



YAYASAN PRIMA AGUS TEKNIK



Machine Learning (ML) untuk Material Semikonduktor



Dr. Ir. Agus Wibowo, M.Kom, M.Si, MM.



Dr. Ir. Agus Wibowo, M.Kom, M.Si, MM.

Machine Learning (ML) **untuk** **Material Semikonduktor**



YAYASAN PRIMA AGUS TEKNIK

PENERBIT :

YAYASAN PRIMA AGUS TEKNIK
Jl. Majapahit No. 605 Semarang
Telp. (024) 6723456. Fax. 024-6710144
Email : penerbit_ypat@stekom.ac.id

ISBN 978-634-7695-04-8 (PDF)



Machine Learning (ML) untuk Material Semikonduktor

Penulis :

Dr. Ir. Agus Wibowo, M.Kom, M.Si, MM.

ISBN : 978-634-7695-04-8 (PDF)

Editor :

Dr. Joseph Teguh Santoso, S.Kom., M.Kom.

Penyunting :

Dr. Mars Caroline Wibowo. S.T., M.Mm.Tech

Desain Sampul dan Tata Letak :

Irdha Yuniarto, S.Ds., M.Kom

Penebit :

Yayasan Prima Agus Teknik Bekerja sama dengan
Universitas Sains & Teknologi Komputer (Universitas STEKOM)

Anggota IKAPI No: 279 / ALB / JTE / 2023

Redaksi :

Jl. Majapahit no 605 Semarang

Telp. 08122925000

Fax. 024-6710144

Email : penerbit_ypat@stekom.ac.id

Distributor Tunggal :

Universitas STEKOM

Jl. Majapahit no 605 Semarang

Telp. 08122925000

Fax. 024-6710144

Email : info@stekom.ac.id

Hak cipta dilindungi undang-undang

Dilarang memperbanyak karya tulis ini dalam bentuk dan dengan cara
apapun tanpa ijin dari penulis

KATA PENGANTAR

Puji dan syukur penulis panjatkan ke hadirat Tuhan Yang Maha Esa atas limpahan rahmatnya, dan karunia-Nya yang melimpah sehingga buku berjudul “***Machine Learning (ML) untuk Material Semikonduktor***” dapat terselesaikan dengan baik. Dalam era revolusi industri 4.0 dan menuju 5.0, semikonduktor bukan lagi sekadar fondasi elektronika, melainkan pusat inovasi yang mendorong batas kemampuan manusia. Buku *Machine Learning untuk Bahan Semikonduktor* ini lahir dari kebutuhan mendesak untuk mengintegrasikan kecerdasan buatan (AI), khususnya machine learning (ML), guna mengatasi tantangan kompleks dalam desain, produksi, dan optimalisasi material semikonduktor canggih. Dari silikon klasik hingga graphene super fleksibel, SiC penakluk panas ekstrem, dan GaN pendobrak 5G, dunia semikonduktor menghadapi kendala seperti deteksi cacat presisi, efisiensi produksi, serta transisi ke komputasi kuantum dan energi terbarukan.

Indonesia, dengan posisi strategis di rantai pasok global semikonduktor melalui inisiatif Kementerian Diklat Sains Teknologi, memerlukan talenta lokal yang mahir AI-for-materials untuk mencapai kemandirian teknologi di tengah dominasi TSMC, Samsung Foundry, dan Intel yang semakin mengandalkan ML-accelerated EDA tools.

Buku ini tersusun dalam sepuluh bab yang mengikuti pipeline lengkap dari materials discovery hingga fab deployment dengan narasi yang mengalir dari konteks historis hingga aplikasi futuristik. Bab pertama menguraikan evolusi material semikonduktor secara kronologis dan teknis: dari silikon dominan ke germanium untuk infrared detection, material optoelektronik generasi ketiga (GaN, SiC), graphene transparan fleksibel, transition metal dichalcogenides (MoS₂, WS₂) untuk 2D electronics, serta batas akhir Moore's Law yang mendorong post-silicon paradigms termasuk quantum computing chips.

Bab kedua membangun fondasi pembelajaran mesin yang solid meliputi sejarah AI dari perceptron hingga transformer architectures, empat paradigma learning (supervised, unsupervised, reinforcement, self-supervised), aplikasi industri seperti defect classification pada SECOM dataset, algorithmic complexity analysis untuk high-dimensional fab data, sinergi ML-elektroteknologi, serta etika AI dalam critical infrastructure.

Bab ketiga menerapkan anomaly detection pipeline pada SECOM dataset industri untuk yield optimization, mencakup Isolation Forest, Local Outlier Factor, data preprocessing strategies untuk missing sensor readings, hybrid ensemble models (XGBoost + SVM), ROC-AUC evaluation, dan decision tree interpretability untuk root cause analysis.

Bab keempat membahas deep learning predictive modeling untuk production yield enhancement dengan LSTM sequences untuk time-series fab data, ResNet architectures untuk multivariate feature correlation, Bayesian hyperparameter tuning, MLOps deployment patterns, dan ROI quantification untuk fab managers.

Bab kelima mengimplementasikan CNN-based visual inspection untuk semiconductor wafer defects menggunakan transfer learning dari EfficientNet/ImageNet backbones,

SEM/TEM image augmentation pipelines, GradCAM explainability, dan edge deployment pada NVIDIA Jetson untuk real-time cleanroom monitoring. Bab keenam mengintegrasikan ML dalam end-to-end device engineering workflows, membahas generative adversarial networks untuk layout optimization, reinforcement learning untuk plasma etching process control, dan physics-informed neural networks untuk TCAD acceleration.

Bab ketujuh menyajikan ML-accelerated numerical analysis untuk cylindrical BioFET biosensors dengan COMSOL multiphysics calibration, biomarker sensitivity prediction, dan clinical validation metrics. Bab kedelapan menganalisis wide-bandgap semiconductors (SiC, GaN) untuk EV inverters dan PV MPPT systems dengan ML-based thermal modeling dan efficiency optimization. Bab kesembilan mengoptimasi Triple Metal Gate Vertical TFET menggunakan ML surrogate models untuk band-to-band tunneling currents dan subthreshold swing minimization. Bab kesepuluh membahas macaroni Ge/Si NWFET untuk analog/RF applications dengan ML-driven parameter extraction dari Silvaco TCAD, g_m linearity analysis, dan figure-of-merit optimization untuk 5G/6G mmWave transceivers.

Diharapkan buku ini menjadi sumber inspirasi bagi mahasiswa, peneliti, dan praktisi teknik elektro, material, serta informatika. Dengan ML sebagai senjata utama, kita tak hanya bertahan di persaingan global, tapi memimpin era chip generasi baru. Terima kasih kepada semua kontributor dan pembaca yang turut mewujudkan visi ini. Semoga buku ini menjadi katalisator kemandirian teknologi semikonduktor Indonesia melalui AI-accelerated materials discovery, mempercepat transisi dari silicon dependency menuju wide-bandgap dan 2D materials sovereignty, sekaligus membekali generasi muda engineer bersaing di frontier global computational materials science.

Semarang, April 2026
Penulis


Dr. Ir. Agus Wibowo, M.Kom, M.Si, MM.

DAFTAR ISI

KATA PENGANTAR.....	ii
DAFTAR ISI.....	iv
BAB 1 TREN & KENDALA SEMIKONDUKTOR CANGGIH	1
1.1 Pendahuluan.....	1
1.2 Silikon (Si)	2
1.3 Mengenal Germanium & Teknologi Inframerah	3
1.4 Material Masa Depan Untuk Optoelektronik	5
1.5 Masa Depan Elektronika.....	6
1.6 SiC Sang Penakluk Panas Dan Tegangan Tinggi	6
1.7 Galium Nitrida Pendobrak Batas Komunikasi 5G	7
1.8 Era Baru Semikonduktor Super Tipis	8
1.9 Graphene Material Super Transparan Dan Fleksibel	9
1.10 Fleksibilitas Tanpa Batas Dari Dunia Transisi Logam.....	10
1.11 Tantangan Besar Dalam Menjaga Keajaiban Dunia Komputer.....	11
1.12 Batas Akhir Kejayaan Silikon Dalam Dunia Elektronika	11
1.13 Era Komputasi Kuantum Dan Kebangkitan Chip Generasi Baru	12
1.14 Kesimpulan	12
BAB 2 PEMBELAJARAN MESIN PENDAHULUAN DAN FITUR.....	15
2.1 Pendahuluan.....	15
2.2 Sejarah Kecerdasan Buatan (AI)	17
2.3 Mengenal Empat Cara Berbeda Mesin Mempelajari Sesuatu	19
2.4 Mendeteksi Kerusakan Produk Menggunakan Algoritma Cerdas.....	23
2.5 Navigasi Cerdas Di Tengah Lautan Data Semikonduktor	32
2.6 Sinergi Cerdas Antara Algoritma Dan Teknologi Kelistrikan	34
2.7 Etika Dan Masa Depan Sosial Dunia Digital.....	35
BAB 3 DETEKSI CACAT SEMIKONDUKTOR BERBASIS DATASET SECOM	36
3.1 Pendahuluan.....	36
3.2 Menang Di Pasar Global Dengan Optimasi Produksi Yang Cerdas	36
3.3 Tantangan Menjaga Kemurnian Dan Kualitas Di Ruang Produksi	38
3.4 Dataset Secom Dan Perannya Dalam Inovasi Manufaktur	39
3.5 Teknik Kunci Dalam Menjaga Kelancaran Produksi	40
3.6 Empat Algoritma Andalan Dalam Dunia Machine Learning.....	40
3.7 Dua Teknik Utama Untuk Menemukan Data Yang Tidak Normal.....	42
3.8 Pendekatan Hibrida Untuk Masa Depan Produksi Chip	42
3.9 Tahap Krusial Pra-Pemrosesan Data Semikonduktor	43
3.10 Membaca Peta Keberhasilan Model Dalam Mendeteksi Kerusakan	46
3.11 Strategi Antara SvC, Logistik, Dan Pohon Keputusan	50

3.12	Kesimpulan	50
BAB 4	PEMODELAN PREDIKTIF UNTUK PENINGKATAN HASIL PRODUKSI	52
4.1	Pendahuluan.....	52
4.2	Mengenal Celah Metode Konvensional Dan Hadirnya Solusi Digital	53
4.3	Keunggulan Mutakhir Deep Learning Dalam Mencetak Chip Sempurna.....	54
4.4	Fondasi Penting Dalam Dunia Deep Learning	56
4.5	Perjalanan Data Dari Sensor Pabrik Hingga Siap Dipelajari Mesin.....	59
4.6	Siklus Hidup Pengembangan Model Deep Learning	61
4.7	Menghubungkan Kecerdasan Buatan Dengan Sistem Pabrik Modern.....	62
4.8	Parameter Kunci Untuk Mengevaluasi Performa Model.....	64
4.9	Penerapan Praktis AI Untuk Menjaga Kualitas Dan Efisiensi Pabrik.....	65
4.10	Menuju Era Kecerdasan Buatan Generasi Baru Di Lantai Fabrikasi	66
4.11	Kesimpulan	68
BAB 5	AI UNTUK DETEKSI CACAT SEMIKONDUKTOR	70
5.1	Pendahuluan.....	70
5.2	Tonggak Sejarah Dan Kemajuan Manufaktur Chip Global.....	71
5.3	Rintangan Utama Dalam Pengawasan Kualitas Semikonduktor.....	74
5.4	Keunggulan Arsitektur CNN Untuk Klasifikasi Gambar	75
5.5	Inspirasi Arsitektur Klasifikasi Untuk Deteksi Cacat.....	76
5.6	AI Presisi Untuk Pabrik Modern.....	77
5.7	Proses Pengumpulan Data Inspeksi Digital	77
5.8	Teknik Pembersihan Dan Penguatan Data Gambar.....	79
5.9	Barisan Model Legendaris Yang Mengubah Cara AI Belajar.....	80
5.10	Menyusun Strategi Agar Model AI Belajar Dengan Cerdas Dan Cepat	81
5.11	Parameter Evaluasi Kinerja Model Prediktif	82
5.12	Membuktikan Ketangguhan Kecerdasan Buatan Di Lantai Fabrikasi	84
5.13	Kesimpulan	85
BAB 6	PEMBELAJARAN MESIN UNTUK PERANGKAT SEMIKONDUKTOR	86
6.1	Pendahuluan.....	86
6.2	Sejarah Dan Lompatan Teknologi Perangkat Semikonduktor	88
6.3	Tren Inovasi Terbaru Di Ambang Era Digital Masa Depan	90
6.4	Implementasi AI Dan ML Pada Protokol Manufaktur Semikonduktor	91
6.5	Promosi Manufaktur Menggunakan AI Dan ML.....	98
6.6	Kesimpulan	99
BAB 7	ANALISIS NUMERIK BIOSENSING BIOFET SILINDRIS BERBASIS ML.....	100
7.1	Pendahuluan.....	100
7.2	Panduan Kalibrasi Dan Pemodelan Simulator BioFET	103
7.3	Deteksi Biomolekul Untuk Aplikasi Klinis	107
7.4	Kesimpulan	126
BAB 8	SEMIKONDUKTOR EV & ENERGI TERBARUKAN	127
8.1	Pendahuluan.....	127

8.2	Aspek Finansial Dan Keberlanjutan Sistem Panel Surya.....	132
8.3	Sistem Konversi Dan Optimasi Daya Fotovoltaik	133
8.4	Masa Depan Elektronika Daya Dalam Genggaman Teknologi SiC.....	135
8.5	Kesimpulan	139
BAB 9	ANALISIS ML PADA TFET VERTIKAL TIGA LAPIS	141
9.1	Pendahuluan.....	141
9.2	Geometri Perangkat Triple METAL GATE (TMG) V-TFET	141
9.3	AI Pada Struktur TFET	149
9.4	Mengenal Peran Ai Dalam Mempercepat Inovasi Transistor	150
9.5	Kesimpulan	150
BAB 10	ANALISIS ML PADA NWFET MACARONI GE/SI UNTUK ANALOG/RF	152
10.1	Pendahuluan.....	152
10.2	Arsitektur Dan Spesifikasi Sensor Nanowire	154
10.3	Bedah Performa Perangkat Makaroni Untuk Sinyal Analog	156
10.4	Kesimpulan	175
	DAFTAR PUSTAKA	176



BAB 1

TREN & KENDALA SEMIKONDUKTOR CANGGIH

1.1 PENDAHULUAN

Bahan semikonduktor telah memainkan peran penting dalam revolusi informasi. Karakteristik utama bahan semikonduktor adalah nilai resistivitasnya yang berada di antara logam dan isolator, dan dapat disesuaikan dengan berbagai pendekatan fabrikasi material. Resistivitas listrik yang dapat disesuaikan dari bahan-bahan ini telah memungkinkan pengembangan berbagai macam perangkat elektronik yang secara fundamental telah mengubah cara manusia berinteraksi satu sama lain atau berbagi, menyimpan, dan menciptakan pengetahuan dan data, serta mengubah dunia. Pengembangan bahan semikonduktor dimulai pada abad ke-19 dengan penemuan konduktivitas listrik oleh Alessandro Volta. Alessandro Volta merancang tumpukan Volta, yang dikenal sebagai baterai listrik pertama, yang mengarah pada pengembangan pembahasan tentang sifat-sifat listrik dari berbagai jenis material.

Setelah itu, pada tahun 1833, Michael Faraday mempelajari korelasi antara jumlah listrik yang melewati larutan dan jumlah perubahan kimia dalam larutan dan menyajikan hukum elektrolisis, sehingga menetapkan elektron sebagai pembawa muatan listrik dalam larutan listrik. Penemuan penting lainnya dilakukan pada tahun 1873 oleh Frederick Guthrie, yang menemukan fenomena emisi termionik, di mana batang logam panas memberikan gaya tarik atau tolak pada benda-benda ringan. Emisi termionik kemudian menjadi dasar tabung vakum yang digunakan untuk memodulasi sinyal untuk amplifikasi atau rektifikasi. Munculnya tabung vakum menyebabkan pengembangan perangkat elektronik dan industri elektronik. Namun, karena kelemahan bawaan tabung vakum, seperti ukurannya yang besar, strukturnya yang berat, dan output yang tidak andal, permintaan akan perangkat elektronik yang lebih efisien dan kompak terus mendorong pencarian.

Pada tahun 1904, John Ambrose Fleming menemukan dioda, perangkat elektronik dua terminal yang memungkinkan arus mengalir hanya dalam satu arah. Dioda dibuat dari tabung vakum dengan katoda yang dipanaskan dan anoda yang dingin. Pada tahun 1906, Lee De Forest menemukan trioda, perangkat elektronik tiga terminal yang dapat digunakan untuk memperkuat sinyal listrik. Trioda dibuat dari tabung vakum dengan katoda yang dipanaskan, anoda yang dingin, dan grid kontrol. Tabung vakum digunakan dalam berbagai aplikasi, termasuk radio, televisi, dan radar. Namun, tabung vakum masih besar, berat, dan tidak andal. Hal ini menyebabkan pencarian perangkat elektronik yang lebih efisien dan kompak.

Upaya dan pencarian berkelanjutan untuk menggantikan tabung vakum dengan perangkat elektronik yang lebih efisien, kompak, dan andal mendorong J. Bardeen, W. Brattain, dan W. Shockley pada tahun 1947 untuk mengembangkan transistor. Transistor adalah perangkat semikonduktor yang mampu memperkuat dan mengalihkan sinyal listrik yang dibuat dengan menyusun semikonduktor ekstrinsik dalam format PNP atau NPN. Karena sifatnya yang lebih baik, transistor menggantikan tabung vakum dalam berbagai aplikasi dan



memicu proliferasi berbagai perangkat elektronik.^{7,8} Hal ini selanjutnya mengarah pada penemuan chip terintegrasi (IC) oleh J. Kilby dan R. Noyce pada tahun 1950, yang merupakan perangkat elektronik kompak yang menampung ribuan transistor dan struktur elektronik lainnya.^{9–11} Dengan pengembangan IC, dimungkinkan untuk merancang dan membuat struktur elektronik yang sangat kompleks dengan biaya yang lebih rendah, yang mengarah pada pengembangan perangkat elektronik yang hemat daya, kompak, dan memiliki daya komputasi yang lebih besar, sehingga memunculkan revolusi elektronik modern. Perangkat elektronik tersebut digunakan dalam segala hal, mulai dari komputer hingga jam tangan, rudal, pesawat terbang, dan ponsel pintar.

1.2 SILIKON (Si)

Silikon (Si) adalah salah satu material paling melimpah di kerak bumi, membentuk hampir 27% darinya. Selain itu, ia memiliki sifat elektronik yang menguntungkan, yang dapat disesuaikan dengan berbagai pendekatan. Sifat semikonduktornya sangat berguna untuk industri elektronik; oleh karena itu, ia telah banyak digunakan untuk pembuatan komponen elektronik untuk industri elektronik. Sifat silikon telah membuka jalan baginya untuk digunakan dalam pembuatan banyak komponen elektronik untuk digunakan dalam berbagai aplikasi; oleh karena itu, silikon telah mendominasi industri semikonduktor selama bertahun-tahun. Di antara banyak komponen yang dibuat dalam skala besar dari silikon adalah transistor, dioda, IC, sensor, dan sel surya, untuk menyebutkan beberapa. Bagian ini menyoroti pentingnya silikon sebagai material pilihan untuk industri semikonduktor beserta beberapa keterbatasannya yang menonjol untuk aplikasi canggih.

