



Surabaya, 6 Juli 2023

SEMINAR NASIONAL HASIL RISET DAN PENGABDIAN

"Peran Riset, Inovasi dan Pengabdian Kepada Masyarakat Bagi Pembangunan Indonesia Berkelanjutan"



DETEKSI PENGGUNAAN MASKER WAJAH DENGAN ALGORITMA DEEP LEARNING

Rani Kurnia Putri¹, Muhammad Athoillah², Arina Haqiqiyah³, Fina Wahyu Ananda Lestari⁴

^{1,3} Program Studi Pendidikan Matematika, ^{2,4} Program Studi Statistika

Universitas PGRI Adi Buana Surabaya

Email: rani@unipasby.ac.id¹, athoillah@unipasby.ac.id²

Abstrak

Keahlian *Machine Learning* dalam mengolah dan menganalisis data dengan cepat dan akurat, serta menghasilkan informasi yang bermanfaat dan relevan bagi pengguna, menjadi penyebab utama popularitasnya. Salah satu algoritma *Machine Learning* yang sering digunakan adalah *Deep Learning* (DL). DL bekerja dengan cara merepresentasikan data dalam lapisan-lapisan pembelajaran untuk memberikan representasi yang lebih berarti. Istilah "*Deep*" dalam *Deep Learning* mengindikasikan bahwa algoritma ini menggunakan lapisan-lapisan representasi secara berurutan. Penelitian ini bertujuan untuk memberikan referensi baru tentang pengembangan sistem dan analisis hasil identifikasi masker wajah menggunakan algoritma *Deep Learning*. Dari hasil penelitian yang dilakukan, diketahui bahwa model ini mampu mengenali wajah dengan baik. Hal ini dibuktikan dengan nilai rata-rata spesifisitas sebesar 93,60%, nilai rata-rata presisi sebesar 93,86%, dan nilai rata-rata sensitivitas atau recall sebesar 95,40%. Selain itu, model ini juga menunjukkan tingkat akurasi yang memadai secara keseluruhan, dengan rata-rata akurasi mencapai 94,50%.

PENDAHULUAN

Deep learning adalah cabang kecerdasan buatan yang menggunakan jaringan saraf buatan dengan banyak lapisan. Keberhasilannya dalam memecahkan masalah kompleks dan pengolahan data yang rumit telah membuatnya sangat populer. Deep learning telah mencatat kemajuan besar dalam pengenalan gambar, pengolahan citra, pengenalan suara, terjemahan mesin, dan pemodelan bahasa alami. Kemajuan dalam teknologi perangkat keras dan ketersediaan sumber daya serta framework yang kuat telah memfasilitasi pengembangan dan implementasi deep learning. Kepopuleran deep learning juga didorong oleh keberhasilannya dalam industri dan penelitian, dengan banyak perusahaan teknologi besar dan peneliti yang mengadopsinya dalam produk dan layanan mereka. (Alzubaidi et al., 2021)

Deep Learning merupakan algoritma yang bekerja dengan cara merepresentasikan data dalam layer-layer learning layer agar representasi tersebut menjadi lebih bermakna. "Deep" dalam Deep Learning berarti bahwa Deep Learning memulai lapisan representasi berurutan. Saat ini, Deep Learning biasanya memiliki lapisan dengan puluhan hingga ratusan lapisan yang berurutan dan lapisan tersebut secara otomatis dapat mempelajari data pelatihan yang diberikan. Pada Deep Learning, lapisan representasi diberi nama Neural Networks. Neural Networks memiliki struktur bertumpuk yang berarti bahwa satu lapisan akan berada di atas yang lain. Neural Networks mengambil konsep dari bidang neurobiologi dan terinspirasi oleh kemampuan untuk melihat hal-hal seperti otak manusia (Hassabis et al., 2017). Meskipun konsep utama Deep Learning dikembangkan atas inspirasi tersebut, namun model Deep Learning bukanlah model otak manusia. Ini karena tidak ada bukti yang menunjukkan bahwa otak manusia bekerja seperti model pembelajaran mendalam seperti sekarang ini (Chollet, 2021).

