

DETEKSI DAN KLASIFIKASI OTOMATIS LAPISAN GRAFENA BERBASIS YOLOV11

Junervin¹, Syamsuwarni Rambe², Silmi Azmi³, Muhammad Luqmanul Hakim⁴, Amina Kurniasi Alu⁵, Tresna Ayu Safitri⁶

^{1,2,3,4,5,6} Program Studi Teknik Industri Pertanian, Universitas Linggabuana PGRI Sukabumi, Kota Sukabumi

Corresponding author
E-mail: junervin@unlip.ac.id



Diterima : 03-02-2025
Direvisi : 11-02-2025
Dipublikasi : 25-02-2025

Kata Kunci: YOLOv11, grafena, deep learning, deteksi objek, rekayasa material

Abstrak: Automatic detection and classification of graphene layers pose a significant challenge in artificial intelligence-based material analysis. This study aims to develop a YOLOv11-based detection model capable of identifying and classifying graphene with varying layer thicknesses. The annotated dataset consists of four classes: 1-Layer, 2-Layer, 3-Layer, and 4-Layer. The model was trained and evaluated using various experimental scenarios to ensure both detection accuracy and speed. The evaluation results indicate that the model achieved a precision of 0.68, a recall of 0.623, an mAP50 of 0.69, and an mAP50-95 of 0.45, with the 1-Layer category demonstrating the highest performance. The model reliably classifies graphene layers with high efficiency, enabling real-time material analysis applications. With an inference speed of 40.4 ms per image, this model holds significant potential for implementation in advanced material-based industries. The primary contribution of this study is the introduction of a deep learning-based solution that enhances the efficiency and accuracy of nanoparticle detection, supporting technological advancements in materials science and engineering.

Abstrak: Deteksi dan klasifikasi lapisan grafena secara otomatis merupakan tantangan dalam analisis material berbasis kecerdasan buatan. Penelitian ini bertujuan untuk mengembangkan model deteksi berbasis YOLOv11 yang mampu mengidentifikasi dan mengklasifikasikan grafena dalam berbagai ketebalan lapisan. Dataset anotasi terdiri dari empat kelas: 1-Layer, 2-Layer, 3-Layer, dan 4-Layer. Model dilatih dan diuji menggunakan berbagai skenario eksperimental untuk memastikan akurasi dan kecepatan deteksinya. Hasil evaluasi menunjukkan bahwa model mencapai precision sebesar 0,68, recall 0,623, mAP50 0,69, dan mAP50-95 0,45, dengan kategori 1-Layer menunjukkan

	<i>performa terbaik. Model ini mampu mengklasifikasikan lapisan grafena secara andal dengan efisiensi tinggi, memungkinkan aplikasi dalam analisis material secara real-time. Dengan kecepatan inferensi 40,4 ms per gambar, model ini sangat potensial untuk digunakan dalam berbagai industri berbasis material maju. Kontribusi utama penelitian ini adalah menghadirkan solusi berbasis deep learning yang dapat meningkatkan efisiensi dan akurasi deteksi nanopartikel, mendukung perkembangan teknologi dalam rekayasa dan ilmu material.</i>
--	--

PENDAHULUAN

Grafena merupakan material dua dimensi yang memiliki sifat unik, termasuk konduktivitas listrik dan termal yang tinggi, fleksibilitas mekanis, serta transparansi optik. Material ini banyak digunakan dalam berbagai bidang seperti elektronik, material komposit, sensor, penyimpanan energi, dan biomedis (Geim dan Novoselov, 2007). Salah satu aspek penting dalam karakterisasi grafena adalah identifikasi jumlah lapisannya, karena sifat fisik dan elektroniknya sangat bergantung pada ketebalan material tersebut.

Metode konvensional untuk mengidentifikasi jumlah lapisan grafena umumnya melibatkan spektroskopi Raman, mikroskop optik, dan *Atomic Force Microscopy* (AFM) (Shearer et al., 2016). Meskipun metode ini dapat memberikan hasil yang akurat, penggunaannya memerlukan peralatan yang cukup mahal, waktu analisis yang lama, serta ketergantungan pada operator peralatan. Selain itu, keterbatasan dalam hal resolusi dan akurasi gambar dapat menyebabkan kesalahan klasifikasi pada lapisan grafena yang sangat tipis. Oleh karena itu, diperlukan metode yang lebih efisien dan otomatis untuk mengklasifikasikan lapisan grafena secara lebih cepat dan akurat.

