

Pengembangan Sistem Prediksi Konduktivitas Listrik Semikonduktor Melalui Integrasi *Machine Learning* dan Teori Fisika Zat Padat untuk Desain Material Elektronik

Development of Semiconductor Electrical Conductivity Prediction System through Integration of Machine Learning and Solid State Physics Theory for Electronic Material Design

Received 25 May 2025

Accepted 20 June 2025

Published June 2025

Yanuar Abimanyu*, Rike Aji Santoso, Revaldy Bisma Saylendra, Sri Astutik, Habibah Khusna Baihaqi

Pendidikan Fisika, Fakultas Keguruan dan Ilmu Pendidikan, Universitas Jember

Abstrak. Pembelajaran mesin (*machine learning*) telah dengan cepat muncul sebagai sebuah sistem yang efektif dalam berbagai bidang, termasuk ilmu material, karena kemampuannya dalam mengungkap pola kompleks dari data besar secara efisien. Penelitian ini bertujuan untuk mengembangkan sistem prediksi konduktivitas listrik semikonduktor berbasis *machine learning* yang terintegrasi dengan teori fisika zat padat. Dalam konteks perkembangan teknologi material elektronik, kemampuan untuk memprediksi sifat listrik material sebelum proses sintesis sangat penting untuk meningkatkan efisiensi dan akurasi dalam desain material. Penelitian ini menggunakan metode deskriptif kualitatif untuk membuat sebuah sistem berbasis *machine learning* dan menggambarkan hasil penelitian secara kualitatif. Data set diperoleh dari berbagai literatur dan eksperimen terdahulu, dengan parameter fisika seperti struktur kristal, band gap, dan densitas. Model *machine learning* yang digunakan adalah algoritma *random forest*. Hasil evaluasi menunjukkan bahwa sistem mampu mengklasifikasikan material berdasarkan sifat konduktivitas listriknya dengan akurasi tinggi. Material seperti GaAs, Ge, dan Si diidentifikasi sebagai potensial untuk desain perangkat elektronik. Integrasi teori fisika zat padat dalam sistem ini meningkatkan validitas prediksi secara fisik dan statistik. Penelitian ini menunjukkan bahwa pendekatan *machine learning* berbasis prinsip fisis dapat menjadi solusi efektif dalam rekayasa material semikonduktor masa depan.

Abstract. Machine learning has rapidly emerged as an effective system in various fields, including materials science, due to its ability to efficiently uncover complex patterns from big data. This research aims to develop a machine learning-based semiconductor electrical conductivity prediction system integrated with solid state physics theory. In the context of electronic material technology development, the ability to predict the electrical properties of materials before the synthesis process is crucial for improving efficiency and accuracy in material design. This study employs a qualitative descriptive method to create a machine learning-based system and qualitatively describe the research results. The dataset is obtained from various literature and previous experiments, with physical parameters such as crystal structure, band gap, and density. The machine learning model used is the random forest algorithm. Evaluation results show that the system can classify materials based on their electrical conductivity properties with high accuracy. Materials such as GaAs, Ge, and Si are identified as potential candidates for electronic device design. The integration of solid-state physics theory into this system enhances the physical and statistical validity of predictions. This research demonstrates that a machine learning approach based on physical principles can be an effective solution for future semiconductor material engineering.

Keywords: Semiconductors, Electrical Conductivity, Machine Learning, Physics of Solids.

Pendahuluan

Semikonduktor merupakan sebuah bahan yang memiliki dua sifat sekaligus, yaitu isolator dan juga konduktor. Pada suhu yang tinggi bahan semikonduktor akan bersifat seperti bahan konduktor, namun pada suhu yang rendah bahan ini akan bersifat seperti bahan isolator. Bahan semikonduktor banyak dimanfaatkan sebagai material pembuatan komponen elektronik. Disisi lain perkembangan teknologi elektronik dan komputasi mendorong perkembangan material semikonduktor dengan performa yang lebih optimal dan sesuai kebutuhan (Sasya, 2024).

Perkembangan teknologi di bidang komputasi *material science*, mampu meningkatkan efektivitas pembuatan atau rekayasa bahan semikonduktor. Namun pada kenyataannya di Indonesia pemilihan dan rekayasa material semikonduktor masih jarang dilakukan dan bergantung pada eksperimen konvensional (Komaril Sofi and Sudarman, 2022). Berkaitan dengan hal tersebut diperlukan sebuah sistem atau pendekatan baru untuk memprediksi potensi dari bahan semikonduktor sebelum dilakukan sebuah sintesis bahan lebih lanjut.