Deep learning sering digunakan dalam aplikasi yang memerlukan pengenalan gambar dan suara dalam bidang ilmu biologi, kesehatan, keuangan, dan teknologi, serta pengolahan bahasa alami (Alzubaidi et al., 2021; Mosavi et al., 2020). Algoritma ini memiliki kelebihan dan kelemahan, tergantung pada tugas yang ingin diselesaikan dan karakteristik data yang dihadapi. Beberapa penelitian terakhir banyak memanfaatkan algoritma *Deep learning* diantaranya: Mohsen dkk yang mengklasifikasikan tumor otak dengan menggunakan algoritma deep learning (Mohsen et al., 2018) atau contoh lainnya seperti yang dilakukan oleh Gauri dkk yang memanfaatkan algoritma deep learning untuk mendeteksi adanya Spam pada platform media sosial seperti twitter dan facebook (Jain et al., 2019). Dan tentunya banyak penelitian lain yang memanfaatkan kedua algoritma tersebut yang tidak bisa dijelaskan semuanya dalam artikel ini.

Banyaknya penelitian yang melibatkan Deep learning menjadikan algoritma ini semakin menarik untuk diteliti lebih lanjut. Tujuan dari penelitian ini adalah untuk memberikan referensi tentang cara membuat sistem dan menganalisis hasil dari identifikasi masker wajah menggunakan algoritma deep learning. Deteksi masker wajah merupakan sebuah permasalahan

yang penting dalam pengenalan wajah dan keamanan. Pada masa pandemi seperti saat ini, penggunaan masker wajah menjadi keharusan untuk mengurangi penyebaran penyakit. Oleh karena itu, penelitian tentang deteksi masker wajah memiliki relevansi yang tinggi dan penting dalam berbagai bidang, termasuk keamanan, kesehatan masyarakat, dan teknologi pengenalan wajah. Tantangan utama dalam deteksi masker wajah adalah perbedaan tampilan wajah ketika menggunakan dan tidak menggunakan masker. Penelitian tentang deteksi masker wajah bertujuan untuk mengembangkan metode dan algoritma yang efektif dalam mengenali wajah yang menggunakan masker. Dengan menggunakan teknik deep learning, seperti algoritma deep neural network, convolutional neural network (CNN), atau metode deep learning lainnya.(Nowrin et al., 2021). Oleh karena itu, kami memberikan studi untuk memberikan pemahaman yang lebih baik tentang seberapa baik algoritma ini digunakan untuk mengklasifikasikan masker wajah.

METODE

Data Penelitian

Data yang digunakan dalam penelitian ini adalah kumpulan citra masker wajah yang diperoleh dari sumber publik di GitHub (<https://github.com/prajnasb>) dan Kaggle (<https://www.kaggle.com/andrewmvd>). Dataset ini terdiri dari citra-citra wajah yang memiliki dan tidak memiliki masker. Contoh citra-citra wajah dengan dan tanpa masker yang digunakan dalam penelitian dapat dilihat pada Gambar 1. Total dataset yang digunakan adalah 1000 citra, dengan 500 citra merupakan wajah yang menggunakan masker dan 500 citra lainnya adalah wajah tanpa masker. Dataset tersebut dibagi menjadi dua bagian, yaitu data latihan (900 citra atau 90%) dan data uji (100 citra atau 10%).



Gambar 1. Contoh citra wajah dengan dan tanpa masker (<https://github.com/prajnasb> dan <https://www.kaggle.com/andrewmvd>).

Pra-Proses

Untuk mencapai hasil yang optimal, diperlukan pra-pemrosesan pada dataset citra sebelum melakukan klasifikasi dengan model algoritma *Deep Learning*. Berikut adalah metode-metode yang digunakan dalam tahap pra-pemrosesan:

1. Pemangkasan (*Cropping*):

Langkah pertama dalam persiapan dataset adalah melakukan pemangkasan gambar secara manual menggunakan perangkat lunak pengolahan gambar. Tujuannya adalah untuk mengoptimalkan pemrosesan dan memastikan konsistensi ukuran citra.

2. Pembersihan Noise (*Noise Cleaning*):

Untuk meningkatkan kualitas dataset, dilakukan proses yang disebut pembersihan noise untuk menghilangkan piksel-piksel yang mengganggu pada gambar dan dapat menurunkan kualitas dataset. Proses ini dilakukan secara manual menggunakan perangkat lunak pengolahan gambar untuk memastikan akurasi tinggi selama tahap klasifikasi.

3. Konversi ke *Grayscale*:

Mengubah gambar ke mode *grayscale* memiliki beberapa manfaat, seperti menyederhanakan gambar dan mempermudah interpretasi, meningkatkan kecepatan pemrosesan, dan mengurangi ukuran file yang memerlukan ruang penyimpanan yang lebih sedikit. Proses konversi ini melibatkan penghilangan informasi hue dan saturasi namun mempertahankan luminansi.