Setelah oksigen, silikon adalah material paling melimpah yang ada di bumi. Umumnya diekstrak dari pasir silika. Kelimpahan dan ketersediaannya menjadikannya kandidat yang cocok untuk penggunaan skala besar. Kristal silikon berkualitas tinggi ditumbuhkan dari larutan yang diperoleh dari silikon dioksida, yang dibutuhkan untuk proses fabrikasi dalam industri semikonduktor. Dengan celah pita rendah sebesar 1,12 eV, silikon memungkinkan pengendalian pembawa muatan yang efektif pada suhu kamar, dan dengan doping yang sesuai, konsentrasi pembawa dapat dikendalikan dengan menambahkan kation aliovalen ke kisi Si. Kemampuan untuk mengendalikan konsentrasi pembawa secara efektif, dan karenanya konduktivitas Si, menjadikannya kandidat yang cocok untuk aplikasi seperti transistor, perangkat switching, dan amplifier. Ketika silikon terpapar oksigen, ia dengan mudah membentuk lapisan isolasi SiO_2 , yang sangat penting untuk fabrikasi transistor efek medan semikonduktor oksida logam (MOSFET). MOSFET telah menjadi pusat dari banyak komponen elektronik dalam sirkuit digital dan analog. Selain itu, SiO_2 , yang terbentuk saat silikon terpapar oksigen, memberikan isolasi listrik yang sangat dibutuhkan antara berbagai komponen bila diinginkan, meningkatkan keandalan komponen elektronik untuk penggunaan jangka panjang.

Sejak pengembangan pertamanya sejak lama, industri berbasis Si telah menciptakan kemampuan sintesis dan fabrikasi skala besar – khususnya, IC berbasis Si dan teknologi semikonduktor oksida logam komplementer, yang memungkinkan pembuatan jutaan transistor pada satu chip untuk komputasi berkinerja tinggi. Kemampuan infrastruktur yang



matang, tenaga kerja terampil, dan pertimbangan biaya adalah beberapa alasan mengapa Si menjadi material dominan selama bertahun-tahun di industri semikonduktor.

Keterbatasan Silikon Untuk Perangkat Semikonduktor Canggih

Meskipun silikon memiliki banyak sifat yang mengagumkan, ia memiliki keterbatasan yang signifikan, terutama di bidang perangkat frekuensi tinggi dan kecepatan tinggi. Mari kita lihat beberapa keterbatasan secara singkat di sini: (1) Dibandingkan dengan galium arsenida (GaAs), mobilitas pembawa muatan dalam silikon rendah. Untuk aplikasi yang membutuhkan operasi frekuensi tinggi, seperti perangkat frekuensi radio (RF) dan gelombang mikro, material dengan mobilitas pembawa muatan yang besar lebih efisien. Oleh karena itu, material seperti GaAs lebih disukai daripada Si untuk operasi kecepatan tinggi dengan konsumsi daya yang lebih rendah.

(2) Silikon bukanlah material pilihan di bidang elektronika daya karena konduktivitas termalnya yang lebih rendah dibandingkan dengan material lain, seperti silikon karbida (SiC) atau berlian. Dalam aplikasi daya tinggi, kemampuan untuk mengelola panas yang dihasilkan menjadi sangat penting untuk disipasi yang efisien. Material seperti SiC dan berlian termasuk di antara material pilihan dalam elektronika daya karena konduktivitas termal yang lebih baik dan tegangan tembus yang lebih tinggi. (3) Dengan kemajuan ilmu pengetahuan, khususnya di bidang nanoteknologi, Si menghadapi tantangan pada skala nano, yang berkaitan dengan penerowongan kuantum dan efek saluran pendek. Efek ini menyebabkan kebocoran daya dan penurunan kinerja untuk transistor ultra-kecil.¹⁴ Karena keterbatasan ini, komunitas ilmiah sedang mencari material 2D lain, seperti graphene, dikalkogenida logam transisi, dan senyawa semikonduktor III-V, untuk perangkat generasi berikutnya.

Prospek Dan Alternatif Masa Depan

Saat ini terdapat kelas material semikonduktor yang berbeda yang cocok untuk menggantikan silikon, seperti SiC dan galium nitrida (GaN). Meskipun Si tetap menjadi material pilihan di banyak bidang, terdapat pergeseran bertahap di bidang-bidang canggih, seperti aplikasi daya tinggi dan frekuensi tinggi. Karena infrastruktur yang ada, efektivitas biaya, dan jangkauan penerapannya yang luas, Si masih sangat disukai.

1.3 MENGENAL GERMANIUM & TEKNOLOGI INFRAMERAH

Material lain yang sebelumnya digunakan untuk pembuatan perangkat elektronik adalah germanium (Ge). Material ini pertama kali digunakan untuk pembuatan transistor pada awal tahun 1940-an dan 1950-an. Transistor yang terbuat dari Ge banyak digunakan sebelum digantikan oleh Si. Meskipun Ge telah digantikan oleh Si di sebagian besar bidang, Ge masih menjadi pilihan utama dalam aplikasi frekuensi tinggi dan optoelektronik karena mobilitas pembawa muatan yang lebih unggul dan celah pita langsungnya.

Dengan celah pita yang lebih rendah yaitu 0,66 eV, Ge dapat menghantarkan arus mendekati suhu ruangan dibandingkan dengan Si, yang hanya dapat menghantarkan arus pada suhu yang lebih tinggi karena celah pita yang lebih lebar. Hal ini menjadikannya kandidat yang lebih cocok untuk banyak perangkat elektronik seperti dioda dan transistor. Pada saat yang



sama, ini juga berarti bahwa perangkat elektronik yang terbuat dari Ge lebih sensitif terhadap variasi suhu, yang menyebabkan arus bocor yang lebih tinggi dibandingkan dengan Si.^{13,15}

Dibandingkan dengan silikon, mobilitas pembawa muatan germanium jauh lebih tinggi. Mobilitas elektron dan lubang pada germanium dan silikon masing-masing adalah $3.900 \text{ cm}^2/\text{V}\cdot\text{s}$ dan $1.900 \text{ cm}^2/\text{V}\cdot\text{s}$ serta $\sim 1.500 \text{ cm}^2/\text{V}\cdot\text{s}$ dan $\sim 450 \text{ cm}^2/\text{V}\cdot\text{s}$. Mobilitas pembawa muatan yang lebih tinggi menunjukkan kesesuaian germanium dalam aplikasi frekuensi tinggi, di mana peralihan cepat dan pemrosesan sinyal merupakan persyaratan utama. Meskipun mobilitas pembawa muatan jauh lebih tinggi (149 W/mK) untuk germanium, konduktivitas termalnya lebih rendah (60 W/mK). Dengan demikian, germanium menghadapi masalah dalam mengelola panas yang dihasilkan dalam elektronika daya dan aplikasi suhu tinggi.

Sebelum penggunaan germanium secara luas, tabung vakum digunakan untuk penguatan sinyal. Penggunaan Ge merevolusi proses tersebut dan menyebabkan pembuatan transistor persimpangan bipolar pertama pada tahun 1940-an. Perkembangan ini memungkinkan terciptanya penguat yang kompak dan hemat energi, menggantikan tabung vakum. Hingga tahun 1960-an, Ge mendominasi; digunakan untuk membuat berbagai macam perangkat elektronik mulai dari radio hingga komputer awal. Namun, sensitivitas Ge terhadap suhu yang lebih tinggi dan biayanya yang relatif lebih tinggi dibandingkan dengan Si akhirnya menyebabkan silikon menggantikannya. Kemampuan silikon untuk membentuk SiO_2 dengan oksigen menyebabkan pengembangan MOSFET, yang meletakkan dasar industri elektronik modern.

Aplikasi Dan Keterbatasan Saat Ini

Meskipun Ge digantikan oleh Si dalam banyak aplikasi, penggunaannya dalam banyak aplikasi masih menjadi arus utama, seperti yang dijelaskan di sini:

- **Transistor Kecepatan Tinggi:** Mobilitas pembawa muatan Ge yang lebih tinggi cocok untuk transistor frekuensi tinggi dan kecepatan tinggi, dengan mempertimbangkan frekuensi switching dan persyaratan konsumsi daya.
- **Optoelektronik:** Bandgap Ge yang lebih rendah cocok untuk deteksi dan pengukuran radiasi energi rendah, seperti inframerah (IR) dan sistem komunikasi serat optik.
- **Sel Surya:** Ge dapat meningkatkan efisiensi energi substrat pada sel surya multi-junction dan juga memiliki aplikasi di bidang antariksa.
- **Paduan dan senyawa:** Ge sangat sering dipadukan dengan Si; misalnya, paduan SiGe digunakan dalam aplikasi RF dan gelombang mikro.

Terlepas dari keunggulan-keunggulan ini, Ge memiliki keterbatasan, seperti biaya pemrosesan yang mahal, konduktivitas termal yang lebih rendah, dan ketidakmampuan untuk membentuk lapisan oksida seperti SiO_2 , yang semuanya membatasi aplikasinya dan membuatnya kurang serbaguna dalam aplikasi MOSFET.

Prospek Masa Depan

Dengan meningkatnya permintaan akan perangkat yang lebih ringkas, lebih cepat, dan lebih hemat energi, terdapat minat baru pada perangkat elektronik berbasis Ge untuk mengatasi keterbatasan penskalaan Si. Selain itu, ada upaya untuk menyelidiki penggunaan Ge dalam komputasi kuantum dan perangkat fotonik, di mana sifat listrik dan optiknya yang unik



dapat menawarkan keuntungan tambahan. Oleh karena itu, ada kemungkinan penggunaan Ge dengan cara baru dan khusus dalam perangkat elektronik.

1.4 MATERIAL MASA DEPAN UNTUK OPTOELEKTRONIK

GaAs adalah semikonduktor III-V dengan celah pita langsung. Material ini telah digunakan dalam aplikasi penting, seperti perangkat gelombang mikro dan gelombang milimeter, sel fotovoltaik, dan dioda pemancar cahaya (LED). Sebagai semikonduktor dengan celah pita langsung dan material kunci dalam industri elektronik untuk waktu yang lama, material ini menawarkan keunggulan unik dibandingkan material tradisional, seperti Si, khususnya dalam aplikasi frekuensi tinggi, kecepatan tinggi, dan optoelektronik.

Celah pita GaAs adalah 1,42 eV pada suhu kamar, sedangkan Si adalah material celah pita tidak langsung. Hal ini membuat GaAs lebih efisien energi untuk transisi elektron dari pita konduksi ke pita valensi dan sebaliknya, yang mengarah pada emisi foton yang efektif. Dengan demikian, GaAs banyak digunakan dalam aplikasi optoelektronik seperti dioda laser dan LED. Mobilitas pembawa muatan GaAs adalah $\sim 8.500 \text{ cm}^2/\text{V}\cdot\text{s}$, yang secara signifikan lebih tinggi dibandingkan dengan Si ($1.500 \text{ cm}^2/\text{V}\cdot\text{s}$).

Mobilitas pembawa yang lebih tinggi menghasilkan respons yang cepat terhadap medan eksternal yang diterapkan, membuat GaAs lebih cocok untuk aplikasi frekuensi tinggi dan kecepatan tinggi, seperti transistor gelombang mikro dan transistor efek medan (FET). Perangkat berbasis GaAs dapat digunakan secara efektif dalam rentang frekuensi GHz, yang cocok untuk sistem komunikasi RF dan gelombang mikro. Stabilitas yang lebih tinggi dari perangkat berbasis GaAs terhadap kerusakan radiasi juga menempatkan perangkat ini di depan perangkat berbasis Si untuk aplikasi ruang angkasa dan satelit, di mana kinerja yang terakhir dapat menurun secara signifikan. Perangkat berbasis GaAs menunjukkan stabilitas kinerja yang lebih tinggi untuk jangka waktu yang lebih lama dalam kondisi yang keras.

Aplikasi GaAs Dalam Perangkat Semikonduktor

Karena celah pita langsung yang rendah, mobilitas pembawa yang tinggi, dan kecepatan saturasi yang tinggi, perangkat berbasis GaAs telah banyak digunakan dalam aplikasi frekuensi tinggi dan optoelektronik. Perangkat berbasis GaAs – misalnya, transistor gelombang mikro dan gelombang milimeter seperti transistor bipolar heterojunction dan transistor mobilitas elektron tinggi – telah banyak digunakan untuk berbagai aplikasi, seperti telekomunikasi, radar, sistem komunikasi nirkabel, optoelektronik, sel surya, LED, dan dioda laser.

Sistem fotovoltaik seperti sel surya berbasis GaAs telah digunakan dalam aplikasi satelit dan luar angkasa karena efisiensinya yang tinggi, daya tahan, dan kinerja yang tinggi di bawah paparan radiasi ekstrem untuk jangka waktu yang lama. Selain itu, GaAs adalah material pilihan untuk fabrikasi Sirkuit Terpadu Gelombang Mikro Monolitik (MMIC), yang integral untuk sistem komunikasi berbasis radar, satelit, dan seluler. Selain itu, karena celah pita langsungnya, GaAs ideal untuk aplikasi optoelektronik seperti LED efisien dan perangkat laser.

Keterbatasan Galium Arsenida



Meskipun GaAs memiliki banyak keunggulan, kekurangannya telah membatasi aplikasinya di banyak bidang. GaAs mahal untuk disintesis dibandingkan dengan Si terutama karena kelangkaan Ga. Fabrikasi wafer GaAs kompleks, meningkatkan biaya keseluruhan dan membatasi penggunaannya pada aplikasi berkinerja tinggi yang khusus. Sifatnya yang rapuh secara mekanis membuatnya sulit ditangani selama proses fabrikasi, sehingga menyulitkan untuk meningkatkan skala produksi sistem berbasis GaAs. Konduktivitas termalnya yang lebih rendah membatasi aplikasinya di mana pembuangan panas sangat penting untuk kinerja perangkat. Karena masalah ini, SiC dan GaN lebih disukai dalam banyak aplikasi.

Prospek Masa Depan

Meskipun GaAs sangat penting untuk banyak aplikasi, material seperti SiC dan GaN juga digunakan untuk elektronika daya dan transistor berkinerja tinggi. GaAs terus menjadi sangat penting untuk aplikasi frekuensi tinggi dan optoelektronik di mana emisi cahaya yang efisien dan stabilitas terhadap radiasi matahari merupakan persyaratan penting.

1.5 MASA DEPAN ELEKTRONIKA

Dengan kemajuan ilmu pengetahuan dan teknologi, khususnya perangkat elektronik, permintaan akan perangkat yang ringkas dan hemat energi telah meningkat dalam beberapa tahun terakhir. Sifat-sifat material semikonduktor tradisional membatasi aplikasinya di banyak bidang, seperti elektronika daya, telekomunikasi, dan optoelektronik. Keterbatasan ini telah menyebabkan pengembangan material baru dengan sifat fisik dan kimia yang unggul untuk aplikasi tersebut. Di antara material lainnya, silikon karbida (SiC), galium nitrida (GaN), dan indium fosfida (InP) merupakan kandidat yang berguna dan menjanjikan untuk aplikasi teknik dan teknologi.

1.6 SiC SANG PENAKLUK PANAS DAN TEGANGAN TINGGI


Sifat Dan Keunggulan

Silikon karbida – semikonduktor pita lebar dengan celah pita 3,26 eV, tegangan tembus tinggi, konduktivitas termal tinggi, keras secara mekanis, dan stabilitas termal dan struktural pada suhu dan frekuensi tinggi – merupakan kandidat yang cocok untuk perangkat yang beroperasi pada frekuensi tinggi dan tegangan tinggi di bidang elektronika daya. Konduktivitas termalnya yang tinggi ($\sim 4,9 \text{ W/cm}\cdot\text{K}$) memastikan manajemen termal yang efisien dalam aplikasi suhu tinggi tanpa memerlukan dukungan pendinginan yang detail untuk perangkat, sehingga perangkat tersebut cukup kuat untuk berfungsi dalam kondisi yang keras.

Perangkat yang terbuat dari SiC, seperti MOSFET dan dioda Schottky, menunjukkan resistansi keadaan ON dan kerugian switching yang jauh lebih rendah dibandingkan dengan perangkat berbasis semikonduktor tradisional, yang menyebabkan peningkatan efisiensi yang drastis. Karakteristik ini sangat penting untuk banyak aplikasi yang sensitif terhadap energi, seperti kendaraan listrik (EV), sistem energi terbarukan, dan penggerak motor industri.

Tantangan Dan Perkembangan Saat Ini

Meskipun terdapat keuntungan signifikan dengan sifat-sifat SiC untuk aplikasi di bidang-bidang kritis, terdapat pula keterbatasannya: (1) Biaya dan kompleksitas perangkat



berbasis SiC jauh lebih tinggi daripada perangkat berbasis Si. (2) SiC adalah material yang sangat keras dan rapuh serta membutuhkan perawatan khusus untuk memoles dan memotong kristal menjadi serat untuk proses fabrikasi. Dengan demikian, pembuatan wafer merupakan proses yang mahal dan kompleks. Teknologi untuk fabrikasi wafer SiC belum sematang teknologi untuk perangkat berbasis Si.

Untuk mengatasi tantangan ini dan memanfaatkan sifat-sifat unik SiC, telah dilakukan upaya berkelanjutan untuk mengembangkan teknologi guna mengatasi keterbatasannya. Beberapa upaya difokuskan pada pengembangan deposisi uap fisik (PVD), deposisi uap kimia (CVD), dan proses pertumbuhan kristal tunggal untuk meningkatkan ketersediaan kristal dan wafer SiC. Peningkatan ini telah menyebabkan peningkatan penggunaan material untuk aplikasi komersial. Selain itu, upaya untuk pengembangan arsitektur elektronik baru dan proses fabrikasi menjadi fokus. Hal ini telah menghasilkan struktur MOSFET parit, yang dibuat untuk meminimalkan resistansi keadaan ON dan meningkatkan kinerja perangkat berbasis SiC.

Aplikasi

Aplikasi utama SiC adalah dalam elektronika daya, di mana ia digunakan dalam perangkat tegangan tinggi, suhu tinggi, dan efisiensi tinggi. MOSFET SiC dan dioda Schottky semakin banyak digunakan dalam konverter daya, inverter, dan penggerak motor karena kemampuannya untuk beroperasi pada frekuensi dan suhu switching yang lebih tinggi dibandingkan dengan perangkat berbasis silikon. Hal ini memungkinkan sistem daya yang lebih kompak, efisien, dan andal, terutama pada kendaraan listrik (EV), peralatan industri, dan instalasi energi terbarukan.