Fisika zat padat merupakan sebuah teori yang diperlukan untuk pondasi teoritis sebelum memahami sifat dari bahan semikonduktor terutama pada konduktivitas listriknya (April *et al.*, 2024). Sifat semikonduktor dapat ditentukan dari beberapa parameter diantaranya adalah struktur kristal bahan, celah pita (*band gap*), serta mobilitas elektron dan hole sangat berperan dalam penentuan sifat bahan terutama pada sifat listrik material (Yoo *et al.*, 2021). Salah satu

faktor yang dapat meningkatkan sifat konduktivitas listrik semikonduktor adalah proses doping pada bahan. Doping merupakan suatu proses menambahkan unsur tertentu kedalam struktur kristal. Proses ini akan menciptakan sebuah tingkat energi baru yang mempercepat mobilitas muatan listrik dalam bahan (Saleem *et al.*, 2022).

Penerapan *machine learning* dalam bidang *material science* bukan hal yang baru dilakukan oleh peneliti. Melalui *machine learning* pengembangan material semakin berkembang pesat terutama dalam prediksi sifat elektronik material, sebelum di kembangkan atau di sintesis lebih lanjut (Choubisa *et al.*, 2023). *Machine learning* adalah salah satu cabang dari kecerdasan rancangan manusia yang memungkinkan komputer agar belajar dari data dan pengalaman, serta mampu untuk melaksanakan tugas-tugas yang bersifat kompleks tanpa pemrograman secara eksplisit. Salah satu peran teknologi *machine learning* adalah untuk menganalisis sifat material. Model seperti *Neural Network* dan *Random Forest* dapat digunakan sebagai penghubung antara struktur atomik lokal yang bersifat makroskopik seperti konduktivitas listrik. konsep *machine learning* menggunakan data hasil perhitungan teori atau eksperimen sebagai melatih model prediksi (Poul *et al.*, 2023). Model *random forest* memiliki keunggulan sebagai sistem prediksi, dikarenakan model *Random Forest* lebih cepat dalam melatih data serta dapat memberikan interpretasi fitur yang lebih jelas. Melalui pelatihan model *machine learning* pola kompleks seperti prediksi potensi bahan semikonduktor dapat dikenali dengan baik dan teliti. Pendekatan ini meningkatkan efisiensi dan akurasi dalam desain material semikonduktor.

Proses pengembangan material semikonduktor, diperlukan sebuah sistem yang mampu memprediksi konduktivitas listrik secara akurat sebelum proses sintesis dilakukan (Vaithianathan *et al.*, 2024). Pendekatan berbasis *machine learning* menjadi salah satu solusi yang berpotensi untuk dilakukan, namun dalam proses pendekatan ini diperlukan data dengan kualitas baik agar model yang diuji dapat berjalan dengan maksimal ketika melakukan sebuah analisa material dengan parameter fisika zat padat. Tantangannya adalah bagaimana membangun sistem prediksi bukan sekedar akurat namun juga mampu memvisualisasikan hasil prediksi berdasarkan konsep fisika zat padat (Guo *et al.*, 2021). Oleh karena itu, peneliti melakukan sebuah pengembangan sebuah sistem yang mengintegrasikan dengan teori fisika zat padat agar model yang dibangun dapat berjalan dengan maksimal.

Metodologi

Penelitian ini menggunakan metode deskriptif dengan pendekatan kualitatif dengan tujuan utama membuat sistem prediksi berbasis *artificial intelligence* dalam perancangan desain material elektronik serta menganalisis secara kualitatif material yang berpotensi dijadikan perangkat elektronik. Tahapan awal dimulai dari studi pendahuluan untuk menganalisis material yang berpotensi diaplikasikan sebagai perangkat semikonduktor. Tahapan selanjutnya berlanjut pada tahap perencanaan dan pengembangan model prediktif menggunakan algoritma *Random Forest*, model ini akan diaplikasikan untuk menangani data set kecil dan tidak memerlukan asumsi distribusi data. Data yang digunakan dalam eksperimen simulasi terdiri dari 7 jenis material dengan melatih 6 data material input, dan menguji 1 data secara bergantian hingga kombinasi selesai. Keterbatasan jumlah data membuat peneliti melakukan pembagian data dengan metode *leave-one-out cross validation* untuk menghindari *overfitting* (sebuah kondisi dimana model sangat akurat terhadap data yang dilatih namun lemah dalam memprediksi data uji / baru).