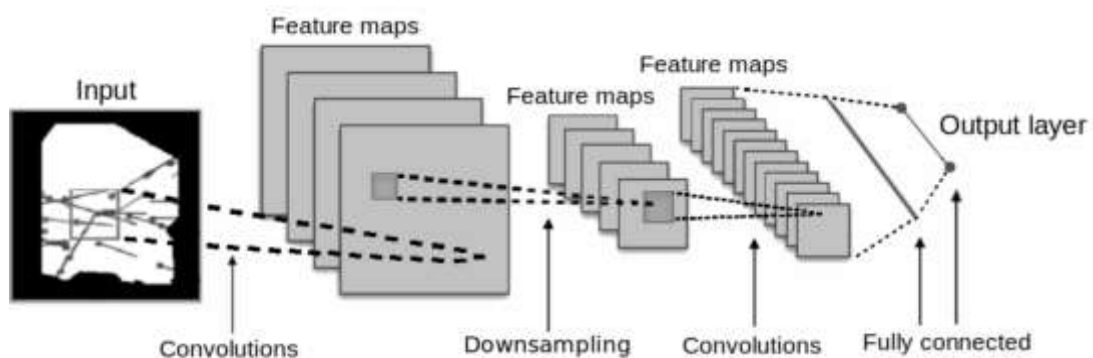
Dengan menerapkan metode-metode pra-pemrosesan ini, diharapkan dataset citra dapat siap digunakan untuk klasifikasi menggunakan algoritma *Deep Learning*.

Klasifikasi dengan Deep Learning

Deep Learning adalah algoritma jaringan saraf tiruan untuk mengidentifikasi dan mengkategorikan input data ke dalam kelas atau kategori yang telah ditentukan (Zhong et al., 2019). Umumnya, klasifikasi menggunakan Deep Learning memerlukan data dalam jumlah besar, sumber daya komputasi yang kuat, dan keahlian dalam arsitektur jaringan saraf dan teknik pelatihan. Meskipun demikian, algoritma ini telah terbukti sebagai alat yang sangat efektif dalam menyelesaikan masalah klasifikasi yang kompleks di berbagai aplikasi, termasuk pengenalan gambar dan ucapan, pemrosesan bahasa alami, dan analitik prediktif. (Sarker, 2021).

Arsitektur jaringan saraf tiruan merujuk pada struktur dan organisasi dari berbagai lapisan dan koneksinya. Pemilihan arsitektur yang tepat tergantung pada masalah yang ingin diselesaikan dan karakteristik data input. Selain itu, ada faktor-faktor lain yang perlu dipertimbangkan saat merancang arsitektur model, termasuk jumlah dan ukuran lapisan, jenis fungsi aktivasi yang digunakan di setiap lapisan, serta algoritma optimisasi yang digunakan untuk menyesuaikan parameter model selama proses pelatihan. (Khan et al., 2020). Dalam penelitian

ini, arsitektur jaringan syaraf tiruan yang digunakan adalah model Convolutional. Lapisan convolutional dan down-sampling diikuti oleh satu atau lebih lapisan yang terhubung sepenuhnya. Seperti namanya, lapisan yang terhubung sepenuhnya adalah lapisan di mana neuron terhubung ke semua neuron di lapisan sebelumnya. Lapisan ini menggabungkan semua fitur yang dipelajari oleh lapisan sebelumnya di seluruh citra untuk mengidentifikasi pola yang lebih besar. Lapisan terakhir yang terhubung sepenuhnya menggabungkan fitur untuk mengklasifikasikan citra. Oleh karena itu, parameter *Output Size* pada lapisan terakhir yang terhubung sepenuhnya sama dengan jumlah kelas pada data target (Mas-Pujol et al., 2022).



Gambar 2. Arsitektur Algoritma Deep Learning (Mas-Pujol et al., 2022)

Proses pelatihan melibatkan perulangan iteratif *forward propagation* dan *backpropagation*. Dalam propagasi maju, input data dimasukkan melalui jaringan dan prediksi dibuat. Kesalahan antara keluaran yang diprediksi dan label sebenarnya kemudian dihitung, dan kesalahan ini digunakan untuk menyesuaikan bobot koneksi di jaringan selama propagasi balik. Tujuan dari pelatihan adalah untuk meminimalkan kesalahan antara label yang diprediksi dan benar selama iterasi, atau *epoch*, dari proses pelatihan. Kecepatan pembelajaran, yang mengontrol ukuran langkah setiap pembaruan bobot, adalah parameter kunci untuk disetel selama Latihan (Montesinos López et al., 2022). Setelah proses pelatihan selesai, model dievaluasi pada dataset validasi terpisah untuk mengukur akurasi dan performa dari sistem yang telah dibuat.