Dalam beberapa tahun terakhir, kecerdasan buatan (*Artificial Intelligence*) berbasis *deep learning* menjadi pendekatan yang populer untuk analisis citra dalam berbagai bidang, termasuk karakterisasi material nano. Model *deep learning* memungkinkan analisis otomatis terhadap citra mikroskopik dengan akurasi yang tinggi. Salah satu arsitektur *deep learning* yang banyak digunakan dalam deteksi objek adalah *You Only Look Once* (YOLO), yang dikenal karena kemampuannya dalam melakukan deteksi secara *real-time* dengan kecepatan dan akurasi yang tinggi (Khan dan Jensen, 2025).

Penelitian ini bertujuan untuk menerapkan model YOLOv11 untuk mendeteksi dan mengklasifikasikan grafena berdasarkan jumlah lapisannya menggunakan dataset Grafena

Material Microscopy (GMM) (Uslu et al., 2024). Dataset ini mengandung citra grafena dengan anotasi berbasis COCO dengan ketebalan satu hingga empat lapisan. Penggunaan YOLOv11 diharapkan dapat meningkatkan efisiensi dalam karakterisasi grafena, baik dalam kecepatan inferensi maupun akurasi deteksi.

KAJIAN PUSTAKA

Dalam beberapa tahun terakhir, berbagai penelitian telah dilakukan untuk mengembangkan metode otomatis berbasis *deep learning* dalam mendeteksi grafena dan material nano lainnya. Beberapa studi menunjukkan efektivitas YOLO dalam mendeteksi material berbasis citra mikroskopik. Misalnya, penelitian oleh Chen et al. (2023) menunjukkan bahwa YOLOv4 mampu mendeteksi material 2D dalam citra mikroskop optik dengan akurasi tinggi dibandingkan berbagai metode konvensional. Selain itu, penelitian oleh Khalili dan Smyth (2024) mengembangkan metode YOLO yang telah dioptimalkan untuk mendeteksi objek kecil dalam citra mikroskopik.

Mahjoubi et al. (2023) menggunakan pendekatan *Convolutional Neural Networks* (CNN) untuk mengklasifikasikan grafena berdasarkan jumlah lapisannya. Hasil penelitian ini menunjukkan bahwa pendekatan berbasis *deep learning* lebih unggul dibandingkan metode berbasis fitur lainnya dalam mengidentifikasi variasi ketebalan grafena. Studi lain oleh Çınar et al. (2023) menunjukkan bahwa YOLOv5 dapat digunakan untuk mendeteksi partikel nano dalam citra mikroskopik, dengan hasil yang lebih cepat dan akurat dibandingkan metode segmentasi klasik.

Seiring dengan perkembangan model YOLO, beberapa penelitian telah berupaya meningkatkan akurasi deteksi grafena dengan memodifikasi arsitektur dan model pelatihan. Misalnya, Zenebe et al. (2022) mengevaluasi arsitektur deteksi objek untuk mendeteksi lapisan tipis material 2D dan menemukan bahwa YOLO memiliki keseimbangan terbaik antara kecepatan dan akurasi deteksi. Sementara itu, penelitian oleh Guo et al. (2022) mengembangkan metode yang menggabungkan YOLO dengan model transformer untuk meningkatkan deteksi objek berukuran kecil seperti lapisan grafena.

Penggunaan YOLOv11 dalam penelitian ini memberikan beberapa keuntungan dibandingkan metode konvensional, antara lain kecepatan inferensi tinggi, kemampuan mengenali variasi bentuk dan ukuran lapisan grafena tanpa perlu pemrosesan manual yang kompleks, dan potensi integrasi dengan sistem otomatisasi di laboratorium, sehingga dapat mempercepat analisis material nano.


Seiring dengan perkembangan teknologi *deep learning* dan ketersediaan dataset yang lebih baik, diharapkan sistem deteksi grafena berbasis AI dapat semakin akurat dan efisien. Dengan adanya sistem otomatis ini, diharapkan analisis lapisan grafena dapat dilakukan dengan lebih cepat dan akurat, sehingga mendukung pengembangan berbagai aplikasi berbasis grafena dalam industri dan penelitian.