Dalam industri otomotif, SiC digunakan dalam sistem penggerak kendaraan listrik dan hibrida untuk meningkatkan efisiensi dan mengurangi ukuran serta berat sistem elektronik daya. Konduktivitas termal SiC yang tinggi memungkinkan pembuangan panas yang lebih efektif, mengurangi kebutuhan akan sistem pendingin yang besar dan memungkinkan desain yang lebih kompak.

SiC juga menemukan aplikasi di bidang kedirgantaraan dan pertahanan, di mana kemampuannya untuk menahan suhu dan radiasi ekstrem membuatnya cocok untuk digunakan di lingkungan yang keras. Perangkat SiC juga digunakan dalam sistem komunikasi satelit, radar, dan sensor suhu tinggi.

1.7 GALIUM NITRIDA PENDOBRAK BATAS KOMUNIKASI 5G

Sifat Dan Keuntungan

Dengan celah pita 3,4 eV, galium nitrida merupakan pilihan yang disukai untuk banyak aplikasi. Celah pita GaN bahkan lebih besar daripada SiC; ia memiliki mobilitas pembawa dan kecepatan saturasi yang tinggi, memungkinkan penggunaannya dalam aplikasi frekuensi tinggi, dan perangkat berbasis GaN bekerja pada kecepatan yang jauh lebih besar daripada perangkat berbasis Si. Karena sifat-sifat ini, GaN dapat digunakan untuk berbagai aplikasi yang melibatkan frekuensi tinggi dan daya tinggi, seperti RF, transistor daya, dan sistem komunikasi berkecepatan tinggi.



Galium nitrida memiliki tegangan tembus dan stabilitas termal yang tinggi. Ia stabil pada tegangan tinggi dan suhu tinggi. Karena konduktivitas termalnya yang tinggi, ia dapat beroperasi secara efisien pada suhu yang lebih tinggi tanpa memerlukan sistem pendingin. Selain itu, kristal GaN memiliki mobilitas pembawa muatan yang tinggi. Juga, karena parameter kisi yang kompatibel, GaN dapat ditumbuhkan pada silikon. Oleh karena itu, ia dapat memanfaatkan teknik fabrikasi dan manufaktur yang ada untuk silikon, memungkinkan integrasi teknologi yang disesuaikan untuk Si untuk digunakan pada GaN.

tantangan dan perkembangan saat ini

Terdapat banyak tantangan dalam pengembangan GaN sebagai material elektronik utama dibandingkan dengan Si, terutama karena kompleksitas proses manufaktur yang terlibat. Biaya proses manufaktur lebih besar dibandingkan dengan Si, sehingga membatasi penerapan GaN. Terdapat masalah keandalan dalam aplikasi daya tinggi, dan perangkat berbasis GaN rentan terhadap degradasi dalam kondisi tekanan tinggi.

Di antara perkembangan terkini dalam aplikasi berbasis GaN, telah ditunjukkan peningkatan kinerja di bidang kecepatan switching tinggi dengan kerugian rendah. Penekanannya adalah pada pengembangan perangkat elektronik kompak dengan desain dan teknik pengemasan yang lebih baik serta efisiensi yang lebih baik. Perkembangan terkini telah berfokus pada aplikasinya dalam mobilitas listrik, meningkatkan efisiensi daya stasiun pengisian daya, dan meningkatkan jangkauan kendaraan listrik.

Aplikasi

GaN banyak digunakan dalam aplikasi frekuensi tinggi dan daya tinggi, seperti penguat RF, transistor daya, dan perangkat gelombang mikro. Mobilitas elektron dan kecepatan saturasi yang tinggi menjadikannya ideal untuk digunakan dalam sistem komunikasi frekuensi tinggi, termasuk jaringan 5G dan komunikasi satelit.

Di sektor elektronika daya, perangkat GaN digunakan dalam konverter daya, inverter, dan penggerak motor, di mana efisiensi tinggi dan kecepatan peralihan yang cepat menghasilkan penghematan energi yang signifikan. GaN juga digunakan dalam catu daya untuk pusat data dan peralatan telekomunikasi, di mana kemampuannya untuk menangani tegangan tinggi dan beroperasi pada frekuensi tinggi membantu mengurangi konsumsi daya dan pembangkitan panas. GaN juga menemukan aplikasi dalam optoelektronik, khususnya dalam LED dan dioda laser. LED berbasis GaN banyak digunakan dalam penerangan solid-state, teknologi tampilan, dan penerangan otomotif karena efisiensi dan kecerahannya yang tinggi.

1.8 ERA BARU SEMIKONDUKTOR SUPER TIPIS

Telah terjadi kemajuan luar biasa dalam teknologi informasi berdasarkan ketersediaan produk yang lebih baik yang digunakan untuk penyimpanan, transfer, dan pemrosesan informasi dalam jumlah yang sangat besar. Hal ini dimungkinkan terutama karena ketersediaan semikonduktor yang mampu beroperasi pada skala ini. Kepadatan transistor saat ini, efisiensi energinya, suhu operasinya, kapasitas manajemen termalnya, dan frekuensi operasinya berada pada tingkat yang sebelumnya tidak terbayangkan. Karena permintaan yang terus meningkat untuk produk yang lebih baik, ada kebutuhan akan material dengan sifat yang lebih



baik yang dapat memperluas batas perangkat elektronik saat ini. Dalam beberapa waktu terakhir, telah terjadi perkembangan signifikan di bidang material 2D seperti grafen dan dikalkogenida logam transisi (TMD), yang dapat menjadi kandidat yang menjanjikan karena sifat fisik dan kimianya yang sangat baik yang sangat penting untuk penggunaannya dalam perangkat elektronik.

Material 2D yang sangat terkenal terdiri dari lapisan atom dua dimensi yang diperluas dengan ketebalan beberapa lapisan atom. Hal ini menyebabkan perubahan dramatis pada sifat material ini karena efek pembatasan kuantum pada material 2D. Di antara material 2D, graphene adalah material terpenting yang dilaporkan pada tahun 2004, yaitu lembaran karbon setebal satu lapisan yang tersusun secara heksagonal. Selain itu, TMD seperti molibdenum disulfida (MoS₂) dan tungsten disulfida (WS₂) telah menarik perhatian besar karena sifat semikonduktornya yang unggul.

1.9 GRAPHENE MATERIAL SUPER TRANSPARAN DAN FLEKSIBEL

Graphene disiapkan oleh A. Geim dan K. Novoselov pada tahun 2004, dan mereka memenangkan Hadiah Nobel Fisika tahun 2010 untuk penemuan material yang luar biasa ini. Graphene terdiri dari susunan heksagonal atom karbon dalam satu lapisan, menciptakan struktur pita elektronik yang menghasilkan sifat fisik dan kimia yang unik. Graphene memiliki celah pita nol – artinya, graphene adalah semilogam. Pita valensi teratas dan pita konduksi terendah bersentuhan di titik Dirac, menghasilkan fermion Dirac tanpa massa, sehingga memberikan sifat fisik dan kimia yang sangat baik pada graphene.

Sifat-Sifat

Karbon lapisan tunggal, yang tersusun dalam pola heksagonal membentuk material celah pita nol, memiliki sifat fisik yang sangat baik, yang sangat berguna dalam aplikasi perangkat elektronik. Grafena menunjukkan mobilitas elektron yang sangat besar sebesar $2 \times 10^5 \text{ cm}^2/\text{Vs}$ dalam kondisi ideal. Nilai mobilitas elektron tersebut sangat tinggi dibandingkan dengan konduktor tradisional seperti perak dan tembaga. Grafena sangat kuat, dengan kekuatan tarik 130 GPa, hampir 200 kali lipat dari baja. Konduktivitas termalnya sekitar 5.000 W/mK, menjadikannya kandidat ideal untuk manajemen termal dalam perangkat elektronik. Grafena hanya menyerap sebagian kecil radiasi elektromagnetik yang mengenainya. Grafena adalah material yang sangat transparan dan cocok untuk aplikasi optoelektronik. Meskipun sangat kuat dibandingkan dengan baja, grafena juga fleksibel dan dapat diregangkan hingga hampir 20%, menjadikannya kandidat terbaik untuk elektronik fleksibel.

Aplikasi

Mobilitas graphene yang tinggi menjadikannya kandidat yang paling cocok untuk menggantikan material elektronik tradisional untuk membuat FET, dan perangkat yang terbuat dari graphene dapat digunakan pada frekuensi sinyal tinggi, sehingga menghasilkan perangkat dengan kecepatan yang jauh lebih cepat. Luas permukaan yang besar dan konduktivitas listrik graphene yang tinggi membuatnya cocok untuk digunakan dalam baterai penyimpanan tinggi dan superkapasitor, yang secara signifikan meningkatkan kepadatan energi perangkat ini. Graphene juga berguna untuk aplikasi yang sensitif terhadap permukaan seperti sensor untuk



deteksi gas, bahan kimia, dan molekul lainnya. Sifat fleksibel graphene menjadikannya kandidat yang sangat diinginkan untuk elektronik fleksibel, perangkat yang dapat dikenakan, dan layar lipat, untuk menyebutkan beberapa aplikasi. Selain itu, sifat transparan graphene memiliki banyak aplikasi dalam perangkat optoelektronik, seperti LED, elektroda transparan, dan fotodioda.

Tantangan Dan Kemajuan Terbaru

Meskipun graphene memiliki sifat yang sangat baik untuk aplikasi di berbagai bidang, terdapat keterbatasan yang melekat. Keterbatasan utama adalah kurangnya celah pita (bandgap), yang memperpendek penerapannya dalam perangkat elektronik. Merupakan tantangan bagi komunitas ilmiah untuk menemukan cara mensintesis graphene secara reproduksi dan menciptakan celah pita pada graphene menggunakan berbagai pendekatan. Selain itu, ada upaya untuk menginterkalasi graphene dengan material menjanjikan lainnya seperti TMD untuk menciptakan komposit dan heterostruktur yang dapat mengatasi beberapa masalah mendesak dan mengeksplorasi kemungkinan untuk kelas material baru yang sesuai.

1.10 FLEKSIBILITAS TANPA BATAS DARI DUNIA TRANSISI LOGAM

Struktur Dan Komposisi

TMD dua dimensi memiliki rumus MX_2 ($M = Mo, W; X = S, Se, Te$). TMD, tidak seperti graphene, bersifat semikonduktor dan oleh karena itu cocok untuk aplikasi elektronik. Tidak seperti material lain, TMD dapat dengan mudah dieksfoliasi menjadi lapisan tunggal. Sifat-sifatnya bervariasi dari satu material ke material lainnya; Misalnya, MoS_2 adalah material dengan celah pita rendah (1,8 eV), sehingga cocok untuk berbagai aplikasi seperti transistor dan perangkat optoelektronik.

Sifat

TMD 2D dalam bentuk monolayer adalah semikonduktor celah pita langsung, yang merupakan semikonduktor celah pita tidak langsung dalam bentuk bulk. Oleh karena itu, mereka merupakan kandidat yang sangat baik untuk aplikasi optoelektronik. Bentuk monolayer TMD fleksibel dan dapat digunakan dalam perangkat elektronik fleksibel. Mobilitas elektron pembawa muatan yang cukup tinggi dalam TMD baik untuk penggunaannya dalam transistor film tipis.

Aplikasi

TMD adalah material dengan celah pita rendah, dan oleh karena itu, mereka dapat menyerap radiasi elektromagnetik dengan energi yang lebih rendah. Hal ini menjadikan mereka kandidat yang cocok untuk fotoluminesensi, fotodioda, dan aplikasi optoelektronik lainnya. Oksida logam transisi telah menjadi fokus karena aplikasinya dalam elektronik, seperti FET, perangkat switching tinggi, dan perangkat hemat daya.

Selain itu, TMD 2D secara mekanis fleksibel dan cocok untuk elektronik yang dapat dikenakan karena sifat elektroniknya yang sesuai. Sifat TMD yang bergantung pada ketebalan telah dimanfaatkan untuk mendesain memori non-volatil untuk meningkatkan kinerja perangkat elektronik. TMD juga telah menemukan aplikasi di bidang katalis yang sedang



berkembang dalam evolusi hidrogen dan solusi penyimpanan untuk masa depan yang berkelanjutan.

Tantangan Dan Kemajuan Terbaru

TMD telah terbukti sebagai material yang menjanjikan untuk meningkatkan fungsionalitas perangkat elektronik. Namun, ada tantangan yang membutuhkan banyak kemajuan untuk memanfaatkan potensi penuh dari material yang menjanjikan ini. Faktor pembatas utama adalah tantangan untuk meningkatkan skala temuan laboratorium ke skala industri untuk meningkatkan produksi perangkat elektronik berbasis TMD. Material ini menunjukkan sifat yang sangat baik dalam pengaturan laboratorium kecil, tetapi di area yang lebih besar, karena variasi ketebalan material ini, telah diamati variasi dalam sifat yang dihasilkan. Area perhatian lainnya adalah resistansi antarmuka/kontak elektroda logam dan TMD pada perangkat berbasis TMD. Resistansi pada antarmuka dapat memengaruhi kinerja perangkat elektronik secara negatif. Telah ada upaya untuk menumbuhkan TMD area luas dengan sifat seragam dan meminimalkan resistansi kontak antara TMD dan elektroda logam. Pendekatan lain adalah pengembangan heterostruktur dengan graphene dan TMD lainnya untuk memajukan penggunaan heterostruktur dalam perangkat multifungsi.

1.11 TANTANGAN BESAR DALAM MENJAGA KEAJAIBAN DUNIA KOMPUTER

Pada tahun 1960-an, Moore menyajikan hukum empiris yang dengannya ia memprediksi kemajuan dalam industri elektronik dan revolusi cara interaksi manusia serta penciptaan, penanganan, dan transmisi pengetahuan dan data. Menurut hukum Moore, jumlah transistor pada sebuah chip akan berlipat ganda setiap dua tahun. Perkembangan perangkat elektronik yang tak henti-hentinya telah sejalan dengan prediksi hukum Moore selama lebih dari enam dekade sekarang. Peningkatan eksponensial dalam kemampuan untuk mengintegrasikan sejumlah besar komponen elektronik pada sebuah chip telah menghasilkan perangkat elektronik dengan daya komputasi yang lebih tinggi dan biaya serta kebutuhan energi yang lebih rendah pada saat yang bersamaan.

Namun, seiring dengan semakin terbatasnya kemampuan mengintegrasikan komponen elektronik menggunakan material semikonduktor tradisional, kebutuhan akan material yang lebih hemat ruang dan energi semakin meningkat. Pada bagian selanjutnya, kita akan membahas keterbatasan material semikonduktor tradisional terkait dengan hukum Moore dan meneliti pengaruhnya terhadap teknologi semikonduktor.

1.12 BATAS AKHIR KEJAYAAN SILIKON DALAM DUNIA ELEKTRONIKA

Batas Skala Fisik Silikon

Seiring dengan mengecilnya ukuran komponen elektronik hingga di bawah 10 nm dalam perangkat elektronik, efek mekanika kuantum mulai menonjol dalam IC yang padat. Efek penerowongan kuantum lebih terasa ketika ketebalan lapisan isolasi berada dalam orde puluhan nanometer dalam transistor. Akibatnya, elektron dapat menembus lapisan isolasi SiO_2 dalam kasus wafer Si, menciptakan jalur pergerakan elektron yang tidak pasti dalam transistor, yang menyebabkan peningkatan arus bocor. Penerowongan kuantum mengganggu kemampuan transistor untuk beralih mati, sehingga meningkatkan kebutuhan daya dan



menurunkan efisiensi perangkat elektronik. Dengan berkurangnya ketebalan panjang gerbang, kemampuan elektron untuk mengalir dari gerbang ke drain menggunakan tegangan gerbang berkurang, sehingga meningkatkan kebocoran dan mengurangi kinerja perangkat elektronik.

Kepadatan Daya Dan Pembuangan Panas

Dengan meningkatnya kepadatan komponen pada sebuah chip, kepadatan daya juga meningkat, yang menyebabkan tantangan dalam manajemen termal. Karena konduktivitas termal semikonduktor tradisional, terdapat masalah dalam pengelolaan panas yang dihasilkan selama pengoperasian perangkat. Selain itu, efek kuantum yang menyebabkan penerowongan pembawa muatan melintasi penghalang isolasi, terutama pada pengoperasian frekuensi tinggi, secara signifikan berkontribusi pada pembangkitan panas. Metode umum dan tradisional yang digunakan untuk mendinginkan perangkat elektronik memiliki keterbatasan, yang dapat menyebabkan masalah manajemen panas pada perangkat dan menciptakan ketidakstabilan kinerja.

Kinerja Listrik Dan Masalah Interkoneksi

Seiring dengan berkurangnya ukuran komponen, kinerja kawat logam, yang dikenal sebagai interkoneksi, yang menghubungkan transistor yang berbeda menjadi signifikan. Dengan berkurangnya ketebalan interkoneksi, resistivitas interkoneksi yang terbuat dari tembaga atau aluminium meningkat, menciptakan hambatan kritis untuk transfer muatan. Selain itu, dengan meningkatnya kepadatan interkoneksi, kapasitansi antara interkoneksi yang tersusun rapat meningkat. Efek gabungan dari peningkatan resistivitas dan kapasitansi menyebabkan penundaan resistif-kapasitif (RC) dalam rangkaian dan sering kali meniadakan peningkatan kecepatan sinyal yang dicapai untuk komponen yang lebih kecil.


1.13 ERA KOMPUTASI KUANTUM DAN KEBANGKITAN CHIP GENERASI BARU

Ada banyak tantangan bagi industri semikonduktor untuk mengikuti laju perkembangan seperti yang diantisipasi oleh hukum Moore. Ada tantangan penskalaan untuk masa depan industri elektronik, dan ada peluang untuk mengatasi tantangan tersebut dengan pendekatan inovatif dengan menggunakan material baru, arsitektur perangkat, dan teknik manufaktur. Penggunaan material dan teknologi baru akan mengubah industri dan memungkinkan penerapan material ini di bidang kecerdasan buatan, komputasi kuantum, dan sistem otonom.

Integrasi heterogen dari berbagai sistem ke dalam chip yang sama akan membantu mengatasi keterbatasan penskalaan dan memungkinkan pemanfaatan sifat-sifat material yang berbeda untuk meningkatkan kinerja perangkat elektronik. Komputasi kuantum akan membuka jalan baru bagi penerapan teknologi canggih dengan daya komputasi yang lebih besar untuk melakukan perhitungan rumit di bidang-bidang terdepan sains dan teknologi.

1.14 KESIMPULAN

Material semikonduktor telah memainkan peran penting dalam pengembangan teknologi modern. Material ini telah memungkinkan terciptanya perangkat yang telah mengubah dunia kita, mulai dari komputer dan ponsel pintar hingga sel surya dan LED. Masa



depan material semikonduktor cerah, dengan aplikasi baru dan menarik yang terus dikembangkan.