HASIL DAN PEMBAHASAN

Hasil penelitian ditunjukkan dengan menampilkan hasil perhitungan Presisi, Spesifisitas, *Recall*/Sensitivitas, dan Akurasi. Semua nilai tersebut diperoleh dari perbandingan hasil prediksi dengan dataset sebenarnya yang diilustrasikan oleh *Confusion Matrix* seperti yang ditunjukkan pada Gambar 3. Pengujian sistem dilakukan dengan menggunakan metode *Hold-out Validation*. Metode ini melibatkan pemilihan persentase sampel data secara acak dan menyisihkannya sebagai set validasi, sedangkan sampel yang tersisa digunakan untuk melatih model. Proses diulang 10 kali, setiap kali dengan pemilihan sampel acak yang berbeda untuk validasi. Selama

setiap iterasi, model dilatih pada set pelatihan dan dievaluasi pada set validasi. Pendekatan ini membantu mengurangi potensi bias atau varians yang dapat muncul dari penggunaan satu set validasi. Evaluasi akhir kinerja model didasarkan pada kinerja rata-rata di semua set validasi yang digunakan dalam iterasi. Ini memberikan ukuran yang lebih komprehensif dan representatif dari keefektifan model dalam mengidentifikasi wajah dengan atau tanpa masker. (Athoillah et al.,2022; Xu & Goodacre, 2018).

		Predicted Class		
		Positive	Negative	
Actual Class	Positive	True Positive (TP)	False Negative (FN)	Sensitivity $\frac{TP}{(TP + FN)}$
	Negative	False Positive (FP)	True Negative (TN)	Specificity $\frac{TN}{(TN + FP)}$
		Precision $\frac{TP}{(TP + FP)}$	Accuracy $\frac{TP + TN}{(All\ Sample)}$	

Figure 3. Confusion Matrix (Athoillah et al., 2022)

Hasil penelitian menunjukkan bahwa Secara keseluruhan, hasil percobaan menunjukkan bahwa model klasifikasi deep learning ini memiliki performa yang tinggi di keempat aspek sensitivitas, spesifisitas, presisi, dan akurasi. Berikut detail hasil dari tiap percobaan.

TABEL 1. Hasil Uji Coba Keseluruhan

Percobaan	Sensitivitas/ <i>Recall</i>	Spesifisitas	Presisi	Akurasi
1	98,00%	96,00%	96,08%	97,00%
2	98,00%	94,00%	94,23%	96,00%
3	94,00%	88,00%	88,68%	91,00%
4	94,00%	98,00%	97,92%	96,00%
5	80,00%	98,00%	97,56%	89,00%
6	100,00%	94,00%	94,34%	97,00%
7	94,00%	94,00%	94,00%	94,00%
8	98,00%	90,00%	90,74%	94,00%
9	100,00%	92,00%	92,59%	96,00%
10	98,00%	92,00%	92,45%	95,00%
Average	95,40%	93,60%	93,86%	94,50%

Tabel 1 menggambarkan hasil performa sistem yang dilatih untuk mendeteksi penggunaan masker wajah berdasarkan pada beberapa data input. Model tersebut diuji pada sepuluh percobaan yang berbeda dan tabel menunjukkan hasil yang diperoleh pada setiap percobaan. Dalam tabel tersebut, terdapat beberapa nilai yang menonjol, diantaranya:

- Sensitivitas/recall menggambarkan sejauh mana model mampu mengenali dengan benar hasil positif. Hasil percobaan menunjukkan tingkat sensitivitas yang bervariasi antara 80,00% hingga 100,00%. Semakin tinggi sensitivitas, semakin baik model dapat mengenali hasil positif dengan benar.
- Spesifisitas menunjukkan kemampuan model untuk mengenali dengan benar hasil negatif. Rentang nilai spesifisitas dalam percobaan ini adalah antara 88,00% hingga 98,00%. Semakin tinggi spesifisitas, semakin baik model dapat mengenali hasil negatif dengan benar.
- Presisi mengindikasikan tingkat ketepatan model dalam memberikan hasil positif yang benar. Hasil percobaan menunjukkan rentang presisi antara 88,68% hingga 97,92%. Semakin tinggi presisi, semakin sedikit hasil positif palsu yang diberikan oleh model.
- Akurasi merupakan ukuran keseluruhan tingkat keakuratan model. Rentang nilai akurasi dalam percobaan ini adalah antara 89,00% hingga 97,00%. Semakin tinggi akurasi, semakin baik model dalam memberikan hasil klasifikasi yang benar secara keseluruhan.