Tahapan *preprocessing* akan dilakukan proses normalisasi data numerik untuk membuat data mentah menjadi data yang siap pakai untuk uji coba. Proses pemodelan dilakukan dengan platform *Google colab*, hasil penelitian dengan platform tersebut akan menghasilkan sebuah sistem sederhana yang mampu mengevaluasi material sebagai perangkat semikonduktor yang efisien.

Lokasi dan Waktu Penelitian

Penelitian ini dilaksanakan di laboratorium Kimia dan Fisika Lanjut Program Studi Pendidikan Fisika, Fakultas Keguruan dan Ilmu Pendidikan Universitas Jember. Kegiatan penelitian berlangsung selama tiga bulan. Proses pengumpulan dan analisis data memanfaatkan *software Google Colab* yang dioperasikan melalui laptop secara online, serta didukung dengan literatur yang relevan dari penelitian sebelumnya.

Variabel Penelitian

Variabel penelitian sebagaimana ditunjukkan pada Tabel 1 berikut

Tabel 1 Variabel Penelitian

Variabel	Jenis	Indikator
Parameter Fisis Material	Bebas (X)	1. Nama Material
		2. Struktur Kristal
		3. Band Gap (e)
		4. Densitas (kg/m ³)
		5. Konduktivitas

Sifat listrik Material	Terikat (Y)	1. Isolator 2. Konduktor 3. Semikonduktor
---------------------------	----------------	---

Teknik Pengambilan Data

Pengambilan data menggunakan teknik pengumpulan data dokumen dari berbagai literatur artikel, buku, dan data percobaan sebagai data sekunder. Data sekunder ini digunakan sebagai *datasheet* yang akan digunakan untuk mengembangkan model *machine learning* sebagai sistem prediksi. Data yang digunakan dalam eksperimen simulasi terdiri dari 7 jenis material dengan melatih 6 data material input, dan menguji 1 data secara bergantian hingga kombinasi selesai. Dalam pengambilan data akan dilakukan studi literatur yang berfokus untuk mencari persamaan matematis yang menyatakan hubungan antara bandgap dengan konduktivitas serta peran suhu terhadap *band gap*.

$$\sigma \propto e^{-E_g/(2kT)} \quad (1)$$

Dimana σ adalah nilai konduktivitas listrik suatu bahan, E_g nilai energi gap (*band gap*) dalam satuan eV, k adalah konstanta Boltzmann yang memiliki nilai $8,617 \times 10^{-5}$ eV/K, dan T adalah suhu mutlak bahan tersebut dalam satuan Kelvin (K).

Teknik Analisis Data


Teknik analisa data ditujukan untuk mengolah data yang diperoleh dari berbagai eksperimen literatur sebelumnya, dalam rangka mengembangkan model *machine learning* yang relevan dengan tujuan penelitian. Proses analisa ini mencakup tahapan dari pengumpulan data hingga evaluasi model. Rincian teknik analisa data ditunjukkan dalam Tabel 2 berikut.

Tabel 2 Teknik Analisis Data

Tahap	Fase Analisis	Metode Analisis	Tujuan
Invetarisasi Data Sekunder	Studi Literatur yang Relevan	Mengumpulkan data karakteristik fisik material dari konduktivitas, sampai band gap dari jurnal	Memahami karakteristik fisik dari material
Preprocessing Data	Proses Normalisasi dan standarisasi Data	Menghapus duplikat data dan mengubah satuan konduktivitas bahan agar seragam, mengkategorikan material berdasarkan bandgap menjadi : konduktor, semikonduktor, dan isolator	Mengonversi data mentah ke format yang konsisten agar siap digunakan dalam proses analisis
Eksplorasi Data	Pengujian Statistik Deskriptif	Menyaring material semikonduktor yang efisien berdasarkan nilai konduktivitas tertinggi, membuat visualisasi scatter plot hubungan antara band gap dan konduktivitas.	Menggambarkan distribusi dan hubungan antar variabel data
Pemodelan machine learning	Penerapan Algoritma random forest	Menentukan fitur input : band gap, densitas, dan struktur kristal. Lalu menentukan target output, setelah itu membagi data training dan testing, lalu langkah terakhir yaitu melatih model random forest.	Menentukan klasifikasi atau prediksi dari berbagai material yang diuji
Evaluasi model	Validasi dan pengukuran kinerja model Prediktif	Melakukan proses prediksi pada data uji, menampilkan confusion matrix untuk mengevaluasi hasil klasifikasi model	Menilai keakuratan model dalam proses analisa