Peran silikon sebagai material semikonduktor tradisional sangat mengakar dalam industri elektronik. Sifat-sifatnya yang menguntungkan, seperti ketersediaan, celah pita yang moderat, dan kompatibilitas dengan fabrikasi MOSFET, telah memungkinkan dominasinya yang bertahan lama. Namun, seiring kemajuan teknologi menuju aplikasi berkinerja lebih tinggi, material dengan sifat elektronik dan termal yang lebih baik sedang dieksplorasi untuk penggunaan khusus. Meskipun demikian, silikon diperkirakan akan terus menjadi landasan teknologi semikonduktor selama bertahun-tahun yang akan datang, terutama dalam komputasi dan elektronik tujuan umum.

Germanium, sebagai salah satu material semikonduktor asli, memainkan peran penting dalam pengembangan awal industri elektronik. Meskipun silikon telah mengungguli germanium untuk sebagian besar aplikasi, mobilitas elektron dan lubang germanium yang unggul, bersama dengan sensitivitas inframerahnya, memastikan bahwa germanium tetap relevan dalam aplikasi berkecepatan tinggi, optoelektronik, dan khusus. Seiring munculnya teknologi inovatif, germanium terus menjadi material berharga untuk perangkat semikonduktor canggih.

Galium arsenida adalah material semikonduktor tradisional yang telah terbukti sangat berharga dalam berbagai aplikasi elektronik dan optoelektronik canggih. Celah pita langsungnya, mobilitas elektron yang tinggi, dan ketahanan terhadap radiasi telah menjadikannya material pilihan untuk perangkat frekuensi tinggi, MMIC, dan sel surya berbasis ruang angkasa. Meskipun menghadapi persaingan dari material semikonduktor lain di area tertentu, GaAs terus memegang posisi penting dalam industri semikonduktor, terutama di mana kinerja tinggi dan fungsionalitas khusus diperlukan.

Silikon karbida, galium nitrida, dan indium fosfida mewakili generasi material semikonduktor berikutnya, masing-masing menawarkan keunggulan unik untuk aplikasi daya tinggi, frekuensi tinggi, dan optoelektronik. SiC ideal untuk elektronika daya, di mana efisiensi tinggi dan stabilitas termalnya memungkinkan perangkat yang lebih kompak dan andal. GaN unggul dalam aplikasi frekuensi tinggi dan daya tinggi, menjadikannya material kunci untuk penguat RF, transistor daya, dan sistem komunikasi. InP adalah material pilihan untuk sistem komunikasi berkecepatan tinggi dan optik, di mana mobilitas elektronnya yang tinggi dan celah pita langsung memungkinkan transmisi data yang efisien.

Meskipun material-material ini menghadirkan tantangan dalam hal biaya dan manufaktur, pembahasan dan pengembangan yang berkelanjutan mendorong peningkatan kinerja dan skalabilitasnya. Seiring dengan terus meningkatnya permintaan akan perangkat semikonduktor yang lebih efisien, lebih cepat, dan lebih andal, SiC, GaN, dan InP siap memainkan peran penting dalam membentuk masa depan teknologi elektronik dan komunikasi.


Grafena dan TMD mewakili garda terdepan material semikonduktor canggih. Konduktivitas, kekuatan, dan fleksibilitas grafena yang tak tertandingi menjadikannya kandidat yang kuat untuk berbagai aplikasi elektronik, optik, dan mekanik. Namun, kurangnya celah pita



membatasi penggunaannya dalam elektronika digital. Di sisi lain, TMD menawarkan sifat semikonduktor yang dibutuhkan untuk perangkat switching, bersama dengan fleksibilitas dan fotoluminesensi yang kuat, menempatkannya sebagai kandidat utama untuk elektronik dan optoelektronik generasi berikutnya.

Seiring berlanjutnya pembahasan, kombinasi graphene, TMD, dan material 2D lainnya dalam heterostruktur kemungkinan akan menghasilkan terobosan dalam kinerja dan fungsionalitas perangkat. Meskipun tantangan seperti skalabilitas dan rekayasa kontak tetap ada, masa depan material ini di industri semikonduktor sangat menjanjikan.

Keterbatasan material tradisional, khususnya silikon, menimbulkan tantangan signifikan untuk penskalaan perangkat semikonduktor yang berkelanjutan. Saat ukuran transistor mendekati skala atom, efek mekanika kuantum, disipasi daya, dan kendala ekonomi semakin mempersulit untuk mempertahankan laju yang diprediksi oleh hukum Moore. Namun, eksplorasi material alternatif seperti silikon karbida, galium nitrida, dan material 2D menawarkan solusi yang menjanjikan untuk tantangan ini. Dalam beberapa dekade mendatang, industri semikonduktor kemungkinan akan bertransisi ke era pasca-Hukum Moore, di mana inovasi dalam material, arsitektur perangkat, dan komputasi kuantum akan mendorong kemajuan teknologi lebih lanjut. Meskipun jalan di depan tidak pasti, potensi terobosan dalam teknologi semikonduktor tetap sangat besar, memastikan bahwa generasi perangkat berikutnya akan terus mendorong batas-batas kemungkinan.



BAB 2

PEMBELAJARAN MESIN PENDAHULUAN DAN FITUR

2.1 PENDAHULUAN

Pembelajaran mesin (ML), untuk keperluan pengantar, adalah sub-bidang dari kecerdasan buatan (AI) – sebuah bidang yang digemari banyak peneliti teknologi. Sebagai sub-bidang AI, ML telah mencapai sebagian besar aspek implementasi AI. Dari perspektif peneliti ML, Naqa dan Murphy, subbidang algoritma komputasi yang sedang berkembang yang disebut "pembelajaran mesin" bertujuan untuk meniru kecerdasan manusia dengan mengambil informasi dari lingkungannya. Sekarang kita memiliki gambaran yang cukup jelas tentang ML dalam kaitannya dengan AI, mari kita lihat lebih jauh apa yang ditawarkan ML. ML mencakup berbagai bidang multidisiplin yang termasuk dalam banyak arena yang mungkin atau mungkin tidak berinteraksi dengan ilmu komputer dan teknik.

Selain itu, karena telah menjadi bagian yang tak terpisahkan dari sebagian besar disiplin ilmu, terutama dalam beberapa tahun terakhir, sejumlah besar alat pemodelan dan bahkan algoritma untuk berbagai tugas pemrosesan data kini menjadi bagian dari proses ML. Tidak hanya pemrosesan data, ilmu hayati dan bahkan ilmu fisika juga menggunakan ML untuk mengatur teori mereka dan mensimulasikan hipotesis spesifik subjek. Lebih jauh lagi, ilmu elektronika dan digital menganggap ML sangat diperlukan dalam lingkungan yang berkembang yang mengakomodasi fakta bahwa ML sebagian besar adalah perangkat lunak yang dapat diintegrasikan dengan perangkat keras.

Klasifikasi material dan definisi properti adalah contoh implementasi ML yang lebih mudah di bidang ini. Dalam pembahasan mereka, Kudelina dan Vaimann telah mengutip ML untuk ilmu kelistrikan, yang paling tepat, bahwa algoritma AI dapat dilatih menggunakan model matematika mesin listrik. Hal ini akurat mengingat industri dan laboratorium mengalami kesulitan dalam mengumpulkan sejumlah besar data karena keterbatasan sumber daya. Dengan demikian, beberapa metode diagnostik berbasis AI yang menarik dipamerkan dengan penekanan pada karakteristiknya.


Berkaitan dengan pembelajaran mesin inti, pertama-tama kita akan membahas konsep dan struktur teoretis yang telah memikat dunia AI secara luas, sebelum itu, kita akan mendefinisikannya secara independen dari aplikasi dan cara kerjanya. Setelah dasar-dasar tersebut diletakkan, bab ini akan membahas ML tingkat lanjut, dengan mengingat bahwa ML itu sendiri sudah canggih dalam struktur dasarnya. Terakhir, bab ini akan diakhiri dengan aplikasi dan berbagai relevansinya dalam ilmu kelistrikan dan mengapa mengintegrasikan ML dan material semikonduktor merupakan ide yang cemerlang. Jadi, mari kita langsung terjun ke inti pembahasan!

Pertama-tama, mari kita pahami bahwa AI adalah tentang menanamkan realisme seperti kehidupan pada perangkat. Menarik untuk dicatat bahwa AI adalah tentang membuat mesin meniru manusia. Di sinilah kita sampai pada ML. Ini adalah cabang AI yang membantu mesin untuk melatih dirinya sendiri pada beberapa data dan menemukan pola di dalamnya



sehingga dapat memodifikasi analisisnya dan menerapkannya di masa depan dalam hal analisis dan prediksi. Motif ML adalah untuk menafsirkan data dan memahami pola.

Manusia melihat data, dan otak, dengan sendirinya, mulai menganalisis data dan membuat interpretasi dan kesimpulan. Misalnya, bayi manusia melihat lingkungannya dan menemukan tugas yang paling berulang dan menyimpan tindakan itu dan mulai menggunakannya untuk situasi di masa depan: katakanlah seorang anak meminta cokelat dan menyadari bahwa jika ditolak, ia dapat mendapatkannya dengan mengamuk. Itulah tepatnya yang dilakukan mesin: mereka menemukan data dan belajar darinya, dan kemudian berdasarkan masukan di masa depan, mereka mengandalkan pembelajaran untuk melakukan tindakan spesifik peristiwa untuk mendapatkan hasil yang diinginkan. Sangat menarik untuk menyaksikan tugas tersebut! Gambar 2.1 menggambarkan AI sebagai himpunan bagian dari pembelajaran.



GAMBAR 2.1 Kecerdasan buatan sebagai himpunan bagian dari pembelajaran.

Sekarang kita membahas tugas selanjutnya: konsep ML. Implikasi pertama adalah untuk data, yang dapat berupa terstruktur, tidak terstruktur, atau semi-terstruktur. Berdasarkan data tersebut, kita menetapkan "tugas" bagi mesin untuk mendapatkan "pengalaman", dan kemudian kita mengukur "kinerjanya". Hal ini mengarah pada kategorisasi ML dalam hal input data sebagai pembelajaran terawasi, tidak terawasi, semi-terawasi, dan penguatan. Keempat subset tersebut memiliki serangkaian algoritma sendiri yang mendefinisikan operasinya.

Selanjutnya, kita menuju ke aplikasi sistem cerdas ini. Xue dan Zhu mempelopori pembahasan di bidang-bidang yang dipengaruhi oleh ML, dan mereka menyimpulkan bahwa ML adalah teknik dasar yang memberikan kecerdasan pada komputer. Aplikasinya, yang sebelumnya sebagian besar bergantung pada metode sintesis dan induksi daripada deduksi,



telah meluas ke bidang AI lainnya dan semua ilmu pengetahuan yang dikenal dengan sangat mudah. Sekarang setelah kita meletakkan dasar, dengan ide dasar tentang ML, mari kita melangkah menuju bagian yang lebih dalam.


2.2 SEJARAH KECERDASAN BUATAN (AI)

AI, meskipun secara resmi diperkenalkan pertama kali pada tahun 1950-an, memiliki fondasi yang dibangun jauh lebih awal. Dari teori seorang penyair hingga makalah pembahasan yang mempertanyakan gagasan tersebut, AI telah memikat para peneliti awal bahkan sebelum istilah tersebut secara resmi diciptakan. Pembelajaran Mesin (ML) adalah instrumen penting untuk mencapai tujuan pemanfaatan teknologi terkait AI. ML terkadang disalahartikan dengan AI karena kemampuannya untuk belajar dan mengambil keputusan, tetapi sebenarnya merupakan bagian dari AI. Baru setelah tahun 1970-an ML terpisah dan berkembang secara independen. Berikut adalah pembahasan singkat tentang asal usul ML.


Kecerdasan Buatan

Dari era SM hingga abad ke-21, ML telah mengalami beberapa fase. Istilah "kecerdasan buatan" secara ironis berasal dari kata Yunani automaton, yang berarti "bertindak atas kemauan sendiri". Catatan paling awal tentang automaton berasal dari tahun 400 SM, yang tidak mengherankan, karena para sarjana Yunani di masa lalu dikenal karena pemikiran dan filosofi mereka yang melampaui batas. Baru kemudian, pada awal tahun 1900-an, banyak ide yang berpusat pada manusia buatan mendorong para ilmuwan untuk mempertanyakan apakah mungkin untuk menciptakan otak buatan yang dapat mereplikasi siklus pemikiran dan pola perilaku manusia. Makalah ilmiah "A Logical Calculus of the Ideas Immanent in Nervous Activity" oleh Walter Pitts dan Warren McCulloch dari tahun 1943 berisi model matematika pertama dari jaringan saraf dan karenanya meluncurkan bidang ML.

Buku *Organization of Behaviour*, karya Donald Hebb, berisi teori tentang hubungan antara aktivitas otak, jaringan saraf, dan perilaku. Pertama kali diterbitkan pada tahun 1949, buku ini menjadi salah satu karya fundamental dalam sejarah ML. Seperti yang disebutkan sebelumnya, AI muncul pada tahun 1950-an. Dari makalah pembahasan penting Alan Turing "Computing Machinery and Intelligence" yang dibuka dengan kalimat, "Saya mengusulkan untuk mempertimbangkan pertanyaan, "Bisakah mesin berpikir?", hingga Arthur Samuel mengembangkan proses pembelajaran awal yang dapat diterapkan pada mesin pada tahun 1952 dan akhirnya John McCarthy menciptakan istilah "kecerdasan buatan", dunia telah ramai membicarakan bagaimana mesin dapat diisi dengan informasi yang hanya dapat diinterpretasikan oleh otak manusia. Gambar 2.2 menyoroti garis waktu konversi AI ke ML.



Gambar 2.2 Garis waktu AI ke ML.



Jaringan Neural

Pada tahun 1957 Frank Rosenblatt memberikan penjelasan tentang jaringan neural paling awal untuk mesin – perceptron; sistem ini mampu mereplikasi otak Homo sapiens dalam hal memproses pikiran. Pada tahun 1970-an ML berkembang pesat, bercabang sebagai subset AI yang membantu analisis dan interpretasi pola agar mesin dapat memahami dan menginterpretasikan data. Selanjutnya, pada tahun 1990-an, ML, yang sebelumnya beroperasi berdasarkan pengetahuan turunan, mulai mengadopsi pendekatan berbasis data.

Pada tahun 1997, Deep Blue milik IBM mengalahkan juara dunia catur, yang semakin memperkuat gagasan ML yang berkembang menjadi pembelajaran mendalam, sebuah istilah yang diciptakan oleh Geoffrey Hinton. Sejak itu, banyak perusahaan multinasional mulai memanfaatkan rekayasa pengetahuan ini dan menerapkannya untuk membangun model yang dapat meniru emosi dan kecerdasan manusia secara luas. Saat ini, ML telah menggemparkan dunia dengan berbagai kasus penggunaan dan aplikasi yang melampaui apa yang mungkin dipikirkan oleh para pendiri AI. Lebih jauh lagi, pembahasan demi pembahasan telah menentukan bahwa ML masih memiliki jalan panjang untuk ditempuh dan akan terus berkembang.

ML mendukung berbagai pekerjaan di berbagai industri, mulai dari pakar keuangan yang mencari sinyal untuk perdagangan yang menguntungkan hingga organisasi keamanan data yang mencari virus. Algoritma AI dirancang untuk belajar terus menerus, mensimulasikan asisten pribadi virtual, sebuah fungsi yang sangat mereka kuasai.

Mengembangkan Pembelajaran Mesin

Kisah ML, yang pernah didefinisikan pada tahun 1970-an, mengarah pada spesifikasinya. Setelah pembahasan awal tentang ML, gagasan jaringan saraf muncul, yang pada dasarnya merupakan prinsip algoritma cerdas. Jaringan saraf dirancang untuk meniru otak manusia. Karena merupakan jaringan dari bagian-bagian yang terhubung, maka disebut jaringan saraf. Pembahasan sistem saraf biologis menjadi dasar komponen-komponen ini. Dengan kata lain, jaringan saraf merupakan upaya untuk mengembangkan mesin yang, dengan memanfaatkan komponen yang berperilaku seperti neuron biologis, bekerja serupa dengan otak manusia.

Tugas jaringan saraf adalah mengambil pola masukan dan mengubahnya menjadi pola keluaran. Kategorisasi pola adalah salah satu tugas yang dapat dilatih untuk dilakukan oleh jaringan saraf, dan akan dijelaskan secara menyeluruh karena gagasan ini agak abstrak. Teknik mengklasifikasikan pola ke dalam kelompok dikenal sebagai klasifikasi pola. Blok bangunan dasar untuk jaringan saraf mirip dengan neuron. Komponen-komponen ini terhubung satu sama lain melalui koneksi yang kekuatannya dapat berubah sesuai dengan algoritma atau proses pembelajaran. Untuk menilai tingkat aktivitasnya, setiap unit ini secara independen (paralel) mengintegrasikan data dari sinapsisnya.

Jaringan saraf mengarah pada pengembangan perceptron. Sebagai hasil kombinasi model Hebb dan Samuel, perceptron dirancang oleh Cornell Aeronautical Laboratory (CAL) sebagai mesin, bukan program. Perangkat lunak kemudian diinstal dan menghasilkan Perceptron Mark 1, bukan IBM 704. Akibatnya, algoritma dan perangkat lunak bersifat


portabel dan dapat ditransfer antar mesin. Kemudian, subset prospek ML muncul dengan pengembangan algoritma tetangga terdekat, jaringan feedforward dan backpropagation, algoritma boosting, dan sebagainya. Berbagai algoritma yang muncul membutuhkan kategorisasi yang jelas di bawah ML.

2.3 MENGENAL EMPAT CARA BERBEDA MESIN MEMPELAJARI SESUATU

Sebelum kita membahas jenis-jenis ML, kategorisasinya, dan dasar-dasarnya, kita akan melihat parameter yang mendefinisikan pengelompokan ML dan menjelaskan dasar dari berbagai algoritma ML. Elemen kunci dari ML bertumpu pada tiga pilar, yaitu: representasi, evaluasi, dan optimasi. Yang pertama berkaitan dengan tampilan model ML dan bagaimana representasi pengetahuan. Yang kedua berfokus pada seberapa baik model tersebut, apa saja pembedaannya, dan tolok ukur evaluasi untuk algoritma yang terlibat. Elemen terakhir berkaitan dengan proses mencari model yang baik dan dengan demikian bergerak menuju bagaimana program sebenarnya dihasilkan.

Jenis-Jenis Pembelajaran Mesin

Berdasarkan deklarasi komponen ML yang telah disebutkan di atas, konsep itu sendiri secara luas dapat dikategorikan menjadi tiga jenis: pembelajaran terawasi, pembelajaran tak terawasi, dan pembelajaran penguatan. Perlu juga dijelaskan bahwa seiring kemajuan teknik berpikir otomatis, kategori keempat diperkenalkan dalam katalog ML: pembelajaran semi-terawasi. Sekarang kita akan mencoba memahami dan membedakan kategori-kategori tersebut. Gambar 2.3 menunjukkan berbagai subkategori ML.