Selain itu, terdapat pula nilai rata-rata dari keseluruhan percobaan yang dihitung untuk setiap aspek performa. Rata-rata sensitivitas adalah 95,40%, rata-rata spesifisitas adalah 93,60%, rata-rata presisi adalah 93,86%, dan rata-rata akurasi adalah 94,50%. Nilai rata-rata ini memberikan gambaran tentang performa rata-rata model dalam aspek-aspek yang diuji dalam penelitian ini.

Selain rata-rata, Dalam hasil uji coba yang diberikan, terdapat beberapa nilai yang menarik dan mencerminkan performa model klasifikasi deep learning yang signifikan:

- Percobaan 6 menunjukkan hasil yang paling menonjol dengan mencapai sensitivitas sebesar 100,00%. Hal ini mengindikasikan bahwa model dapat mengenali dengan sempurna semua hasil positif yang ada dalam dataset. Sensitivitas yang tinggi seperti ini sangat penting dalam aplikasi yang memerlukan deteksi yang akurat terhadap data positif.
- Pada Percobaan 4, spesifisitas mencapai 98,00%, yang artinya model memiliki kemampuan yang sangat baik dalam mengidentifikasi dengan benar semua hasil negatif. Spesifisitas yang tinggi adalah faktor penting dalam mengurangi jumlah kesalahan klasifikasi yang disebabkan oleh hasil negatif palsu.
- Percobaan 1 dan 2 menunjukkan nilai presisi yang tinggi, yaitu lebih dari 94%. Hal ini menandakan bahwa hasil positif yang diberikan oleh model cenderung sangat akurat. Presisi yang tinggi merupakan indikator bahwa model cenderung memberikan hasil positif yang benar tanpa banyak menghasilkan hasil positif palsu.

- Dalam Percobaan 5, meskipun sensitivitasnya sedikit lebih rendah (80,00%), model tetap menunjukkan spesifisitas yang tinggi (98,00%) dan presisi yang cukup tinggi (97,56%). Hal ini menunjukkan bahwa model mampu mengenali dengan baik hasil negatif dan memberikan hasil positif yang akurat, meskipun ada beberapa hasil positif yang mungkin terlewatkan.
- Rata-rata akurasi sebesar 94,50% menggambarkan tingkat keakuratan model secara keseluruhan. Ini menunjukkan bahwa model klasifikasi deep learning memiliki performa yang konsisten dalam penelitian ini, dengan kemampuan yang baik dalam mengklasifikasikan data dengan benar.

Dalam keseluruhan, hasil uji coba ini menunjukkan bahwa model klasifikasi deep learning memiliki performa yang tinggi dalam aspek sensitivitas, spesifisitas, presisi, dan akurasi. Hasil ini memberikan indikasi bahwa model dapat menjadi alat yang efektif dalam memecahkan masalah klasifikasi yang kompleks dalam berbagai aplikasi. Seliain itu, dari analisis tersebut dapat diketahui bahwa tidak hanya nilai rata-rata yang perlu diperhatikan, tetapi juga nilai-nilai pada setiap percobaan yang dapat memberikan gambaran yang lebih detail tentang kelebihan dan kekurangan dari sebuah model klasifikasi pada kasus-kasus tertentu.

KESIMPULAN

Penelitian ini bertujuan untuk memberikan panduan tentang pembuatan sistem dan analisis hasil identifikasi masker wajah menggunakan algoritma deep learning. Dataset yang digunakan dalam penelitian ini diperoleh dari sumber seperti Github (<https://github.com/prajnasb>) dan Kaggle (<https://www.kaggle.com/andrewmvd>). Dataset ini terdiri dari citra wajah dengan dan tanpa masker yang kemudian dianalisis menggunakan metode deep learning dan diuji dengan menggunakan skema validasi Hold-out validation secara berulang.