METODE PENELITIAN

Pengumpulan Data

Dataset yang digunakan pada penelitian ini menggunakan Grafena GMM Dataset (Uslu et al., 2024) yang merupakan gambar hasil karakterisasi lapisan grafena menggunakan mikroskop optik Nikon Eclipse pada substrat Si/SiO₂ dengan lima perbesanan lensa objektif (2.5x, 5x, 20x, 50x, 100x). Dataset terdiri dari 1775 gambar dengan 4 kelas (1-Layer, 2-Layer, 3-Layer, dan 4-Layer). Sampel gambar lapisan grafena disajikan pada Tabel 1.

Tabel 1. Sampel Gambar Lapisan Grafena

Nama Citra	Layer	Citra
1c34e4bd-0bc1-4a56-90d8-145e5519964f	1-Layer	
0e8284a8-24dc-465a-8529-b2160395dfdf	2-Layer	
0b10c8df-d236-48f7-84de-5cbf9e3aae78	3-Layer	
30cac8ac-d94e-48bc-bf3e-a766c8b1235b	4-Layer	

1344465d-b444-4dec- b5bb-6c39c7b6b210	Null	
--	------	--

Preprocessing Data

Preprocessing data adalah tahap penting dalam pemrosesan gambar sebelum digunakan dalam pelatihan model YOLOv11. Pada penelitian ini, preprocessing meliputi dua langkah utama: anotasi gambar dan pembagian (split) data.

Anotasi Gambar

Pada tahap anotasi, gambar lapisan grafena (train_images dan test_images) pada Grafena GMM Dataset digabungkan dan dianotasi menggunakan menggunakan file anotasi _300 dalam format COCO (Common Objects in Context). Anotasi ini mendukung representasi objek dalam bentuk *bounding box*, *segmentation mask*, dan *keypoints* sehingga memungkinkan pemrosesan data yang lebih terstruktur dalam model deteksi objek berbasis *deep learning*.

Split data

Dataset dibagi menjadi tiga bagian yaitu data pelatihan, data validasi, dan data pengujian (Tabel 2). Pembagian ini untuk memastikan bahwa model YOLOv11 memiliki cukup data untuk belajar (*training set*), data untuk evaluasi selama proses pelatihan (*validation set*), dan data untuk pengujian akhir kinerja model (*test set*). Pembagian ini dirancang untuk memberikan keseimbangan antara pelatihan yang efektif dan evaluasi kinerja model yang akurat.

Tabel 2. Pembagian Data

Kategori	Jumlah Gambar	Persentase
<i>Training Set</i>	916	70%
<i>Validation Set</i>	252	20%
<i>Test Set</i>	132	10%
Total	1300	100%


Pelatihan Model

Penelitian ini menggunakan model YOLOv11m yang memiliki keseimbangan antara kecepatan inferensi dan akurasi. Arsitektur model YOLOv11m terdiri dari 125 layer dengan total 20.03 juta parameter, sehingga memungkinkan efisiensi komputasi yang tinggi dengan

kompleksitas sekitar 67.7 GFLOPs. Pelatihan model dilakukan sebanyak 50 epochs dengan ukuran gambar input 800 piksel. Dataset yang digunakan telah dianotasi dalam format COCO (*Common Objects in Context*), yang memungkinkan representasi objek dalam bentuk *bounding box* dan *segmentation mask*.

Pelatihan model dilakukan menggunakan framework PyTorch dengan konfigurasi *batch size* yang disesuaikan dengan kapasitas komputasi. Selama pelatihan, model dioptimalkan menggunakan algoritma *Stochastic Gradient Descent* (SGD) atau AdamW dengan strategi *cosine decay* dan adaptasi *learning rate* sehingga dapat mempercepat konvergensi (Tian et al., 2023).

Model ini mengadopsi struktur CSPDarkNet dengan blok C3k2, SPPF, dan C2PSA, yang dapat meningkatkan kemampuan ekstraksi fitur dan deteksi multi-skala. Pada tahap awal, gambar input diproses melalui beberapa lapisan konvolusi (Conv), dengan jumlah filter yang meningkat secara bertahap dari 16 hingga 256, diikuti dengan operasi *max pooling* untuk mengurangi dimensi spasial. Blok SPPF (*Spatial Pyramid Pooling-Fast*) digunakan untuk meningkatkan kemampuan model dalam menangani variasi ukuran objek, sedangkan C2PSA digunakan untuk memperkuat pemetaan spasial dan hubungan antar fitur. Arsitektur model YOLOv11 secara umum disajikan pada gambar 1.