Gambar 2.3 Subdivisi pembelajaran mesin.

Pembelajaran Terawasi

Seperti namanya, model pembelajaran ini memiliki pengawas, yang secara teknis kita sebut sebagai "label". Dengan dataset yang berisi label, model ML dapat dibangun untuk melatih dirinya sendiri pada output, dan kemudian ketika diberikan data baru, harapannya tetap untuk dapat mengambil label yang benar. Informasi dari satu jaringan saraf berfungsi sebagai sinyal instruksional untuk mengubah pola koneksi di jaringan lain melalui pembelajaran terawasi.

Sejak munculnya ML, pembelajaran terawasi telah berkembang berdasarkan konsep bahwa pola perilaku manusia terbentuk sejak bayi berdasarkan data – misalnya, seorang anak diperlihatkan pohon dan berulang kali diberi tahu, "Ini adalah POHON"; kemudian mungkin anak itu diperlihatkan mobil dan sekali lagi berulang kali diberi tahu, "Ini adalah MOBIL"; dan seterusnya dengan sejumlah hal yang tidak diketahui yang dikategorikan di otak di bawah subjudul. Pada dasarnya, ini menjadi pembelajaran terawasi; Jauh kemudian, jika anak diperlihatkan gambar yang berisi pohon dan mobil, ia akan mampu mengidentifikasinya, bukan berdasarkan karakteristik tetapi berdasarkan label yang diberikan kepada mereka. Model ML berperilaku kurang lebih serupa. Gambar 2.4 mengilustrasikan model pembelajaran terawasi.



Gambar 2.4 Model pembelajaran terawasi.

Akibatnya, jaringan yang dilatih memperoleh keterampilan baru dalam pemrosesan informasi yang memungkinkannya untuk mencapai tujuan atau transformasi spesifik yang ditentukan oleh sinyal instruksional. Dengan melakukan ini, pembelajaran terawasi secara efektif dan tepat menciptakan pola koneksi yang tidak perlu dikodekan dan seringkali tidak dapat dikodekan.


Banyak aktivitas neural yang dibantu dalam pembuatan dan pemeliharaan pembelajaran terawasi. Algoritma pembelajaran terawasi selanjutnya dikategorikan menjadi algoritma klasifikasi dan algoritma regresi.

Pembelajaran Tak Terawasi

Kebalikan dari pembelajaran terawasi, pembelajaran tak terawasi berasal dari gagasan bahwa alih-alih label yang tersedia secara formal, model ML harus belajar untuk mengidentifikasi dan menafsirkan fitur serupa dari elemen dalam dataset tertentu dan kemudian mengelompokkannya berdasarkan kesamaan tersebut. Argumen yang dikemukakan adalah bahwa pertama, pengetahuan yang dimasukkan ke dalam peta atau model disediakan oleh pengulangan pesan sensorik. Kemudian sebagian dari informasi ini dapat ditemukan dengan melihat rata-rata, varians, dan kovariansi pesan sensorik. Mari kita pahami ini

menggunakan analogi anak. Seorang anak diberi potongan lima gambar matematika, masing-masing dua set.

Katakanlah dua persegi, dua lingkaran, dua segitiga, dan seterusnya, lalu diminta untuk memasangkannya. Anak tersebut mampu melakukannya dengan mempelajari struktur dan karakteristik objek. Misalnya, di kemudian hari, sebuah potongan persegi baru dipotong dan diberikan kepada anak; ia akan dapat menempatkannya bersama dengan potongan persegi lainnya. Pembelajaran tanpa pengawasan bekerja serupa. Algoritma dapat memahami karakteristik dan pola serupa, sehingga ia tahu DI MANA sesuatu ditempatkan tetapi tidak tahu APA sesuatu itu. Gambar 2.5 menggambarkan model logika pembelajaran tanpa pengawasan.



Gambar 2.5 Model logika pembelajaran tanpa pengawasan.


Selanjutnya, dengan menggunakan informasi ini untuk membangun model "apa yang biasanya terjadi", komunikasi yang masuk dapat secara otomatis dibandingkan dengannya, sehingga memungkinkan untuk segera mendeteksi perbedaan yang tidak terduga. Akhirnya, jenis pengetahuan yang masuk ke dalam filter tersebut merupakan prasyarat yang diperlukan untuk pembelajaran reguler, dan asosiasi dengan fungsi logis komponen – bukan hanya elemen itu sendiri – dapat dibentuk dengan representasi konstituen yang independen. Algoritma pembelajaran tanpa pengawasan selanjutnya diklasifikasikan sebagai algoritma pengelompokan, aturan asosiasi, dan pengurangan dimensi.

Pembelajaran Penguatan

Metode pembelajaran ini paling erat kaitannya dengan teknik yang digunakan orang tua dalam membimbing dan mengajar anak-anak. Pembelajaran penguatan meniru metode coba-coba di mana keberhasilan menghasilkan hadiah dan kegagalan menyebabkan hukuman. Sekali lagi, mari kita pahami ini dengan analogi anak. Beberapa hari setelah memahami pohon, mobil, dan bentuk, anak tersebut diperlihatkan sebuah pohon; untuk keperluan argumen, katakanlah anak itu berteriak, "Itu adalah MOBIL"; wali anak tersebut akan memarahi atau memberikan tatapan tidak setuju dan mengoreksinya. Sekarang, seandainya anak itu berkata, "Itu adalah POHON", dia akan mendapatkan apresiasi atau permen. Ini hampir persis seperti yang dilakukan pembelajaran penguatan.

Untuk mengatasi tantangan pembelajaran penguatan, dua pendekatan utama dapat dilakukan. Yang pertama adalah menyelidiki melalui rentang perilaku dan mengidentifikasi sesuatu yang bekerja dengan baik dalam pengaturan tertentu. Inilah tepatnya yang diadopsi oleh pemrograman genetik dan algoritma sebagai strategi. Yang kedua adalah menghitung utilitas bertindak dalam berbagai kondisi dunia menggunakan pendekatan statistik dan


pemrograman dinamis. Algoritma pembelajaran penguatan dikelompokkan menjadi algoritma berbasis model dan tanpa model, juga disebut sebagai teknik positif dan negatif. Gambar 2.6 mewakili pembelajaran penguatan.



Gambar 2.6 Representasi pembelajaran penguatan.

Pembelajaran Semi-Supervised

Pembelajaran semi-supervised (SS) memiliki kumpulan data minimal berupa data berlabel dan kumpulan data tak berlabel yang luas dengan jenis yang sama. Ketika model ML bekerja dengan kombinasi data yang ditentukan dan menerjemahkan fitur data berlabel ke data tak berlabel dan kemudian memprediksi kategori dari kumpulan data baru, ini menghasilkan pembelajaran SS. Berikut analogi anak terakhir: anak ini sekarang sangat pintar. Dia hanya diperlihatkan satu atau dua pohon dan diberi tahu, “Ini adalah POHON”. Anak itu diajak berjalan-jalan keesokan harinya, di mana setiap struktur tinggi yang berdiri berwarna cokelat di bagian bawah dan hijau di bagian atas; sekarang anak itu dapat berhenti dan berkata, “POHON”. Ini akan menjadi pembelajaran SS. Gambar 2.7 merangkum contoh pembelajaran semi-supervised.



Gambar 2.7 Contoh pembelajaran semi-supervised.



Pembelajaran SS, yang melibatkan pembelajaran simultan dari sekumpulan konsep yang terpisah, dengan algoritma pembelajaran hanya memiliki akses ke informasi keanggotaan konsep parsial, kini telah ditambahkan ke paradigma independen distribusi dari pembelajaran konsep (supervised). Banyak kelas konsep yang dapat dipelajari telah terbukti dapat dipelajari SS juga. Sebuah oracle perantara digunakan untuk memperkenalkan metode pembelajaran baru. Agar dapat dipelajari SS, parameter yang cukup disediakan untuk sekumpulan kelas konsep. Algoritma pembelajaran SS dapat dikatalogkan sebagai pelatihan mandiri, pelatihan bersama, dan propagasi label berbasis grafik.

2.4 MENDETEKSI KERUSAKAN PRODUK MENGGUNAKAN ALGORITMA CERDAS


Kami telah meninjau secara menyeluruh jenis dan parameter model ML. Terdapat definisi yang jelas dalam desain kasus penggunaan model. Bagian ini mencoba membahas implementasi algoritma supervised dan unsupervised pada dataset UCI SECOM. Menurut McCann dan Johnston, proses manufaktur semikonduktor kontemporer yang canggih biasanya diamati secara terus menerus melalui pelacakan sinyal atau variabel yang diperoleh dari sensor atau lokasi pengukuran proses. Dalam pembahasan mereka, mereka mengembangkan dataset yang berisi lebih dari 500 variasi sinyal data yang membantu mengekstrak kekhususan pengembangan semikonduktor. Sistem pemantauan khusus secara teknis mengukur berbagai sinyal dan akhirnya menghasilkan lulus atau gagal dalam pengujian lini rumah tangga yang terkendali. Dimensi dataset diberikan pada Tabel 2.1.

Tabel 2.1 Dimensi Asli

Fitur	Kasus Uji	Berhasil	Gagal
592	1.567	1.463	104

Praproses dataset melibatkan perubahan representasi dan penggantian nilai NaN dengan rata-rata/median berdasarkan ketersediaan data. Nilai yang berhasil awalnya direpresentasikan dengan -1 dan kemudian diubah menjadi 1 selama proses pembersihan data; demikian pula, nilai yang gagal, yang kemudian direpresentasikan dengan 1, diganti dengan 0 untuk memastikan kemudahan fungsi aktivasi klasifikasi yang tepat. Kolom yang berlebihan dihilangkan, karena dataset sudah dinormalisasi, dan nilai kosong atau NaN diganti dengan rata-rata kolomnya. Kolom dengan nilai yang hilang yang melebihi tiga jarak pembagian standar yang dapat diterima dihilangkan.

Selanjutnya, kolom dengan nilai univariat dihilangkan. Data yang telah dibagi menjadi parameter dan target pada dasarnya dibagi menjadi dataset parsial, satu untuk pelatihan dan yang lain untuk pengujian. Parameter pelatihan kemudian diskalakan menggunakan `sklearn.preprocessing.MinMaxScaler`. Setelah data sesuai dengan skalar, langkah transformasi terakhir dilakukan sebelum data perlu dijalankan melalui berbagai model. Dimensi dataset sebagai hasil pra-pemrosesan diberikan pada Tabel 2.2.



Tabel 2.2 Dimensi yang Dimodifikasi

Parameter	Target	Pelatihan (Training)	Pengujian (Testing)
443	2	1.175 (75%)	392 (25%)

Dataset setelah diproses menjalani enam algoritma pembelajaran terawasi utama, yaitu: regresi linier, regresi logistik (LR), pohon keputusan, hutan acak, mesin vektor pendukung, dan tetangga terdekat K. Ini diikuti dengan penghapusan label dan menjalankan dataset di bawah tiga algoritma tak terawasi utama. Masing-masing algoritma telah dijelaskan dan didemonstrasikan dalam implementasi.

Algoritma Pembelajaran Terawasi

Seperti yang telah disebutkan sebelumnya dalam bab ini, pembelajaran terawasi melibatkan kejelasan dalam label data. Di sini kita akan membedah lebih lanjut pembelajaran terawasi menjadi klasifikasi dan regresi. Yang pertama melibatkan algoritma yang mencari metode yang benar-benar dapat membantu mengkategorikan dataset sesuai dengan faktor-faktor subset yang memengaruhinya. Penerapan pendekatan klasifikasi melibatkan pengelompokan data sesuai dengan pengetahuan yang telah diperoleh program komputer dari menjalankannya berulang kali melalui dataset pelatihan. Regresi, di sisi lain, melakukan tugas menemukan korelasi antara variabel independen dan dependen.


Beberapa algoritma klasifikasi adalah k-nearest neighbour, naive bayes, random forest, LR, dan lain-lain. Dan beberapa algoritma regresi meliputi regresi pohon keputusan, komponen utama, regresi vektor pendukung, regresi linier, dan sebagainya. Sebelum kita membahas algoritma-algoritma tersebut, mari kita pahami bahwa semua sistem akan menggunakan matriks kebingungan sebagai elemen penentu akhir untuk akurasi model klasifikasi.

Matriks kebingungan terdiri dari empat bagian, dan dapat mewakili hal-hal berikut: positif sejati, yaitu kebenaran aktual yang diprediksi sebagai benar; negatif palsu, ketika kebenaran aktual diprediksi sebagai salah; negatif sejati, di mana nilai yang sebenarnya salah juga diprediksi sebagai salah; positif palsu, ketika nilai yang sebenarnya salah diprediksi sebagai benar. Perbedaan antara positif sejati dan negatif sejati inilah yang dimaksudkan untuk ditingkatkan sehingga memengaruhi akurasi. Oleh karena itu, akurasi dihitung sebagai berikut:

$$\frac{TP + TN}{TP + FP + FN + TN} \quad (2.1)$$

Selanjutnya, untuk model regresi, kita akan menggunakan determinan mean absolute error (MAE) dan mean squared error (MSE). Kedua nilai tersebut dihitung sebagai berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.2)$$



$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.3)$$

Dalam Persamaan 2.2 dan 2.3, n adalah jumlah total instance, $\hat{y}_i$ adalah nilai prediksi instance i , dan y_i adalah nilai target sebenarnya dari i . Semakin rendah nilai MAE dan MSE, semakin baik modelnya.

Dalam semua algoritma pembelajaran terawasi dan pembelajaran tak terawasi, variasi dataset selama pengujian dan pelatihan, rasio keseimbangan, dan jenis penskalaan memengaruhi akurasi data. Misalnya, dalam klasifikasi LR, *StandardScaler* memberikan akurasi 0,82, sedangkan *MinMaxScaler* meningkatkan akurasi menjadi 0,93, yang merupakan peningkatan akurasi yang cukup signifikan, mengingat penggunaan algoritma yang sama.

Regresi Linier

Metode statistik fundamental untuk mengetahui hubungan antara dua variabel kontinu adalah regresi linier. Metode ini mengasumsikan bahwa ada garis lurus antara variabel independen dan dependen. Nilai yang tidak diketahui dapat diprediksi menggunakan analisis regresi linier berdasarkan nilai yang tidak diketahui yang analog. Variabel yang ingin diprediksi oleh peneliti dikenal sebagai variabel dependen. Variabel yang digunakan untuk memprediksi nilai variabel lain dikenal sebagai variabel independen. Gambar 2.8 mengilustrasikan akurasi untuk regresi linier.

Pada Gambar 2.8, dua istilah membantu menentukan akurasi; MAE dan MSE adalah kalkulator akurasi untuk model regresi. Semakin dekat kedua nilai tersebut ke 0, semakin baik modelnya. Tujuan utama LR adalah menemukan garis yang paling sesuai dengan data atau, dalam kasus banyak prediktor, di mana hyperplane terlibat. Jumlah kuadrat residual, atau kesalahan, antara nilai yang diamati dan diprediksi diminimalkan untuk mencapai hal ini.

```
Kesalahan absolut rata-rata: 0.21537161740511412  
Kesalahan kuadrat rata-rata: 0.20304747671519993
```


Gambar 2.8 Akurasi untuk regresi linier.

Regresi Logistik

Regresi logistik adalah model statistik yang memungkinkan pembagian data ke dalam kelompok diskrit dengan melihat korelasi antara satu atau lebih variabel independen. Pemodelan prediktif, di mana model menentukan probabilitas matematis suatu kejadian yang termasuk dalam kategori tertentu atau tidak, sering menggunakannya. Regresi logistik diterapkan pada tugas klasifikasi biner di mana terdapat dua kemungkinan hasil untuk variabel hasil kategorikal. Hal ini dilakukan dengan menyesuaikan data ke kurva logistik, yang memperkirakan kemungkinan suatu peristiwa akan terjadi. Dasar dari LR adalah asumsi



hubungan linier antara prediktor dan log odds variabel hasil. Gambar 2.9 menjelaskan matriks kebingungan untuk LR.



Gambar 2.9 Matriks kebingungan untuk regresi logistik.

Menurut matriks kebingungan yang diberikan pada Gambar 2.9, 365 true positive memberikan gambaran yang jelas tentang efisiensi prediksi model, yang pada kenyataannya menghasilkan akurasi 0,934, sehingga juga mengasumsikan bahwa setiap observasi berdiri sendiri.

Regressor Pohon Keputusan

Sekarang regressor pohon keputusan (DTR) pada dasarnya adalah teknik pembelajaran terawasi yang bersifat nonparametrik dan terutama digunakan untuk regresi, tetapi juga mengakomodasi klasifikasi. Tujuannya adalah untuk membangun model yang, dengan memanfaatkan aturan keputusan dasar yang disimpulkan dari fitur data, memprediksi nilai variabel target.


Aproksimasi konstan dari subset yang rusak dapat diasumsikan sebagai struktur pohon. Sekarang DTR membuat prediksi yang relevan pada data di masa mendatang dengan menggunakan kualitas objek untuk melatih model sehubungan dengan struktur pohon. Dan proses berulang ini menghasilkan output kontinu yang bermakna. Output kontinu menunjukkan hasil atau output yang bukan diskrit – yaitu, tidak hanya diwakili oleh kumpulan angka atau nilai diskrit yang diketahui. Gambar 2.10 menjelaskan akurasi untuk pengklasifikasi pohon keputusan.

Pada Gambar 2.10, MAE dan MSE membantu mengevaluasi akurasi model, yang relatif baik, karena penyetelan parameter model lainnya. Penyetelan halus model pada dasarnya

melibatkan perubahan nilai yang diberikan pada parameter, seperti *random_state*, *test_size*, *criterion*, *max_depth*, dan lain-lain.

```
Kesalahan absolut rata-rata: 0.12526539278131635
Kesalahan kuadrat rata-rata: 0.12526539278131635
```

Gambar 2.10 Akurasi untuk pengklasifikasi pohon keputusan.



Gambar 2.11 Matriks kebingungan untuk pengklasifikasi hutan acak.

Pengklasifikasi Random Forest


Random forest sangat berguna untuk mengelola dataset yang rumit dan besar serta ruang fitur berdimensi tinggi dan menawarkan wawasan tentang signifikansi fitur individual. Ini dapat mengurangi overfitting dan mempertahankan tingkat akurasi prediksi yang tinggi. Gambar 2.11 menjelaskan matriks kebingungan untuk pengklasifikasi random forest.

Akurasi meningkat hingga 0,934 dengan 513 nilai positif sejati, yang secara komparatif lebih tinggi daripada model algoritma klasifikasi dan regresi sebelumnya.