Berdasarkan analisis identifikasi masker wajah dengan deep learning yang dilakukan, dapat disimpulkan bahwa model ini menunjukkan performa yang baik dalam mengenali wajah dengan atau tanpa masker. Hal ini dapat dilihat dari nilai rata-rata spesifisitas dan presisi sebesar 96,00%, serta nilai rata-rata sensitivitas atau recall sebesar 93,47%. Selain itu, model ini juga memberikan akurasi yang cukup tinggi dalam melakukan klasifikasi secara keseluruhan dengan rata-rata akurasi sebesar 94,73%. Dengan demikian, model deep learning ini dapat diandalkan untuk digunakan dalam melakukan klasifikasi pada data yang serupa dengan data yang telah digunakan dalam analisis ini. Namun, perlu diingat bahwa kinerja model deep learning ini sangat tergantung pada kualitas dan jumlah data yang digunakan untuk melatihnya. Oleh karena itu, agar dapat mencapai performa yang optimal, model ini perlu terus diperbarui dan dilatih dengan menggunakan data yang lebih banyak dan berkualitas.

UCAPAN TERIMAKASIH

Tim peneliti mengucapkan rasa terima kasih kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat (LPPM) di Universitas PGRI Adi Buana Surabaya yang telah memberikan dukungan dana melalui program Hibah Adi Buana Tahun 2022/2023. Dukungan ini sangat berarti bagi kelancaran proses penelitian yang sedang dilakukan.

DAFTAR PUSTAKA

- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 53. <https://doi.org/10.1186/s40537-021-00444-8>
- Athoillah, M., Purnaningrum, E., & Putri, R. K. (2022). Modified Multi-Kernel Support Vector Machine for Mask Detection. *CommIT (Communication and Information Technology) Journal*, 16(2), 159–166.
- Chollet, F. (2021). *Deep learning with Python*. Simon and Schuster.
- Hassabis, D., Kumaran, D., Summerfield, C., & Botvinick, M. (2017). Neuroscience-inspired artificial intelligence. *Neuron*, 95(2), 245–258.
- Jain, G., Sharma, M., & Agarwal, B. (2019). Spam detection in social media using convolutional and long short term memory neural network. *Annals of Mathematics and Artificial Intelligence*, 85(1), 21–44.
- Jalil, N. A., Hwang, H. J., & Dawi, N. M. (2019). Machines learning trends, perspectives and prospects in education sector. *Proceedings of the 3rd International Conference on Education and Multimedia Technology*, 201–205.
- Khan, A., Sohail, A., Zahoora, U., & Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 53, 5455–5516.
- Mas-Pujol, S., Salami, E., & Pastor, E. (2022). RNN-CNN Hybrid Model to Predict C-ATC CAPACITY Regulations for En-Route Traffic. *Aerospace*, 9, 93. <https://doi.org/10.3390/aerospace9020093>
- Mohsen, H., El-Dahshan, E.-S. A., El-Horbaty, E.-S. M., & Salem, A.-B. M. (2018). Classification using deep learning neural networks for brain tumors. *Future Computing and Informatics Journal*, 3(1), 68–71.
- Montesinos López, O. A., Montesinos López, A., & Crossa, J. (2022). Fundamentals of Artificial Neural Networks and Deep Learning. In *Multivariate Statistical Machine Learning Methods for Genomic Prediction* (pp. 379–425). Springer.
- Mosavi, A., Ardabili, S., & Varkonyi-Koczy, A. (2020). *List of Deep Learning Models* (pp. 202–214). https://doi.org/10.1007/978-3-030-36841-8_20
- Nowrin, A., Afroz, S., Rahman, M. S., Mahmud, I., & Cho, Y.-Z. (2021). Comprehensive review on facemask detection techniques in the context of covid-19. *IEEE Access*, 9, 106839–106864.

- Ray, S. (2019). A Quick Review of Machine Learning Algorithms. *2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)*, 35–39. <https://doi.org/10.1109/COMITCon.2019.8862451>
- Sarker, I. H. (2021). Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. *SN Computer Science*, 2(6), 420. <https://doi.org/10.1007/s42979-021-00815-1>
- Shalev-Shwartz, S., & Ben-David, S. (2014). *Understanding machine learning: From theory to algorithms*. Cambridge university press.
- Xu, Y., & Goodacre, R. (2018). On splitting training and validation set: a comparative study of cross-validation, bootstrap and systematic sampling for estimating the generalization performance of supervised learning. *Journal of Analysis and Testing*, 2(3), 249–262.
- Zhong, B., Xing, X., Love, P., Wang, X., & Luo, H. (2019). Convolutional neural network: Deep learning-based classification of building quality problems. *Advanced Engineering Informatics*, 40, 46–57.