Gambar 1. Arsitektur Model U-Net (Khan dan Jensen, 2025) di bawah lisensi CC BY 4.0

Evaluasi model

Setelah tahap pelatihan selesai, model dievaluasi menggunakan dataset validasi untuk mengukur kinerja model pada data yang belum pernah ditemukan sebelumnya. Metrik evaluasi

utama yang digunakan pada penelitian ini mencakup mean Average Precision (mAP), Precision, Recall, dan F1-score untuk menilai keakuratan deteksi dan klasifikasi objek.

HASIL DAN PEMBAHASAN


Hasil Preprocessing Data

Hasil anotasi gambar menunjukkan distribusi jumlah anotasi untuk setiap kelas, sebagaimana disajikan dalam Tabel 3 serta contoh hasil anotasi pada Tabel 4. Kelas dengan jumlah anotasi tertinggi adalah 1-Layer dengan 1.172 anotasi, diikuti oleh 2-Layer dengan 1.148 anotasi. Sementara itu, kelas 3-Layer dan 4-Layer masing-masing memiliki 797 dan 585 anotasi. Kelas Null memiliki 475 anotasi, yang muncul sebagai akibat dari penggunaan file anotasi _300 yang menetapkan batas minimum ukuran objek sebesar 300 piksel. Dengan demikian, objek lapisan grafena yang berukuran lebih kecil dari 300 piksel tidak dianotasi dan dikategorikan sebagai Null.

Tabel 3. Hasil Anotasi Gambar

Kelas	Jumlah Anotasi
1-Layer	1172
2-Layer	1148
3-Layer	797
4-Layer	585
Null	475

Tabel 4. Sampel Gambar Hasil Anotasi

Kelas	Gambar Asli	Hasil Anotasi
1-Layer		
2-Layer		

3-Layer		
4-Layer		
Null		

Untuk mencegah model belajar dari pola yang tidak relevan, maka data kategori Null tidak dimasukkan dalam *training set*. Selain itu, untuk mengatasi ketidakseimbangan data pada tiap kelas maka dilakukan proses *oversampling* pada dua kelas minoritas (3-Layer dan 4-Layer) sehingga diperoleh data *training set* seperti yang disajikan pada Tabel 5.

Tabel 5. Training Set Hasil Oversampling


Kelas	Jumlah Anotasi
1-Layer	1681
2-Layer	1815
3-Layer	1212
4-Layer	1683

Hasil Pelatihan dan Evaluasi Model

Hasil *confusion matrix* pada Gambar 2 menunjukkan bahwa model YOLOv11m memiliki performa yang cukup baik dalam mengenali beberapa kelas, namun masih mengalami kesalahan klasifikasi, terutama terhadap gambar latar belakang. Kelas 1-Layer memiliki akurasi 75%, tetapi 25% diklasifikasikan sebagai latar belakang, mengindikasikan fitur yang tumpang tindih. Kelas 2-Layer memiliki 69% akurasi, tetapi 30% diklasifikasikan sebagai latar belakang, yang menunjukkan bahwa model kesulitan membedakan struktur ini.


Kelas 3-Layer dan 4-Layer memiliki akurasi masing-masing 59% dan 51%, dengan sebagian besar kesalahan klasifikasi terjadi pada latar belakang. Kesalahan klasifikasi terhadap

latar belakang yang cukup tinggi (23-31%) menunjukkan bahwa model masih kesulitan dalam pemisahan fitur objek yang kompleks.



Gambar 2. Normalized Confusion Matrix

Oleh karena itu, peningkatan performa dapat dilakukan dengan augmentasi data (Shorten dan Khoshgoftaar, 2019), *class rebalancing* (Buda et al., 2018), dan *hard-negative mining* (Shrivastava et al., 2016). Selain itu, penerapan YOLOv11-seg dapat membantu meningkatkan segmentasi objek untuk mengurangi kesalahan klasifikasi (Terven et al., 2023).



Gambar 3. Hasil Pelatihan Model





Gambar 3 menunjukkan peningkatan performa pelatihan yang sangat baik. Grafik loss function (train/box_loss, train/cls_loss, train/df_l_loss, val/box_loss, val/cls_loss, val/df_l_loss) menunjukkan tren penurunan yang konsisten, menandakan model semakin akurat dalam mendeteksi dan mengklasifikasikan objek. Box loss dan DFL loss yang terus berkurang

menunjukkan bahwa model semakin presisi dalam menentukan posisi objek, sementara classification loss validasi yang rendah menunjukkan model mampu membedakan kelas dengan sangat baik.