Mesin Vektor Pendukung

Tujuan utama dalam algoritma mesin vektor pendukung (SVM) adalah untuk mendeteksi hyperplane terbaik di semua ruang kecuali ruang N-dimensi. Ruang n-D ini kemudian dapat digunakan untuk tujuan membagi titik data ke dalam kelompok ruang fitur multifaset. Hyperplane melakukan upaya tertentu untuk mempertahankan buffer yang harus cukup besar untuk mengakomodasi jarak antitesis antara titik-titik yang paling dekat dalam berbagai subset kelas yang dibagi. Gambar 2.12 menggambarkan matriks kebingungan untuk


SVM. Pengklasifikasi memberikan akurasi puncak 94,64% dengan syarat distribusi data serupa bersama dengan parameter penyetelan untuk model SVM.




Gambar 2.12 Matriks kebingungan untuk mesin vektor pendukung.

K-Nearest Neighbours

Desain algoritma K-nearest neighbours (KNN) didasarkan pada pemetaan jarak dasar untuk menemukan sejumlah tetangga terdekat, K. Menggunakan metrik jarak yang telah ditentukan sebelumnya, seperti jarak Euclidean atau bahkan jarak Manhattan, adalah pendekatan umum dalam mendefinisikan lingkungan suatu titik data. Pilihan yang menguntungkan atau yang paling umum terdekat dari K tetangga kemudian digunakan untuk memutuskan dan menetapkan kelas atau, dalam beberapa kasus, bahkan nilai elemen data. Menggunakan metode ini memungkinkan serangkaian aturan yang diikuti untuk mengantisipasi hasil berdasarkan formasi lokal data dan menyesuaikan dengan berbagai preseden. Gambar 2.13 menyoroti matriks kebingungan untuk KNN.



Gambar 2.13 Matriks kebingungan untuk K-tetangga terdekat.



Gambar 2.14 Peta KNN untuk prediksi oleh model.

Matriks pada Gambar 2.13 menghasilkan akurasi 0,938 dengan nilai NULL untuk false positive dan true negative. Selanjutnya, kita akan melihat distribusi data aktual dalam pengklasifikasi K-neighbour. Pada Gambar 2.14, pemetaan jarak titik data telah dilakukan menggunakan pemetaan jarak Euclidean. Skala skor berkisar dari 0 hingga 1, dan intensitas warna menunjukkan kepercayaan model dalam memberikan skor tersebut. Selanjutnya, bentuk-bentuk tersebut menunjukkan label sebenarnya dari dataset. Gambar 2.14 menunjukkan peta KNN untuk prediksi oleh model.

Algoritma Pembelajaran Tanpa Pengawasan

Sekali lagi, seperti yang disebutkan sebelumnya dalam bab ini, pembelajaran tanpa pengawasan melibatkan kurangnya label data untuk observasi dalam dataset; hasilnya adalah pengelompokan klausa umum. Pembelajaran tanpa pengawasan juga dapat dibagi menjadi tiga kategori: pengelompokan (clustering), aturan asosiasi, dan pengurangan dimensi. Untuk



pengelompokan, data tanpa label dapat diperiksa dan dibagi menjadi kelompok-kelompok berdasarkan kesamaan atau perbedaan.

Data yang tidak terkategori dibagi menjadi kelompok-kelompok yang terjadi secara alami dengan mengidentifikasi pola yang berulang atau struktur yang serupa. Kedua, metode berbasis aturan yang disebut penambangan aturan asosiasi dapat digunakan untuk menemukan koneksi yang menarik antara potongan data dalam basis data besar. Dalam algoritma pembelajaran tanpa pengawasan, korelasi dan kemunculan bersama dalam data serta berbagai koneksi antara objek data ditemukan dengan mencari tautan jika-maka yang sering terjadi, juga dikenal sebagai aturan. Terakhir, pengurangan dimensi adalah metode pembelajaran tanpa pengawasan yang menurunkan jumlah fitur atau dimensi dataset. Algoritma ini mengurangi jumlah karakteristik acak atau yang tidak perlu dalam dataset dengan mengekstrak fitur-fitur kunci.

Pengelompokan K-Means



Pengelompokan K-means adalah pendekatan pembelajaran tanpa pengawasan di mana data yang tidak berlabel dikelompokkan atau dipisahkan menjadi beberapa kluster. K dalam K-means digunakan untuk menentukan jumlah kluster yang telah ditentukan sebelumnya yang perlu dibentuk selama proses. Ini berarti bahwa jika $K = 2$, akan menghasilkan dua kluster; jika $K = 3$, akan menghasilkan tiga kluster, dan seterusnya. Algoritma ini memungkinkan kita untuk mengorganisir data ke dalam kelompok-kelompok terpisah dan memiliki keuntungan hampir secara otomatis menemukan kategori kelompok dengan sendirinya dari dataset yang tidak berlabel tanpa perlu pelatihan. Setiap kluster dalam teknik ini memiliki centroid, umumnya rata-rata titik data, yang melekat padanya sesuai dengan teori centroid. Menggabungkan jarak setiap titik dengan kluster masing-masing menjalankan tujuan dasar dari algoritma ini. Gambar 2. menggambarkan pengelompokan K-means.

Sayangnya, akurasi serendah 44% menggunakan algoritma pembelajaran tanpa pengawasan. Untuk investigasi jumlah kluster ideal, teknik yang sangat umum adalah metode siku. Nilai WCSS digunakan dalam prosedur ini. Jumlah kuadrat di dalam kluster, atau WCSS, adalah ukuran statistik yang mencirikan total variasi di dalam sebuah kluster. Kita dapat menggunakan salah satu metode yang telah dihitung sebelumnya untuk pemetaan jarak, seperti jarak Manhattan atau Euclidean, untuk mengukur jarak antara titik data dan centroid yang sesuai.

Koefisien siluet, juga disebut skor siluet K-means, mengukur seberapa mirip suatu titik data di dalam sebuah kluster atau seberapa kohesifnya dalam kaitannya dengan kluster lain, yang dikenal sebagai pemisahan. Dibandingkan dengan yang sebelumnya, siluet memberikan presisi yang lebih besar.

Pengelompokan Hierarki

Dalam algoritma ini, kita mulai dengan memperlakukan setiap titik data individual sebagai kluster independennya sendiri; kemudian kluster-kluster ini digabungkan berpasangan, bertiga, dan seterusnya hingga akhirnya membentuk satu kluster induk. Dendrogram adalah struktur yang dihasilkan dari pengembangan hierarki kluster dalam algoritma ini dalam bentuk pohon. Kumpulan data dikelompokkan ke dalam kluster menggunakan metode bottom-up.





Gambar 2.15 Pengelompokan K-means menggunakan metode siku dan metode skor siluet.

Ini berarti bahwa algoritma mengelompokkan kluster yang paling dekat. Dan untuk memperluasnya, proses ini dilanjutkan hingga setiap kluster digabungkan untuk membentuk satu kluster tunggal yang menampung setiap kumpulan data. Berbeda dengan pengelompokan berbasis partisi, pengelompokan aglomeratif membentuk pohon gabungan bersumber yang diidentifikasi dari karakteristik biner saat bergerak dari node yang paling sedikit – yaitu, daun yang berisi potongan data hingga ke akar, yang pada dasarnya menampung seluruh kumpulan data. Gambar 2.16 menyoroti dendrogram pengelompokan hierarki dan Gambar 2.17 menggambarkan analisis komponen utama.

Analisis Komponen Utama

Dalam analisis komponen utama (PCA), secara teknis, tujuannya adalah pengurangan dimensi dengan menciptakan beberapa variabel baru yang dikenal sebagai komponen utama; ini berasal dari pencampuran atau penggabungan variabel asli yang tersedia secara linier sederhana. Pada intinya, sebagian besar fakta yang termasuk dalam variabel absolut dikompresi atau diratakan menjadi komponen pendahuluan sebagai hasil dari kombinasi *ex post facto*, sehingga menghasilkan beberapa variabel yang sama sekali tidak berkorelasi, dan ini disebut komponen utama.


Jumlah karakteristik atau dimensi dalam suatu dataset secara eksponensial meningkatkan jumlah data yang dibutuhkan untuk mendapatkan hasil yang bermakna secara statistik. Overfitting, penundaan komputasi yang berkepanjangan, dan penurunan akurasi model ML adalah kemungkinan hasil dari hal ini. "Kutukan dimensi" mengacu pada masalah yang dapat muncul saat bekerja dengan data berdimensi tinggi. Oleh karena itu, PCA diperlukan.



Gambar 2.16 Dendrogram pengelompokan hierarkis.

2.5 NAVIGASI CERDAS DI TENGAH LAUTAN DATA SEMIKONDUKTOR


Semua pembahasan sejauh ini telah mengungkapkan banyak hal terkait kemungkinan kasus penggunaan di bidang ilmu kelistrikan, terutama yang berkaitan dengan material semikonduktor. Metode dan algoritma pembelajaran terawasi memberikan hasil yang jauh lebih andal mengingat tersedianya cukup data berlabel untuk pelatihan model. Sebaliknya, data tanpa label menghasilkan keberhasilan dalam ekstraksi dan analisis fitur menggunakan teknik pembelajaran tak terawasi. Gambar 2.18 menunjukkan garis besar rentang data.



Gambar 2.17 Analisis komponen utama.

Pada Gambar 2.18, fiksasi data setelah setiap tingkat pra-pemrosesan telah didefinisikan. Parameter tersebut tunduk pada proses pembersihan data yang diterapkan per kolom, dan kasus uji hanya berubah sebagai hasil dari pemisahan data, jika tidak, panjang data tetap konsisten. Ini pada dasarnya berarti bahwa tidak ada kehilangan data dalam analisis kumpulan sinyal. Variasi mengacu pada perubahan data berdasarkan aliran per level; ini menggambarkan perbedaan bentuk dan dimensi data dari pra-pemrosesan sebelumnya.

Algoritma pembelajaran terawasi adalah kategori teknik ML di mana model dilatih pada data berlabel, artinya data input memiliki label output yang sesuai. Kita telah melihat bahwa regresi linier digunakan untuk memprediksi nilai numerik kontinu. Regresi logistik memprediksi probabilitas hasil biner. Pohon keputusan membantu membuat keputusan berdasarkan serangkaian kondisi if-else yang berasal dari data pelatihan. Random forest adalah metode ensemble yang menggabungkan beberapa pohon keputusan untuk meningkatkan akurasi prediksi dan mengurangi overfitting. SVM menemukan hyperplane optimal yang memisahkan kelas dalam ruang berdimensi tinggi. KNN memprediksi nilai titik data baru berdasarkan kelas mayoritas dari K-tetangga terdekatnya. Kemudian ada naive bayes, yang menggunakan teorema Bayes untuk memprediksi probabilitas suatu kelas berdasarkan fitur input. Selain itu, gradient boosting machine menggabungkan weak learner secara berurutan untuk meningkatkan kinerja prediksi. Lebih lanjut, jaringan saraf mempelajari pola dan hubungan kompleks dalam data melalui lapisan node (neuron) yang saling terhubung.



Gambar 2.18 Dimensi data selama pra-pemrosesan.

Algoritma pembelajaran tanpa pengawasan digunakan untuk menemukan pola dan struktur dalam data di mana data tersebut tidak diberi label atau dikategorikan. Berikut ringkasan beberapa algoritma pembelajaran tanpa pengawasan yang populer: K-means membagi data menjadi cluster berdasarkan kesamaan. Pengelompokan hierarkis dimulai dengan setiap titik sebagai clusternya dan secara rekursif menggabungkan cluster berdasarkan jarak hingga semua titik termasuk dalam satu cluster. PCA mengurangi dimensi data sambil mempertahankan variansnya.

Kita juga memiliki t-distributed stochastic neighbour embedding; pengelompokan spasial berbasis kepadatan aplikasi dengan noise (DBSCAN); dan algoritma pembelajaran aturan asosiasi seperti algoritma a priori, yang mengidentifikasi himpunan item yang sering muncul dalam data transaksional; kemudian ada algoritma deteksi anomali dan model generatif. Terakhir, seperti yang telah kita lihat, dalam kasus algoritma pembelajaran terawasi, skor akurasi lebih tinggi dibandingkan dengan algoritma pembelajaran tak terawasi.

2.6 SINERGI CERDAS ANTARA ALGORITMA DAN TEKNOLOGI KELISTRIKAN

AI telah merevolusi pendekatan yang sudah mapan, mengoptimalkan sistem, dan merangsang inovasi dalam ilmu kelistrikan. Ini merupakan pergeseran paradigma. Aplikasi inovatif seperti sensor cerdas untuk pemantauan kondisi, robot otonom untuk tugas pemeliharaan, dan algoritma ML untuk perkiraan energi terbarukan dimungkinkan oleh pembahasan berbasis AI dalam ilmu kelistrikan. Penggunaan mutakhir ini tidak hanya memajukan profesi tetapi juga membantu memecahkan masalah sosial dan mendorong ekspansi ekonomi.




Meskipun ML dapat membantu manusia menjadi lebih cerdas di bidang-bidang tertentu, termasuk pengambilan keputusan dan identifikasi pola, kemampuannya untuk meningkatkan kecerdasan manusia secara umum masih dibatasi oleh perbedaan kognitif bawaan dan pertimbangan moral. Dalam hal ilmu kelistrikan, model ML dapat sangat membantu pengembangan objek dan perangkat efisien yang dapat menghasilkan masa depan yang lebih aman di mana pemborosan sumber daya dikurangi sementara penggunaan kembali dan umur pakai ditingkatkan.

Memilih platform bisa jadi sulit karena platform yang salah dapat meningkatkan biaya atau membatasi penggunaan alat atau teknologi bermanfaat lainnya. Seringkali ada kecenderungan untuk percaya bahwa sistem dengan lebih banyak fitur lebih unggul ketika mengevaluasi beberapa pernyataan masalah untuk memilih model ML. Mungkin, tetapi pertama-tama para peneliti harus mempertimbangkan apa yang akan dilakukan platform ML dengan data mereka dan output yang dihasilkan. Fitur mana yang penting untuk mencapai kemampuan ML yang diperlukan? Fungsionalitas seluruh sistem dapat hancur karena satu fitur yang hilang.

2.7 ETIKA DAN MASA DEPAN SOSIAL DUNIA DIGITAL

Dalam seluruh analisis teknis desain algoritma ML inti, kita harus membahas aspek ini untuk membantu pembahasan lebih lanjut. Sudah jelas bahwa manusia takut pada apa yang tidak dapat dikendalikannya. Dalam hal kecerdasan otomatis, bahkan dalam bidang ilmu kelistrikan, pertimbangan etika sama pentingnya dengan dampak ML pada masyarakat. Mari kita langsung membahas implikasi etika; sebagai permulaan, bias dan keadilan model ML tidak stabil, berdasarkan data yang digunakan untuk melatihnya. Kemudian ada kekhawatiran tentang kotak hitam ML dan akuntabilitas yang diperlukan untuk membuktikan kebenaran algoritma apa pun. Beralih ke area inti yang dibahas dalam buku ini, ekstraksi sumber daya dan keberlanjutan sangat mendasar bagi keberhasilan ML untuk material semikonduktor.

Terakhir, mengenai dampak sosial, dengan mengingat faktor ekonomi, kita harus memastikan bahwa pembahasan atau eksperimen selanjutnya di bidang ini berkembang, tetapi tanpa menghambat pertumbuhan, dalam hal geopolitik, keterjangkauan, dan kerangka peraturan. Penting untuk tidak melupakan fakta bahwa motif ML adalah untuk mengurangi kesenjangan digital dan bukan memperburuknya.



BAB 3

DETEKSI CACAT SEMIKONDUKTOR BERBASIS DATASET SECOM

3.1 PENDAHULUAN

Dalam dunia semikonduktor yang sangat kompetitif, efisiensi dan keandalan proses manufaktur merupakan faktor kunci. Produksi semikonduktor melibatkan serangkaian prosedur kompleks, masing-masing berpotensi menimbulkan kesalahan yang memengaruhi hasil produksi atau persentase produk yang memenuhi standar kualitas. Optimalisasi hasil produksi sangat penting karena secara langsung memengaruhi biaya, kualitas, dan profitabilitas keseluruhan perangkat semikonduktor. Mendeteksi dan menyelesaikan masalah selama tahap manufaktur dapat membantu mengurangi limbah, meningkatkan efisiensi produksi, dan mencegah pelepasan produk cacat.

Dataset SECOM telah diteliti secara menyeluruh di bidang identifikasi dan kategorisasi kesalahan. Dataset ini terdiri dari data yang dikumpulkan dari sensor yang digunakan dalam proses produksi. Setiap catatan dalam dataset menangkap momen waktu dari berbagai pengukuran sensor bersama dengan tag yang menunjukkan ada atau tidaknya cacat hasil produksi. Dengan lebih dari 1.500 instance dan lebih dari 590 atribut, dataset ini menghadirkan tantangan tetapi sangat bermanfaat untuk membuat dan menguji algoritma untuk deteksi cacat. Memeriksa dataset ini dapat menawarkan wawasan berharga tentang penyebab masalah hasil produksi dan membantu membangun model prediktif untuk mendeteksi kesalahan pada tahap awal.

Fokus bagian ini adalah untuk mengeksplorasi dataset SECOM secara khusus untuk mengidentifikasi cacat hasil produksi melalui penggunaan algoritma klasifikasi. Tujuan utamanya adalah untuk memeriksa dan memproses dataset SECOM, melakukan analisis data eksplorasi yang menyeluruh, menilai dan mengimplementasikan berbagai algoritma klasifikasi, mengevaluasi efektivitasnya, dan menganalisis hasilnya. Pencapaian tujuan ini akan menyoroti bagaimana analisis data yang canggih dan metode pembelajaran mesin dapat meningkatkan deteksi cacat dalam proses manufaktur semikonduktor, yang mengarah pada hasil produksi dan efisiensi operasional yang lebih baik.

3.2 MENANG DI PASAR GLOBAL DENGAN OPTIMASI PRODUKSI YANG CERDAS

Di sektor manufaktur semikonduktor, optimasi hasil produksi memainkan peran penting dalam menentukan produktivitas, profitabilitas, dan efektivitas biaya operasi produksi secara keseluruhan. Berikut adalah analisis menyeluruh tentang signifikansinya:

- a. **Dampak Ekonomi:** Hasil produksi secara langsung memengaruhi biaya produksi. Tingkat hasil produksi yang lebih tinggi mengurangi biaya per unit, karena persentase unit yang diproduksi lebih besar memenuhi standar kualitas. Sebaliknya, hasil produksi yang lebih rendah menyebabkan peningkatan biaya karena pemborosan dan pengerjaan ulang. Dengan mengoptimalkan hasil produksi, bisnis dapat secara



signifikan meningkatkan margin keuntungan mereka dan mendapatkan keunggulan kompetitif di pasar.