Alur Penelitian

Alur penelitian yang dilakukan ditunjukkan oleh Gambar 1 kerangka berpikir



Gambar 1 Kerangka Berpikir


Langkah awal kerangka berpikir penelitian dimulai dengan tahapan identifikasi permasalahan terkait perancangan material elektronik melalui studi literatur guna memperoleh informasi terhadap permasalahan yang diangkat. Proses ini diikuti dengan perumusan masalah dan penetapan tujuan penelitian sebagai landasan agar penelitian lebih sistematis. Selanjutnya, kajian pustaka dilakukan untuk menghimpun data dari beberapa referensi hasil eksperimen sebelumnya. Kemudian data tersebut digunakan sebagai *datasheet* yang memuat parameter fisis dari berbagai material yang telah diidentifikasi sebelumnya. Data yang telah terkumpul akan dianalisis untuk memahami pola dan potensi dari material. Dari analisis tersebut akan dikembangkan sebuah sistem yang akan dievaluasi secara bertahap sesuai dengan kebutuhan di lapangan.

Hasil Penelitian

Flowchart yang telah dibuat menggambarkan alur pengolahan data hingga menghasilkan sebuah sistem yang dapat memprediksi potensi dari suatu material untuk dijadikan dalam desain material elektronik berbasis kecerdasan buatan. Proses diawali dengan inisialisasi data, dimana *datasheet* yang diperoleh akan dipisahkan antara fitur dan label (normalisasi data) dan didefinisikan agar memudahkan dalam eksplorasi data. Tahap selanjutnya adalah proses klasifikasi material berdasarkan *band gap* untuk mengetahui karakter dari setiap material yang akan di uji coba. Dalam proses uji coba akan diambil beberapa jenis material diantaranya adalah tembaga (Cu), silikon (Si), besi (Fe), aluminium (Al), germanium (Ge), galium arsenida (GaAs), dan seng oksida (ZnO). Kemudian setelah karakteristik diketahui maka pisahkan antara data untuk pengujian dan pelatihan untuk memastikan model berjalan dengan maksimal.

Model *random forest* dilatih menggunakan data yang telah diklasifikasikan menjadi data latih untuk memprediksi data yang akan digunakan dalam pengujian. Setelah prediksi dilakukan maka tahapan selanjutnya adalah mengukur performa model melalui *confusion matrix*. Tahapan yang terakhir adalah memvisualisasikan hasil prediksi dan membandingkan dengan penelitian sebelumnya, dengan tujuan memastikan pengembangan sistem yang telah dikembangkan. Alur pengembangan sistem berbasis *machine learning* dapat dilihat pada Gambar 2.

Hasil pengembangan sistem berbasis *machine learning* menghasilkan output yang penting. Tahapan pengembangan sistem diawali dengan pengumpulan data dan menyusun dataset yang memuat parameter fisis material. Kemudian data dipisahkan antara fitur dan juga label, diikuti dengan proses *preprocessing* berupa normalisasi data numerik agar data siap digunakan dalam pemodelan. Proses klasifikasi awal dilakukan untuk mengetahui karakteristik material berdasarkan nilai *band gap*. Setelah itu data dibagi dengan metode *leave-one-out cross validation*. Kemudian model *Random Forest* dilatih untuk memprediksi kategori material berdasarkan parameter yang telah ditentukan. Tahapan evaluasi dilakukan dengan menggunakan *confusion matrix*, yang menunjukkan akurasi dalam model untuk melakukan proses klasifikasi. Hasil dari pengembangan sistem salah satunya adalah mampu menghasilkan data material yang dianggap efektif untuk perangkat elektronik berdasarkan parameter yang telah ditentukan sebelumnya. Hasil klasifikasi material yang efektif sebagai perangkat elektronik dapat dilihat pada Gambar 3.



Gambar 2 Flowchart Pengembangan Sistem machine learning

Material yang efisien untuk perangkat elektronik:

	Material	Band_Gap	Densitas	Konduktivitas	Kategori
4	Ge	0.67	5.32	2.220000	Semikonduktor
1	Si	1.10	2.33	0.000003	Semikonduktor
5	GaAs	1.42	5.32	0.000000	Semikonduktor