Pada metrik evaluasi, precision dan recall terus meningkat, mengindikasikan bahwa model semakin baik dalam mengenali objek tanpa banyak kesalahan. Kenaikan yang stabil pada mAP50 menunjukkan model dapat mendeteksi objek dengan akurasi tinggi, sementara mAP50-95 yang terus meningkat menunjukkan bahwa model bekerja dengan baik dalam berbagai tingkat presisi.

Secara keseluruhan, hasil ini menunjukkan bahwa model telah mencapai kinerja yang optimal dalam mendeteksi objek. Untuk lebih menyempurnakan performa, optimasi lebih lanjut seperti *fine-tuning IoU threshold* atau penyesuaian *anchor box* dapat diterapkan (Terven et al., 2023). Dengan hasil yang menjanjikan tersebut, model dapat diterapkan dalam berbagai aplikasi deteksi objek yang membutuhkan akurasi tinggi.

Tabel 6. Hasil Prediksi Lapisan Grafena

Gambar Asli	Anotasi	Prediksi
		
		

Hasil prediksi lapisan grafene pada data test (*test set*) disajikan pada Tabel 6, dimana sebagian besar hasil prediksi lapisan grafena telah sesuai dengan data anotasi yang telah dibuat. Sementara itu, hasil evaluasi model pada data validasi diukur menggunakan 4 metrics yaitu precision, recall, mAP50, dan mAP50-95 seperti yang disajikan pada Tabel 7.

Tabel 7. Hasil Evaluasi Model

Class	Precision	Recall	mAP50	mAP50-95
All	0.68	0.623	0.69	0.45

1-Layer	0.783	0.721	0.802	0.53
2-Layer	0.714	0.648	0.733	0.484
3-Layer	0.623	0.61	0.669	0.444
4-Layer	0.599	0.513	0.557	0.342

Hasil evaluasi model YOLOv11m pada 252 gambar validasi menunjukkan kinerja yang sangat baik dalam mendeteksi objek dengan berbagai lapisan (Layer). Secara keseluruhan, model mencapai Precision sebesar 0.68, Recall 0.623, serta mAP50 0.69, dan mAP50-95 0.45, yang mencerminkan performa yang solid dalam berbagai tingkat presisi.

Pada level kelas, kategori 1-Layer memiliki performa terbaik dengan Precision 0.783, Recall 0.721, mAP50 0.802, dan mAP50-95 0.53, menandakan deteksi yang sangat akurat. Kategori 2-Layer juga menunjukkan hasil yang baik dengan Precision 0.714 dan Recall 0.648, menghasilkan mAP50 0.733. Meskipun kategori 3-Layer dan 4-Layer memiliki nilai yang sedikit lebih rendah, keduanya tetap menunjukkan hasil yang kompetitif, dengan mAP50 masing-masing 0.669 dan 0.557, serta mAP50-95 0.444 dan 0.342.

Dari segi kecepatan, model memiliki waktu 40.4ms per gambar untuk inference, menunjukkan efisiensi dalam mendeteksi objek. Dengan performa yang menjanjikan ini, model sudah cukup baik untuk diterapkan dalam deteksi berbasis layer. Namun, untuk lebih meningkatkan akurasi pada kelas dengan performa lebih rendah, strategi seperti *hard example mining* (Shrivastava et al., 2016) atau peningkatan data augmentasi (Shorten dan Khoshgoftaar, 2019) dapat diterapkan untuk memperkuat akurasi model.

KESIMPULAN DAN SARAN

Berdasarkan hasil evaluasi model YOLOv11m yang telah dilakukan, model menunjukkan performa yang baik dalam mendeteksi objek grafena dengan berbagai lapisan (Layer), terutama pada kategori 1-Layer dan 2-Layer, yang memiliki nilai mAP50 masing-masing sebesar 0.802 dan 0.733. Meskipun kategori 3-Layer dan 4-Layer memiliki performa yang sedikit lebih rendah, hasil yang diperoleh tetap kompetitif dan menunjukkan potensi model untuk diterapkan dalam tugas segmentasi nanopartikel. Selain itu, kecepatan inference yang efisien (40.4ms per gambar) menunjukkan bahwa model ini dapat digunakan dalam aplikasi *real-time*. Untuk meningkatkan akurasi lebih lanjut, dapat dipertimbangkan penggunaan teknik augmentasi data serta strategi pelatihan seperti *hard example mining* atau *fine-tuning* pada dataset yang lebih beragam.