- b. **Efisiensi Sumber Daya:** Optimasi hasil produksi mendorong penggunaan sumber daya seperti tenaga kerja, material, dan energi. Lebih sedikit cacat menghasilkan lebih sedikit pemborosan material dan pengurangan pengerjaan ulang berarti menghemat sumber daya dan meminimalkan dampak lingkungan dari proses manufaktur.
- c. **Memastikan Kualitas:** Optimasi hasil produksi memastikan proporsi produk yang lebih besar memenuhi standar kualitas dan keandalan. Hal ini sangat penting di industri semikonduktor di mana kegagalan produk dapat secara signifikan memengaruhi kinerja dan keamanan perangkat elektronik.
- d. **Kepuasan Klien:** Hasil yang lebih baik dikaitkan dengan produk yang lebih konsisten dan berkualitas tinggi, yang meningkatkan kepuasan pelanggan. Barang yang andal mendorong hubungan jangka panjang dan meningkatkan kepercayaan konsumen, yang mendukung kesuksesan perusahaan yang berkelanjutan.
- e. **Keunggulan terhadap Persaingan:** Perusahaan yang mencapai hasil yang baik di sektor semikonduktor yang bergerak cepat dapat menawarkan produk dengan harga yang kompetitif tanpa mengorbankan kualitas. Kemampuan ini memungkinkan bisnis untuk merebut pangsa pasar, memberi mereka keunggulan kompetitif yang signifikan.
- f. **Litbang dan Inovasi:** Optimalisasi hasil memungkinkan pengalokasian kembali sumber daya ke arah inisiatif pembahasan dan pengembangan (Litbang). Dengan meminimalkan kerugian dan inefisiensi, perusahaan dapat menyalurkan lebih banyak dana ke arah kemajuan teknologi dan proses yang meningkatkan penawaran produk mereka dan memperkuat posisi kompetitif mereka.
- g. **Pengendalian Risiko:** Hasil yang tinggi mengurangi risiko yang terlibat dalam produksi. Ketika tingkat kesalahan lebih rendah, penarikan kembali dan klaim garansi, yang dapat mahal dan merusak reputasi perusahaan, menjadi lebih jarang. Optimalisasi hasil produksi berkontribusi pada proses produksi yang lebih tangguh dan konsisten.
- h. **Stabilitas Rantai Pasokan:** Meningkatkan hasil produksi meningkatkan keandalan rantai pasokan. Tingkat produksi yang stabil memastikan lebih sedikit gangguan, memungkinkan penjadwalan dan komunikasi yang lebih baik dengan pemasok dan klien. Konsistensi ini sangat penting untuk menjaga hubungan dengan pemasok dan memenuhi jadwal pengiriman.
- i. **Kepatuhan terhadap Peraturan:** Mematuhi peraturan sangat penting dalam industri semikonduktor. Kualitas yang konsisten diperlukan untuk memenuhi persyaratan peraturan dan menghindari masalah. Optimalisasi hasil produksi memainkan peran penting dalam mencapai hal ini.
- j. **Kemajuan Teknologi:** Memanfaatkan teknologi seperti kecerdasan buatan, pembelajaran mesin, dan analitik data seringkali penting untuk mengoptimalkan hasil produksi. Teknologi ini tidak hanya meningkatkan hasil produksi tetapi juga mendorong kemajuan teknologi secara keseluruhan di dalam perusahaan, memposisikannya sebagai inovator di bidangnya.



Singkatnya, memaksimalkan hasil produksi semikonduktor sangat penting untuk menjaga rantai pasokan yang stabil, memenuhi standar peraturan, mendorong inovasi, memastikan efektivitas biaya, menghemat sumber daya, menjaga kontrol kualitas, meningkatkan kepuasan pelanggan, mendapatkan keunggulan kompetitif, dan mendorong kemajuan teknologi. Dengan memprioritaskan optimasi hasil produksi, perusahaan dapat meningkatkan efisiensi dan posisinya di pasar secara signifikan.

3.3 TANTANGAN MENJAGA KEMURNIAN DAN KUALITAS DI RUANG PRODUKSI

Hasil produksi dalam manufaktur semikonduktor dapat sangat dipengaruhi oleh masalah dan kesalahan umum, yang menyebabkan peningkatan biaya produksi dan penurunan efisiensi. Salah satu tantangan utama adalah adanya pengotor atau ketidakberaturan dalam material seperti wafer silikon, yang dapat mengakibatkan cacat pada produk akhir. Misalnya, pengotor dapat menyebabkan variasi kekerasan yang berdampak pada kualitas keseluruhan perangkat semikonduktor. Faktor penting lainnya adalah konsistensi proses manufaktur. Bahkan fluktuasi kecil dalam suhu, tekanan, atau konsentrasi kimia dapat menyebabkan ketidakteraturan dan cacat pada perangkat semikonduktor. Variasi ini dapat terjadi pada berbagai tahap proses manufaktur, seperti produksi wafer, pengujian wafer, perakitan atau pengemasan, dan pengujian akhir, yang masing-masing menghadirkan serangkaian peluang dan tantangan tersendiri.

Ketika mesin mengalami malfungsi, hal itu dapat menyebabkan komponen yang rusak atau ketidakmampuan untuk mempertahankan kondisi yang tepat yang diperlukan untuk produksi berkualitas tinggi, sehingga mengakibatkan penurunan output. Situasi ini dapat diperburuk oleh kompleksitas dan biaya peralatan seperti mesin litografi canggih, yang membuat perawatan dan penggantian menjadi sulit. Bahkan sejumlah kecil kontaminasi dari zat atau partikel dalam lingkungan ruang bersih dapat berdampak buruk pada kualitas perangkat semikonduktor. Kontaminasi ini dapat terjadi selama berbagai tahap manufaktur, seperti doping, etsa, dan deposisi, dan dapat menjadi tantangan untuk dideteksi dan dihilangkan. Jika desain menyimpang dari standar kinerja, cacat pada sirkuit semikonduktor atau tata letak dapat menyebabkan kegagalan dan berdampak pada produktivitas. Masalah-masalah ini dapat sulit diidentifikasi dan diperbaiki, sehingga memerlukan pendekatan diagnostik.

Cacat dalam proses produksi dapat disebabkan oleh kesalahan seperti pengaturan atau penanganan peralatan yang tidak tepat. Untuk meminimalkan risiko ini, operator dapat dilatih secara ketat, dan langkah-langkah pengendalian mutu dapat diimplementasikan untuk memastikan kepatuhan terhadap standar dan protokol. Selain itu, prosedur pengujian dan inspeksi yang tidak memadai dapat mengabaikan cacat pada produk pada tahap awal, sehingga memungkinkan produk tersebut untuk melanjutkan proses lebih lanjut di jalur produksi dan mengurangi output keseluruhan.

Hal ini menyoroti pentingnya memiliki sistem pengendalian mutu yang kuat dan teknik diagnostik canggih untuk meminimalkan kesalahan dan mengoptimalkan hasil produksi semikonduktor. Terakhir, seiring bertambahnya usia dan keausan peralatan produksi dari



waktu ke waktu, kinerjanya dapat menurun, yang berdampak pada kualitas dan konsistensi output. Peningkatan pemeliharaan rutin dan penggantian peralatan dapat mengatasi masalah ini dengan memastikan bahwa mesin terus beroperasi dengan spesifikasi yang tepat.

Untuk mengatasi tantangan dalam produksi semikonduktor, protokol pengendalian mutu yang ketat, pemantauan berkelanjutan, dan teknik diagnostik canggih sangat penting. Perusahaan seperti Brewer Science mengadopsi pendekatan seperti metrologi dan sidik jari untuk mengurangi cacat material dan kontaminan, memastikan perangkat semikonduktor dengan peningkatan hasil, kinerja, konsistensi, dan keandalan.

Mengatasi masalah ini membutuhkan strategi yang mencakup langkah-langkah pengendalian mutu, pengawasan rutin terhadap kondisi manufaktur, perawatan rutin, dan prosedur pengujian komprehensif. Selain itu, metode diagnostik canggih dapat digunakan untuk mengidentifikasi dan menyelesaikan masalah yang memengaruhi hasil produksi, meningkatkan efisiensi dan keandalan proses manufaktur semikonduktor. Contoh penting dari metode ini termasuk sistem pemantauan dan deteksi kesalahan berbasis pembelajaran mesin.

3.4 DATASET SECOM DAN PERANNYA DALAM INOVASI MANUFAKTUR

Dataset yang umum digunakan untuk mendeteksi dan mengklasifikasikan cacat dalam pembahasan dan pengembangan manufaktur semikonduktor adalah dataset SECOM. Dataset ini berasal dari proses manufaktur semikonduktor di mana sensor mengumpulkan beberapa jenis data yang terkait dengan produksi perangkat semikonduktor. Proyek SECOM bertujuan untuk meningkatkan pengetahuan dan mengoptimalkan proses manufaktur di industri semikonduktor agar dataset ini dapat diakses.

Dataset ini terdiri dari pembacaan yang diperoleh pada berbagai tahap proses produksi. Pembacaan ini mencakup banyak faktor, seperti tekanan, suhu, konsentrasi kimia, dan variabel lainnya. Untuk memberikan gambaran umum tentang lingkungan industri, pengukuran ini diambil secara berkala.

Dalam data terstruktur, setiap entri sesuai dengan batch atau proses produksi perangkat semikonduktor. Dataset ini mencakup pembacaan sensor yang direkam untuk setiap entri beserta label yang menunjukkan apakah cacat terdeteksi dalam hasil produksi untuk batch tertentu.

Label ini sangat penting untuk melatih model klasifikasi, karena memberikan variabel target yang ingin diprediksi oleh algoritma. Untuk mempermudah analisis, dataset biasanya dibagi menjadi beberapa segmen seperti subset pelatihan dan pengujian. Model pembelajaran mesin dikembangkan dan disempurnakan menggunakan set pelatihan, dan kinerjanya pada data yang belum pernah dilihat sebelumnya dievaluasi menggunakan set pengujian. Pembagian ini memungkinkan para peneliti untuk menilai seberapa baik model mereka dapat digeneralisasikan ke dataset baru yang belum diuji.

Dataset SECOM memberikan wawasan tentang proses manufaktur, yang mencakup skenario rutin dan menantang. Hal ini menjadikannya berharga untuk mengembangkan dan mengakses algoritma untuk deteksi kesalahan. Dengan memanfaatkan dataset ini, para peneliti dapat menggunakan metode pembelajaran mesin, seperti deteksi anomali dan



klasifikasi, untuk mengungkap pola yang terkait dengan masalah dan meningkatkan ketepatan prediksi mereka.

Secara keseluruhan, dataset SECOM berfungsi sebagai sumber daya untuk menyempurnakan metode deteksi cacat di sektor manufaktur semikonduktor. Beragam fitur dan relevansinya dengan dunia nyata menjadikannya tolok ukur untuk mengevaluasi berbagai analisis data dan teknik pembelajaran mesin dalam domain ini.

3.5 TEKNIK KUNCI DALAM MENJAGA KELANCARAN PRODUKSI

Identifikasi kesalahan berperan penting dalam mempertahankan tingkat hasil produksi yang tinggi dan memastikan kualitas produk di industri semikonduktor. Berbagai pendekatan dan algoritma digunakan untuk mendeteksi dan memperbaiki kesalahan dalam proses produksi. Berikut adalah pemeriksaan menyeluruh tentang berbagai metode penting dan algoritma yang banyak diterapkan untuk deteksi kesalahan, beserta analisis efektivitasnya:

Kontrol Proses Statistik

Kontrol proses statistik (SPC) adalah pendekatan penting untuk memanfaatkan metode untuk mengawasi dan mengatur proses manufaktur. SPC memeriksa data yang dikumpulkan dari proses untuk mengidentifikasi variasi dan tren yang mungkin menunjukkan potensi masalah. Alat yang umum digunakan dalam SPC meliputi:

- **Bagan Kontrol:** Bagan ini melacak kinerja suatu proses dari waktu ke waktu dan membantu mengidentifikasi penyimpangan dari perilaku yang diharapkan. Bagan ini membantu menentukan apakah perbedaan tersebut disebabkan oleh penyebab yang menunjukkan potensi masalah atau penyebab umum yang melekat pada proses tersebut.
- **Analisis Pareto:** Berdasarkan prinsip Pareto (aturan 80/20), yang menyatakan bahwa 80% masalah sering disebabkan oleh 20% komponen, teknik ini menentukan faktor-faktor paling signifikan yang menyebabkan kesalahan.

Efektivitas: SPC efektif dalam memantau proses dan mendeteksi penyimpangan pada setiap tahap. Namun, SPC mungkin menghadapi tantangan dalam mengidentifikasi kesalahan yang halus atau kompleks yang memerlukan metode analisis yang lebih canggih.

3.6 EMPAT ALGORITMA ANDALAN DALAM DUNIA MACHINE LEARNING

Pohon Keputusan

Algoritma klasifikasi yang populer untuk mensimulasikan keputusan dan hasilnya adalah pohon keputusan. Pohon keputusan merupakan alat yang berguna dalam deteksi masalah, karena dapat digunakan untuk mengkategorikan batch produksi berdasarkan berbagai fitur.

- **Algoritma:** Pohon keputusan bekerja dengan membagi dataset menjadi kelompok-kelompok yang lebih kecil sesuai dengan nilai fitur-fiturnya. Proses ini menghasilkan struktur yang menyerupai pohon yang mewakili berbagai pilihan.
- **Contoh:** Dengan menggunakan parameter proses dan pembacaan sensor, pohon keputusan dapat mengidentifikasi batch sebagai rusak atau tidak.



Efektivitas: Meskipun pohon keputusan mudah dipahami dan lugas, pohon keputusan dapat menjadi terlalu kompleks dan rentan terhadap overfitting jika tidak dipangkas dengan tepat.

Random Forest

Random forest menggunakan teknik untuk meningkatkan presisi dan ketahanan klasifikasi dengan menggabungkan beberapa pohon keputusan.

- **Algoritma:** Algoritma ini membangun beberapa pohon keputusan menggunakan subset fitur acak dan menggabungkan prediksinya untuk membuat keputusan akhir.
- **Contoh:** Random forest dapat mengelola dataset besar dan mengidentifikasi pola kompleks dengan menggabungkan prediksi dari berbagai pohon keputusan.

Efektivitas: Random forest memberikan akurasi tinggi dan kurang rentan terhadap overfitting dibandingkan dengan pohon keputusan individual. Random forest juga mampu menangani nilai yang hilang dan data yang bising dengan baik.

Mesin Vektor Pendukung

Mesin vektor pendukung (SVM) adalah teknik klasifikasi yang ampuh yang digunakan untuk menemukan batas optimal yang memisahkan kelas yang berbeda dalam ruang fitur.

- **Algoritma:** SVM membangun hyperplane yang memaksimalkan margin antara kelas yang berbeda.
- **Contoh:** SVM dapat digunakan untuk mengklasifikasikan batch berdasarkan data sensor dengan menemukan batas terbaik yang memisahkan sampel yang rusak dan tidak rusak.


Efektivitas: SVM efektif dalam ruang berdimensi tinggi dan untuk dataset yang kompleks. Namun, SVM dapat membutuhkan komputasi yang intensif dan memerlukan penyetelan parameter yang cermat.

Jaringan Neural

Model pembelajaran mendalam, khususnya, yang digunakan untuk pengenalan pola yang rumit dan tugas deteksi kesalahan, adalah jaringan neural. Jaringan neural terdiri dari beberapa lapisan node jaringan, atau neuron, yang dapat mengenali karakteristik hierarkis dalam data.

- **Algoritma:** Mereka belajar dengan menyesuaikan bobot melalui backpropagation untuk meminimalkan kesalahan antara label yang diprediksi dan label sebenarnya.
- **Contoh:** Mereka digunakan oleh jaringan saraf untuk meminimalkan kesalahan antara label yang diharapkan dan label sebenarnya dengan belajar melalui penyesuaian bobot backpropagation.

Efektivitas: Dalam hal menemukan pola dan koneksi yang rumit dalam dataset besar, jaringan saraf berkinerja sangat baik. Namun, mereka membutuhkan sejumlah besar data pelatihan dan daya pemrosesan yang substansial.



3.7 DUA TEKNIK UTAMA UNTUK MENEMUKAN DATA YANG TIDAK NORMAL

Analisis Komponen Utama

Analisis komponen utama (PCA) adalah teknik pengurangan dimensi yang juga dapat digunakan untuk deteksi anomali dengan mengidentifikasi outlier dalam ruang komponen utama.

- **Algoritma:** PCA memproyeksikan data ke ruang berdimensi lebih rendah (komponen utama) dan menemukan outlier berdasarkan jaraknya dari rata-rata dalam ruang yang dikurangi ini.
- **Contoh:** PCA dapat mendeteksi anomali dalam data sensor dengan menemukan penyimpangan dari komponen utama yang mewakili perilaku proses normal.

Efektivitas: PCA berguna untuk mengurangi dimensi dan mengidentifikasi anomali dalam dataset besar. Namun, PCA mengasumsikan hubungan linier dan mungkin tidak dapat menangkap anomali kompleks.

Hutan Isolasi

Teknik deteksi anomali yang disebut hutan isolasi membagi data dan memilih fitur secara acak untuk memisahkan anomali

- **Algoritma:** Dengan membangun kumpulan pohon isolasi, algoritma menentukan anomali dengan mengukur seberapa mudahnya mengisolasi anomali tersebut dari data yang tersisa.
- **Contoh:** Hutan isolasi dapat mendeteksi batch yang salah dengan mengidentifikasi instance yang mudah dipisahkan dari sebagian besar data normal.


Efektivitas: Mengidentifikasi anomali dalam dataset berdimensi tinggi dapat dilakukan secara efektif dan efisien dengan hutan isolasi. Metode ini bekerja efektif dengan dataset besar dan tidak memerlukan asumsi apa pun tentang distribusi data.

3.8 PENDEKATAN HIBRIDA UNTUK MASA DEPAN PRODUKSI CHIP

Metode hibrida menggabungkan berbagai pendekatan untuk memanfaatkan keunggulan dan mengatasi kekurangannya. Misalnya, menggabungkan algoritma pembelajaran mesin dengan teknik statistik dapat meningkatkan efektivitas deteksi kesalahan.

Efektivitas: Dengan menggabungkan banyak teknik, pendekatan hibrida dapat menawarkan deteksi cacat yang lebih andal dan tepat; Meskipun demikian, mereka mungkin memerlukan kalibrasi dan implementasi yang lebih rumit.

Singkatnya, ada beberapa metode dan algoritma yang digunakan dalam produksi semikonduktor untuk deteksi kesalahan, masing-masing memiliki kelebihan dan kekurangan. Sementara algoritma pembelajaran mesin memungkinkan pengenalan dan klasifikasi pola yang lebih canggih, teknik statistik seperti SPC menawarkan kemampuan pemantauan mendasar. Teknik untuk mendeteksi anomali membantu dalam menemukan pola aneh yang mungkin menunjukkan masalah. Produsen dapat meningkatkan hasil dan efisiensi proses dengan menggabungkan teknik-teknik ini untuk meningkatkan kemampuan mereka dalam mengidentifikasi dan memperbaiki cacat.



