <https://doi.org/10.33096/ilkom.v9i2.134.116-123>
- Fanourgakis, G. S., Gkagkas, K., Tylianakis, E., & Froudakis, G. (2020). A Generic Machine Learning Algorithm for the Prediction of Gas Adsorption in Nanoporous Materials. *The Journal of Physical Chemistry C*, 124(13), 7117–7126. <https://doi.org/10.1021/acs.jpcc.9b10766>
- Ghaedi, A. M., & Vafaei, A. (2017). Applications of artificial neural networks for adsorption removal of dyes from aqueous solution: A review. *Advances in Colloid and Interface Science*, 245, 20–39. <https://doi.org/10.1016/j.cis.2017.04.015>
- Ghorai, S., Sarkar, A., Raoufi, M., Panda, A. B., Schönherr, H., & Pal, S. (2014). Enhanced Removal of Methylene Blue and Methyl Violet Dyes from Aqueous Solution Using a Nanocomposite of Hydrolyzed Polyacrylamide Grafted Xanthan Gum and Incorporated Nanosilica. *ACS Applied Materials & Interfaces*, 6(7), 4766–4777. <https://doi.org/10.1021/am4055657>
- González-García, P. (2018). Activated carbon from lignocellulosics precursors: A review of the synthesis methods, characterization techniques and applications. *Renewable and Sustainable Energy Reviews*, 82, 1393–1414. <https://doi.org/10.1016/j.rser.2017.04.117>
- Hafsa, N., Rushd, S., Al-Yaari, M., & Rahman, M. (2020). A Generalized Method for Modeling the Adsorption of Heavy Metals with Machine Learning Algorithms. *Water*, 12(12), 3490. <https://doi.org/10.3390/w12123490>
- Hocking, R. R. (2003). *Methods and Applications of Linear Models: Regression and the Analysis of Variance*. John Wiley & Sons, Inc. <https://doi.org/10.1002/0471434159>
- Jaria, G., Calisto, V., Silva, C. P., Gil, M. V., Otero, M., & Esteves, V. I. (2019). Obtaining granular activated carbon from paper mill sludge – A challenge for application in the removal of pharmaceuticals from wastewater. *Science of The Total Environment*, 653, 393–400. <https://doi.org/10.1016/j.scitotenv.2018.10.346>
- Jatmiko, T. (2020). Optimization of Production Activated Carbon for Removal of Pharmaceuticals Waste Using Taguchi Method and Grey Relational Analysis. *Jurnal Riset Teknologi Pencegahan Pencemaran Industri*, 11(2), 11–18. <https://doi.org/10.21771/jrtppi.2020.v11.no2.p11-18>
- Jatmiko, T. H., Prasetyo, D. J., & Pulungan, N. A. (2018). Analisis Kinerja Reaktor Unggun Tetap untuk Produksi Hidrogen Melalui Reaksi Steam Reforming Etanol. *Jurnal Riset Teknologi Industri*, 12(1), 56–65. <https://doi.org/10.26578/jrti.v12i1.3622>

- Jatmiko, T. H., & Pratiwi, D. (2019). Metode Taguchi Untuk Optimasi Adsorpsi Zat Warna Metilen Biru Dengan Karbon Aktif. *Prosiding Seminar Nasional Industri Kerajinan Dan Batik*, 1(1), C1–C1.
- Jiang, W., Xing, X., Li, S., Zhang, X., & Wang, W. (2019). Synthesis, characterization and machine learning based performance prediction of straw activated carbon. *Journal of Cleaner Production*, 212, 1210–1223.
<https://doi.org/10.1016/j.jclepro.2018.12.093>
- Kiraz, A., Canpolat, O., Erkan, E. F., & Özer, Ç. (2019). Artificial neural networks modeling for the prediction of Pb(II) adsorption. *International Journal of Environmental Science and Technology*, 16(9), 5079–5086.
<https://doi.org/10.1007/s13762-018-1798-4>
- Kooh, M. R. R., Dahri, M. K., & Lim, L. B. L. (2018). Jackfruit seed as low-cost adsorbent for removal of malachite green: Artificial neural network and random forest approaches. *Environmental Earth Sciences*, 77(12), 434.
<https://doi.org/10.1007/s12665-018-7618-9>
- Li, M., Wei, D., Liu, T., Liu, Y., Yan, L., Wei, Q., Du, B., & Xu, W. (2019). EDTA functionalized magnetic biochar for Pb(II) removal: Adsorption performance, mechanism and SVM model prediction. *Separation and Purification Technology*, 227, 115696.
<https://doi.org/10.1016/j.seppur.2019.115696>
- Pathania, D., Sharma, S., & Singh, P. (2017). Removal of methylene blue by adsorption onto activated carbon developed from Ficus carica bast. *Arabian Journal of Chemistry*, 10, S1445–S1451.
<https://doi.org/10.1016/j.arabjc.2013.04.021>
- Patil, M. A., Shinde, J. K., Jadhav, A. L., & Deshpande, S. R. (2017). *Adsorption of Methylene Blue in waste water by low cost adsorbent Rice husk*. 10(1), 7.
- Pauletto, P. S., Dotto, G. L., & Salau, N. P. G. (2020). Optimal artificial neural network design for simultaneous modeling of multicomponent adsorption. *Journal of Molecular Liquids*, 320, 114418.
<https://doi.org/10.1016/j.molliq.2020.114418>
- Prakash, K. B., Ruwali, A., & Kanagachidambaresan, G. R. (2021). Regression. In K. B. Prakash & G. R. Kanagachidambaresan (Eds.), *Programming with TensorFlow: Solution for Edge Computing Applications* (pp. 23–37). Springer International Publishing.
https://doi.org/10.1007/978-3-030-57077-4_4
- Regti, A., Laamari, M. R., Stiriba, S.-E., & El Haddad, M. (2017). Use of response factorial design for process optimization of basic dye adsorption onto activated carbon derived from Persea species. *Microchemical Journal*, 130, 129–136.
<https://doi.org/10.1016/j.microc.2016.08.012>
- Vargas, A. M. M., Cazetta, A. L., Kunita, M. H., Silva, T. L., & Almeida, V. C. (2011). Adsorption of methylene blue on activated carbon produced from flamboyant pods (Delonix regia): Study of adsorption isotherms and kinetic models. *Chemical Engineering Journal*, 168(2), 722–730.
<https://doi.org/10.1016/j.cej.2011.01.067>
- Yu, L., & Luo, Y. (2014). The adsorption mechanism of anionic and cationic dyes by Jerusalem artichoke stalk-based mesoporous activated carbon. *Journal of Environmental Chemical Engineering*, 2(1), 220–229.
<https://doi.org/10.1016/j.jece.2013.12.016>