Gambar 3 Hasil Klasifikasi Material untuk perangkat elektronik


Berdasarkan hasil klasifikasi ada beberapa material yang berpotensi dijadikan sebuah desain material untuk perangkat elektronik, diantaranya adalah silikon (Si), germanium (Ge), silikon dan galium arsenida (GaAs). Parameter yang digunakan dalam klasifikasi adalah *band gap*, densitas, dan konduktivitas. Berdasarkan persamaan dari literatur menyebutkan bahwa energi gap sangat dipengaruhi oleh suhu dan energi gap juga mempengaruhi nilai konduktivitas yang dapat dijelaskan dengan persamaan matematis berikut:

$$\sigma \propto e^{-E_g/(2kT)} \quad (2)$$

Dimana σ adalah nilai konduktivitas listrik suatu bahan, E_g nilai energi gap (*band gap*) dalam satuan eV, k adalah konstanta Boltzmann yang memiliki nilai $8,617 \times 10^{-5}$ eV/K, dan T adalah suhu mutlak bahan tersebut dalam satuan Kelvin (K). Berdasarkan persamaan tersebut diketahui bahwa jika nilai band gap semakin besar maka, konduktivitas listrik akan semakin melemah. Hal ini dikarenakan energi yang digunakan untuk memindahkan elektron dari pita valensi ke pita konduksi menjadi lebih besar.

Dalam aplikasinya material yang sesuai untuk mengembangkan transistor atau dioda adalah dengan *band gap* 1-2eV untuk menyeimbangkan efisiensi konduksi dan stabilitas termal. Galium arsenida (murni) merupakan material yang paling efektif karena memiliki sifat elektronik yang unggul dalam mobilitas elektron. Hal ini didukung dengan penelitian Ram Chhavi Sharma dkk. Menyatakan bahwa GaAs merupakan material yang memiliki mobilitas elektron tinggi, yang sangat penting untuk perangkat elektronik semikonduktor. mobilitas elektron yang tinggi memungkinkan transportasi muatan yang efisien yang cocok untuk aplikasi di perangkat frekuensi tinggi dan optoelektronika (Sharma et al., 2023). Kemudian untuk evaluasi model dilakukan untuk melihat efektivitas dari sistem yang dikembangkan. Evaluasi model ditunjukkan oleh *confusion matrix* sebagaimana ditunjukkan pada Gambar 4.

Berdasarkan *confusion matrix*, menunjukkan bahwa model memiliki akurasi tinggi dalam proses klasifikasi material untuk keperluan desain material elektronik. Matriks tersebut mendeskripsikan prediksi terhadap nilai konduktivitas listrik pada suatu bahan, dikategori rendah maupun tinggi yang menjadi indikator penting dalam pemilihan material untuk perangkat elektronik. Model ini terbukti mampu memprediksi dengan tingkat akurasi yang baik. Perlu diketahui model yang dikembangkan masih memiliki keterbatasan pada pengujian dataset yang lebih bervariasi dan kompleks. Keterbatasan ini disebabkan oleh terbatasnya data sebagai bahan uji coba dalam pengembangan model.



Gambar 4 Evaluasi model

Hambatan utama dalam pengembangan semikonduktor di Indonesia adalah kurangnya infrastuktur dan teknologi yang memadai. Selain itu perkembangan sumberdaya manusia menjadi faktor yang mempengaruhi lambatnya perkembangan industri semikonduktor di Indonesia. Hal tersebut dikarenakan dalam pengembangan sumber daya manusia masih terbatas oleh akses pendidikan yang minim ke setiap golongan. Faktor Regulasi yang rumit dan insentif yang minim di Indonesia mengurangi minat investor tidak ingin melirik Indonesia sebagai tempat mengembangkan industri semikonduktor.

Upaya untuk mengatasi hal tersebut diperlukan kolaborasi antara pemerintah, industri, dan lembaga pendidikan. Pemerintah perlu memperkuat dan menyediakan teknologi pendukung agar generasi muda bisa terus berinovasi di bidang semikonduktor. Disisi lain peningkatan kualitas sumber daya manusia dapat dilakukan dengan menyediakan akses leih untuk pelatihan terkait teknologi semikonduktor. melalui dukungan regulasi yag sederhana dan insentif yang menarik, Indonesia berpotensi menjadi pusat pengembangan semikonduktor.