Secara keseluruhan, penelitian ini berhasil membangun dan mengevaluasi model deteksi yang dapat digunakan untuk segmentasi nanopartikel secara otomatis, memberikan kontribusi terhadap efisiensi analisis dalam bidang rekayasa material dan industri berbasis AI.

DAFTAR RUJUKAN

- Buda, M., Maki, A., dan Mazurowski, M. A. 2018. "A systematic study of the class imbalance problem in convolutional neural networks". *Neural Networks*, 106, 249-259. <https://doi.org/10.1016/j.neunet.2018.07.011>
- Chen, F.X.R., Lin, C.Y., dan Siao, H.Y. 2023. "Deep learning based atomic defect detection framework for two-dimensional materials". *Sci Data*, 10 (91). <https://doi.org/10.1038/s41597-023-02004-6>
- Çınar, A., Erkuş, M., Tuncer, T., Ayyıldız, H., dan Tuncer, S.A. 2023. "YOLOv5 based detector for eight different urine particles components on single board computer". *International Journal of Imaging Systems and Technology*, 34(1). <https://doi.org/10.1002/ima.22968>
- Geim, A. dan Novoselov, K. S. 2007. "The rise of graphene". *Nature Materials*, 6(3), 183–191. <https://doi.org/10.1038/nmat1849>
- Guo, Z., Wang, C., Yang, G., Huang, Z., dan Li, G. 2022. "MSFT-YOLO: Improved YOLOv5 Based on Transformer for Detecting Defects of Steel Surface". *Sensors*, 22(9), 3467. <https://doi.org/10.3390/s22093467>
- Khalili, B. dan Smyth, A.W. 2024. "SOD-YOLOv8—Enhancing YOLOv8 for Small Object Detection in Aerial Imagery and Traffic Scenes". *Sensors*, 24(19), 6209. <https://doi.org/10.3390/s24196209>
- Khan, A.T., dan Jensen, S.M. 2025. "LEAF-Net: A Unified Framework for Leaf Extraction and Analysis in Multi-Crop Phenotyping Using YOLOv11". *Agriculture* 15(2), 196. <https://doi.org/10.3390/agriculture15020196>
- Mahjoubi, S., Ye, F., Bao, Y., Meng, W., dan Zhang, X. 2023. "Identification and classification of exfoliated graphene flakes from microscopy images using a hierarchical deep convolutional neural network". *Engineering Applications of Artificial Intelligence* 119: 105743. <https://doi.org/10.1016/j.engappai.2022.105743>
- Shearer, C.J., Slattery, A.D., Stapleton, A.J., Shapter, J.G., dan Gibson, C.T. 2016. "Accurate thickness measurement of graphene". *Nanotechnology*, 27, 125704. <https://doi.org/10.1088/0957-4484/27/12/125704>
- Shorten, C., dan Khoshgoftaar, T. M. 2019. "A survey on image data augmentation for deep learning". *Journal of Big Data*, 6(10). <https://doi.org/10.1186/s40537-019-0197-0>
- Shrivastava, A., Gupta, A., dan Girshick, R. 2016. "Training region-based object detectors with online hard example mining". *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 761-769. <https://doi.org/10.48550/arXiv.1604.03540>
- Terven, J., Córdova, D.M., dan González, J.A.R. 2023. "A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS". *Mach. Learn. Knowl. Extr.* 5(4), 1680-1716. <https://doi.org/10.3390/make5040083>

-
- Tian, Y., Zhang, Y., dan Zhang, H. 2023. "Recent Advances in Stochastic Gradient Descent in Deep Learning". *Mathematics*, 11(3), 682. <https://doi.org/10.3390/math11030682>
- Uslu, J.L., Ouaj, T., Tebbe, D., Nekrasov, A., Bertram, J.H., Schütte, M., Watanabe, K., Taniguchi, T., Beschoten, B., dan Waldecke, L. 2024. "An open-source robust machine learning platform for real-time detection and classification of 2D material flakes". *Mach. Learn.: Sci. Technol.* 5,015027. <https://doi.org/10.1088/2632-2153/ad2287>
- Zenebe, Y. A., Xiaoyu, L., Chao, W., Yi, W., Endris, H. A., dan Fanose, M.N. 2022. "Towards Automatic 2D Materials Detection Using YOLOv7". *19th International Computer Conference on Wavelet Active Media Technology and Information Processing (ICCWAMTIP)*, pp. 1-5. <https://doi.org/10.1109/ICCWAMTIP56608.2022.10016569>