Penggunaan teknologi, hal ini sejalan dengan penelitian yang dilakukan oleh Tsymbalov dkk. Dalam penelitian *machine learning* untuk mengembangkan desain material listrik merupakan langkah strategis dalam optomalisasi material semikonduktor pada industri tersebut menyimpulkan bahwa dalam mengembangkan sebuah material semikonduktor diperlukan simulasi perhitungan dan prinsip struktur pita elektronik dasar, yang dapat dimaksimalkan melalui pendekatan yang menggabungkan algoritma pembelajaran mesin (*machine learning*) dengan fisika elektronik dan optik(Tsymbalov *et al.*, 2021). Proses pengumpulan *datasheet* yang memuat sifat fisis material merupakan tahapan penting dalam pengembangan sistem berbasis *machine learning*, hal ini dikarenakan performa model sangat bergantung dengan kualitas data yang digunakan dalam proses pelatihan model. Oleh karena itu, penyusunan *datasheet* menjadi syarat utama yang harus diperhatikan untuk menghasilkan model yang akurat.

Kesimpulan

Pengembangan sistem yang dilakukan berjalan dengan baik dan dapat memprediksi kemampuan bahan dalam menghantarkan listrik sebelum bahan tersebut dibuat di laboratorium. Sistem ini menggunakan teknologi *machine learning* yang digabungkan dengan teori dasar fisika zat padat. Berbantuan data sekunder bentuk kristal, celah energi (*band gap*), dan kepadatan bahan, sistem ini bisa menilai bahan dan unsur apa yang efisien untuk dijadikan perangkat elektronik. Hasil penelitian menunjukkan bahwa beberapa bahan seperti silikon, germanium, aluminium, dan terutama galium arsenida (GaAs) sangat cocok digunakan untuk membuat perangkat elektronik. Sistem yang dibuat mampu memberikan hasil prediksi yang akurat, walaupun masih ada kekurangan karena jumlah data yang digunakan masih terbatas. Secara keseluruhan, sistem ini sangat membantu dalam memilih bahan yang tepat untuk teknologi elektronik di masa depan, khususnya di Indonesia.

Referensi

- April, S. *et al.* (2024) 'Analisis literatur tentang fisika zat padat dalam pegembangan teknologi semikonduktor', *IDENTIK: Jurnal Ilmu Ekonomi, Pendidikan dan Teknik*, 01(September), pp. 83–89.
- Choubisa, H. *et al.* (2023) 'Interpretable discovery of semiconductors with machine learning', *npj Computational Materials*, 9(1). Available at: <https://doi.org/10.1038/s41524-023-01066-9>.
- Guo, H. *et al.* (2021) 'Accelerated Atomistic Modeling of Solid-State Battery Materials With Machine Learning', *Frontiers in Energy Research*, 9(June), pp. 1–25. Available at: <https://doi.org/10.3389/fenrg.2021.695902>.

- Komaril Sofi, Y. and Sudarman (2022) 'Peran Kaolin Clay dan Karbon Aktif dalam Produksi Gas Hidrogen dengan Metode Fotokatalisis', *Jurnal Rekayasa Material, Manufaktur dan Energi*, 5(1), pp. 46–55.
- Poul, M. *et al.* (2023) 'Systematic atomic structure datasets for machine learning potentials: Application to defects in magnesium', *Physical Review B*, 107(10). Available at: <https://doi.org/10.1103/PhysRevB.107.104103>.
- Saleem, S. *et al.* (2022) 'Modification in structural, optical, morphological, and electrical properties of zinc oxide (ZnO) nanoparticles (NPs) by metal (Ni, Co) dopants for electronic device applications', *Arabian Journal of Chemistry*, 15(1), p. 103518. Available at: <https://doi.org/10.1016/j.arabjc.2021.103518>.
- Sasya, N.M. (2024) 'Studi Komputasi Modifikasi 3-Pyropheophorbide α Menggunakan Atom Pusat', 47(2), pp. 66–73.
- Sharma, R.C. *et al.* (2023) 'Gallium Arsenide and Gallium Nitride Semiconductors for Power and Optoelectronics Devices Applications', *Journal of Physics: Conference Series*, 2426(1). Available at: <https://doi.org/10.1088/1742-6596/2426/1/012008>.
- Tsymbalov, E. *et al.* (2021) 'Machine learning for deep elastic strain engineering of semiconductor electronic band structure and effective mass', *npj Computational Materials*, 7(1), pp. 1–10. Available at: <https://doi.org/10.1038/s41524-021-00538-0>.
- Vaithianathan, M. *et al.* (2024) 'Integrating AI and Machine Learning with UVM in Semiconductor Design', (August). Available at: <https://doi.org/10.56472/25838628/IJACT-V2I3P104>.
- Yoo, H. *et al.* (2021) 'Recent advances in electrical doping of 2d semiconductor materials: Methods, analyses and applications', *Nanomaterials*, 11(4). Available at: <https://doi.org/10.3390/nano11040832>.