3.9 TAHAP KRUSIAL PRA-PEMROSESAN DATA SEMIKONDUKTOR

Analisis Rinci Dataset Secom

Dataset SECOM berisi banyak informasi dari proses manufaktur semikonduktor untuk membantu optimasi hasil dan deteksi masalah. Dataset ini terdiri dari total 1.567 entri, masing-masing mewakili batch atau peristiwa produksi yang unik. Sampel-sampel ini dicirikan oleh 591 atribut, yang mencakup variabel, metrik turunan yang terkait dengan proses manufaktur, dan pembacaan sensor. Selain variabel spesifik dan metrik yang dihitung, fitur-fitur tersebut mencakup data kontinu dari sensor yang memantau berbagai faktor, seperti suhu, tekanan, dan konsentrasi kimia. Variabel target dataset bersifat biner dengan -1 menunjukkan lulus dan 1 menunjukkan gagal, sehingga menunjukkan apakah setiap batch berhasil melewati pengujian kualitas.

Analisis ini mendapatkan lapisan kedalaman tambahan melalui stempel waktu yang terlampir pada setiap entri dalam dataset SECOM yang mengungkapkan kapan data dikumpulkan. Stempel waktu ini sangat berharga untuk melacak peristiwa dan mengidentifikasi tren yang dapat memengaruhi hasil. Dalam dataset, pengamatan awal sering kali menyajikan campuran distribusi fitur, dengan beberapa menunjukkan fluktuasi yang signifikan tetapi yang lain tetap stabil. Untuk meningkatkan akurasi model, sangat penting untuk mengidentifikasi dan mengatasi komponen dengan varians atau tingkat kebisingan yang menonjol.

Selain itu, analisis dapat mengungkap nilai yang hilang dalam fitur tertentu yang memerlukan penanganan yang cermat untuk menghindari distorsi hasil. Selain itu, dataset mungkin menunjukkan ketidakseimbangan antar kelas, dengan jumlah batch yang gagal jauh lebih kecil dibandingkan dengan yang berhasil. Ketidakseimbangan ini dapat menghambat kinerja algoritma, sehingga memerlukan teknik seperti fungsi kerugian berbobot atau resampling untuk mencapai prediksi yang lebih tepat.

Dengan mempertimbangkan semuanya, dataset SECOM memberikan wawasan tentang proses manufaktur semikonduktor dan informasi berharga mengenai faktor-faktor yang memengaruhi hasil produksi. Dengan memanfaatkan data ini dan menerapkan pemilihan fitur dan teknik pra-pemrosesan yang tepat, para peneliti dan insinyur dapat mengembangkan model yang kuat yang meningkatkan deteksi cacat dan mengoptimalkan proses manufaktur.

Pra-Pemrosesan Data

Dalam ranah persiapan data untuk deteksi cacat dalam manufaktur semikonduktor, beberapa pendekatan kunci digunakan untuk memastikan dataset siap untuk dianalisis. Strategi ini mencakup pengisian nilai yang hilang, penghapusan fitur yang tidak perlu, dan penanganan nilai nol dan NaN (bukan angka). Berikut adalah uraian rinci tentang aktivitas pra-pemrosesan ini:

- a. **Menangani Nilai Nol dan NaN:** Nilai nol dan NaN dalam dataset dapat menandakan informasi yang tidak lengkap atau salah. Mengingat potensi dampaknya terhadap kualitas analisis, sangat penting untuk menilai keberadaannya dan menanganinya dengan tepat. Untuk mengatasi hal ini, kita mulai dengan mengidentifikasi kemunculan nilai nol dan NaN di setiap kolom dataset. Proses ini melibatkan penghitungan jumlah



nilai-nilai ini untuk setiap fitur untuk menentukan apakah ada kolom yang berisi data yang tidak akurat atau hilang. Menilai frekuensi nilai-nilai ini berperan dalam menginformasikan langkah-langkah selanjutnya untuk pembersihan data.

- b. **Menghapus Kolom Konstan:** Beberapa kolom dalam dataset mungkin memiliki nilai yang sama di semua baris. Karena kurangnya keragaman, kolom-kolom ini tidak berkontribusi untuk membedakan antara hasil atau kategori yang berbeda, sehingga tidak cocok untuk analisis. Untuk meningkatkan efektivitas dataset, kolom dengan entri yang identik dihapus. Proses ini melibatkan pengecekan apakah semua nilai dalam sebuah kolom identik. Jika sebuah kolom memenuhi kriteria ini, kolom tersebut dikeluarkan dari dataset. Langkah ini dapat meningkatkan efisiensi analisis selanjutnya atau model pembelajaran mesin dengan mengurangi kompleksitas dan menghilangkan informasi yang tidak relevan.
- c. **Mengisi Nilai yang Hilang:** Nilai yang hilang dalam dataset menimbulkan tantangan yang perlu diatasi untuk analisis yang menyeluruh. Langkah pertama dalam mengatasi nilai yang hilang adalah mengidentifikasi kolom dengan jumlah data yang hilang yang signifikan. Biasanya, kolom dengan persentase nilai yang hilang lebih tinggi daripada ambang batas yang ditetapkan akan dibuang, karena mungkin tidak memberikan informasi yang dapat diandalkan.

Untuk mengatasi nilai yang hilang dalam dataset, teknik imputasi digunakan untuk kolom yang tersisa. Salah satu pendekatan yang umum digunakan melibatkan penggunaan rata-rata atau median dari nilai yang ada dalam sebuah kolom untuk mengganti angka yang hilang. Rata-rata memberikan ukuran kecenderungan, sedangkan median menawarkan metrik yang kurang dipengaruhi oleh outlier.

Memastikan bahwa setiap fitur memiliki imputasi nilai membantu menjaga integritas dataset. Metode pra-pemrosesan ini memainkan peran penting dalam mempersiapkan data untuk analisis. Dengan menangani nilai nol dan NaN, menghilangkan fitur yang tidak informatif, dan mengisi nilai yang hilang, dataset disempurnakan dan dibuat lebih kondusif untuk menghasilkan wawasan dan prediksi yang dapat dipercaya.

Teknik Pemilihan Fitur

Komponen kunci dari persiapan data adalah pemilihan fitur, yang menemukan fitur yang paling relevan untuk meningkatkan kinerja model pembelajaran mesin. PCA, pemilihan berbasis varians, dan pemilihan berbasis model adalah beberapa metode yang digunakan. Berikut adalah uraian lengkap dari setiap teknik:

1. **Pemilihan Fitur Berbasis Varians:** Teknik VarianceThreshold digunakan untuk menghilangkan fitur dengan varians rendah. Fitur-fitur ini cenderung tetap konsisten di seluruh sampel, sehingga dampaknya terhadap kemampuan prediksi model minimal. Dengan menetapkan ambang batas, pendekatan ini menghilangkan atribut yang tidak memenuhi kriteria varians. Tujuannya adalah untuk mempertahankan hanya elemen-elemen yang menunjukkan variasi yang cukup untuk menjadi berharga. Misalnya, sebuah fitur akan dihapus dari dataset jika variansnya di bawah ambang



batas yang ditentukan. Metode ini mengurangi dimensi data dan menghilangkan noise yang tidak perlu.

2. **Pemilihan Fitur Berbasis Model:** Pendekatan ini memanfaatkan efektivitas model pembelajaran mesin untuk menilai signifikansi setiap fitur. Model-model berikut digunakan untuk tujuan ini.
 - **Support Vector Classifier (SVC):** Pendekatan ini menggunakan penalti L1 untuk membantu memilih fitur-fitur penting. Ia bergantung pada vektor pendukung untuk menemukan fitur yang paling relevan. Signifikansi fitur ditunjukkan melalui koefisien model, dan fitur yang memiliki koefisien akan dipilih.
 - **Regresi Logistik:** Model ini melihat bagaimana fitur-fitur terkait dengan variabel target. Fitur dengan koefisien dianggap lebih penting. Dengan menerapkan `SelectFromModel` bersama dengan regresi logistik, ia memilih fitur-fitur yang memiliki kepentingan besar.
 - **Pengklasifikasi Pohon Keputusan:** Pohon keputusan mengevaluasi signifikansi fitur berdasarkan seberapa efektif fitur tersebut membagi data. Fitur yang menghasilkan pemisahan dianggap lebih signifikan. Pengklasifikasi `ExtraTrees`, yang merupakan jenis pohon keputusan, menggabungkan hasil dari beberapa pohon untuk menentukan pemilihan fitur.
3. **Analisis Komponen Utama:** PCA adalah teknik yang digunakan untuk mengurangi dimensi data dengan mentransformasikannya ke dalam sistem koordinat baru. Dalam sistem ini, penyimpangan terbesar dalam proyeksi data sejajar dengan komponen utama awal. PCA mencapai hal ini dengan meminimalkan fitur sambil mempertahankan sebagian besar variabilitas dataset asli. Proses ini melibatkan proyeksi data ke komponen yang berasal dari kombinasi linier fitur asli. Hasilnya adalah sekumpulan komponen atau fitur yang tidak berkorelasi yang menangkap sebagian besar varians data.

Singkatnya, penggunaan metode seleksi seperti seleksi berdasarkan varians, seleksi berbasis model, dan PCA sangat penting untuk meningkatkan efektivitas dan efisiensi model pembelajaran. Pendekatan ini dapat meningkatkan kinerja model, menyoroti aspek-aspek kunci, dan menyederhanakan kompleksitas data.

Oversampling Untuk Dataset Yang Tidak Seimbang

Dalam tugas klasifikasi, dataset sering kali mengalami ketidakseimbangan, di mana satu kelas jauh lebih besar daripada kelas lainnya. Ketidakseimbangan ini dapat menyebabkan model cenderung condong ke kelas mayoritas, sehingga menghasilkan kinerja yang bias dan prediksi akurasi yang buruk untuk kelas minoritas. Untuk mengatasi masalah ini, teknik oversampling seperti teknik oversampling minoritas sintetis (SMOTE) digunakan untuk menyeimbangkan distribusi kelas. SMOTE memungkinkan pembuatan sampel khusus untuk kelas yang kurang terwakili dalam suatu dataset. Alih-alih hanya menduplikasi instance kelas minoritas yang ada, SMOTE menghasilkan sampel sintetis baru melalui interpolasi antara titik data yang ada. Proses ini melibatkan pemilihan titik dan pembuatan sampel tambahan di sepanjang garis yang menghubungkan titik-titik ini ke instance tetangganya.



Dengan demikian, SMOTE secara efektif meningkatkan representasi kelas minoritas, sehingga menghasilkan dataset yang lebih seimbang secara keseluruhan. Untuk menentukan bagaimana kelas didistribusikan, pendekatan ini dimulai dengan memeriksa dataset awal. Dalam kasus ketidakseimbangan, kelas minoritas mungkin kurang terwakili, yang menyebabkan model yang cacat. Selanjutnya, SMOTE diterapkan pada dataset untuk menghasilkan contoh tambahan dari kelas minoritas. Penyesuaian ini membantu menciptakan fondasi untuk pelatihan dengan menyeimbangkan jumlah sampel di seluruh kelas. Dataset yang dimodifikasi, dengan jumlah sampel yang sama untuk setiap kelas setelah SMOTE, digunakan untuk analisis lebih lanjut atau pelatihan model. Keseimbangan ini meningkatkan kinerja model dan mengurangi bias dengan meningkatkan kemampuannya untuk melakukan generalisasi di semua kelas. Dengan dukungan sampel sintetis yang baru dihasilkan, model memperoleh wawasan tentang kelas minoritas, meningkatkan akurasi prediksi dan ketahanan secara keseluruhan.

SMOTE adalah pendekatan untuk mengatasi kelas yang tidak seimbang dalam dataset. Dengan menghasilkan contoh, ia memastikan bahwa model dilatih pada dataset, yang mengarah pada peningkatan kinerja untuk kelas mayoritas dan minoritas. Teknik ini sangat penting untuk mengembangkan model yang tidak bias dan tepat, terutama dalam skenario di mana hasil dapat dipengaruhi secara signifikan oleh ketidakseimbangan kelas.

3.10 MEMBACA PETA KEBERHASILAN MODEL DALAM MENDETEKSI KERUSAKAN Pelatihan Dan Pengujian Model

Proses evaluasi model dimulai dengan melatih model klasifikasi pada sebuah dataset. Dalam hal ini, kita menggunakan pengklasifikasi random forest, yang menggabungkan beberapa pohon keputusan dan menggabungkan hasilnya untuk meningkatkan akurasi dan keandalan. Kita membagi dataset menjadi bagian pelatihan dan pengujian menggunakan ukuran pengujian yang telah ditentukan, memastikan kita dapat menilai model pada data yang belum pernah dilihat sebelumnya.

Setelah kita melatih model, kita membuat prediksi pada set pengujian. Kemudian kita mengukur kinerja model menggunakan akurasi, yang menunjukkan berapa banyak prediksi yang benar dari semua prediksi yang dibuat. Fungsi pengklasifikasi mengembalikan model yang telah dilatih, prediksi, label aktual, dan skor akurasi.

Perhitungan Matriks Konfusi

Matriks konfusi membantu kita memeriksa seberapa baik model klasifikasi bekerja. Matriks ini menguraikan tebakan model secara detail, menunjukkan true positive, true negative, false positive, dan false negative. Untuk mengetahui angka-angka ini, fungsi `'confusion_matrix'` membandingkan label yang diprediksi model dengan label sebenarnya. Berikut cara matriks kebingungan disusun:

- **True Positives (TP):** Kasus di mana model memprediksi kelas positif dengan benar.
- **True Negatives (TN):** Kasus di mana model memprediksi kelas negatif dengan benar.
- **False Positives (FP):** Kasus di mana model memprediksi kelas positif secara salah.
- **False Negatives (FN):** Kasus di mana model memprediksi kelas negatif secara salah.



Nilai-nilai ini digunakan untuk membangun matriks yang secara visual mewakili kinerja model.

Visualisasi Matriks Kebingungan

Untuk memahami matriks kebingungan dengan lebih baik, kita menampilkannya sebagai peta panas. Fungsi `plot_confusion_matrix` membuat visual ini. Peta panas memberi kita gambaran yang jelas tentang seberapa baik model bekerja. Setiap kotak dalam matriks menunjukkan berapa kali model memprediksi suatu kelas dibandingkan dengan kelas sebenarnya.


Kita dapat menampilkan matriks dengan atau tanpa normalisasi. Normalisasi mengubah nilai menjadi persentase, yang membantu saat membandingkan dataset atau model yang berbeda. Fungsi ini menggunakan warna untuk memperjelas, dan menempatkan angka pasti di setiap kotak untuk detail lebih lanjut.

Sebagai penutup, evaluasi model melibatkan tiga langkah: melatihnya, mendapatkan prediksinya, dan memeriksa seberapa baik model tersebut menggunakan matriks kebingungan. Matriks ini menjelaskan apa yang dilakukan model dengan baik dan di mana kekurangannya. Melihatnya memudahkan pemahaman hasil. Metode ini memberi kita gambaran lengkap tentang seberapa baik model klasifikasi dan memastikan evaluasi komprehensif terhadap kinerja model klasifikasi.

Pemilihan Fitur Dan Klasifikasi

Langkah pertama dalam proses ini adalah menyiapkan dataset. Ini melibatkan pembersihan data yang hilang. Selanjutnya, kita menggunakan SVC untuk memilih fitur. SVC menemukan dan menyimpan ciri-ciri terpenting untuk pengurutan. Setelah itu, kita menyeimbangkan fitur yang dipilih menggunakan SMOTE. Kita melakukan ini untuk memperbaiki ketidakseimbangan kelas dalam dataset. Langkah ini memastikan pengklasifikasi memiliki dataset yang seimbang untuk digunakan.


Pengklasifikasi random forest, yang dilatih pada data yang seimbang, mengklasifikasikan sampel. Untuk mengevaluasi kinerja model, kita menghitung skor akurasi dan menganalisis data menggunakan matriks kebingungan. Matriks ini, yang kita visualisasikan dengan normalisasi, memberi kita wawasan tentang kekuatan dan kelemahan model dengan menunjukkan true positive, true negative, false positive, dan false negative. Penilaian menyeluruh ini membantu kita memahami seberapa baik model bekerja dan menemukan area yang dapat kita perbaiki. Gambar 3.1 mengilustrasikan matriks kebingungan yang dinormalisasi untuk pemilihan fitur SVC dengan klasifikasi random forest.



Gambar 3.1 Matriks kebingungan yang dinormalisasi untuk pemilihan fitur SVC dengan klasifikasi random forest.


Dengan cara yang sama, setelah kita menyiapkan dan membersihkan dataset, kita menggunakan pengklasifikasi logistik untuk memilih fitur terbaik. Pengklasifikasi ini memeriksa fitur mana yang paling mungkin memprediksi hasilnya, yang membantu kita mempersempit dataset ke variabel yang paling berguna. Setelah itu, kita menyeimbangkan dataset lagi menggunakan SMOTE. Ini memastikan pengklasifikasi belajar dari penyebaran kelas yang merata.

Dataset yang seimbang berfungsi sebagai input untuk melatih pengklasifikasi random forest. Kita mengukur kinerja pengklasifikasi menggunakan akurasi dan membuat matriks kebingungan yang dinormalisasi untuk menilai kemampuan klasifikasi model. Matriks kebingungan, yang kita visualisasikan dengan normalisasi, menunjukkan seberapa baik model membedakan antar kelas, termasuk true positive, true negative, false positive, dan false negative. Evaluasi ini memberi kita gambaran yang jelas tentang bagaimana kinerja model dan menunjukkan area yang dapat kita tingkatkan dan optimalkan. Matriks kebingungan yang dinormalisasi untuk pemilihan fitur logistik dengan klasifikasi random forest ditunjukkan pada Gambar 3.2.



Gambar 3.2 Matriks kebingungan yang dinormalisasi untuk pemilihan fitur logistik dengan klasifikasi random forest.

Model pohon keputusan membantu memilih fitur-fitur kunci setelah dataset siap dan dibersihkan. Metode ini memeriksa seberapa penting berbagai sifat, sehingga lebih mudah untuk menemukan sifat-sifat yang paling penting untuk memprediksi hasil. Dengan berfokus pada faktor-faktor yang paling berpengaruh, proses klasifikasi menjadi lebih produktif dan efektif, berkat fitur-fitur yang dipilih.



Gambar 3.3 Matriks kebingungan yang dinormalisasi untuk pemilihan fitur pohon keputusan dengan klasifikasi hutan acak.

Setelah memilih fitur, kami mengatasi penyebaran kelas yang tidak merata dengan menyeimbangkan dataset menggunakan SMOTE. Langkah penyeimbangan ini memastikan pengklasifikasi hutan acak belajar dari jumlah kelas yang sama, yang merupakan kunci untuk membangun model yang dapat dipercaya dan adil.

Setelah itu, kami menggunakan dataset yang seimbang ini untuk melatih pengklasifikasi hutan acak. Kami menggunakan matriks kebingungan yang dinormalisasi untuk memvisualisasikan seberapa akurat model tersebut, yang membantu kami mengevaluasi kinerjanya. Matriks ini memberi kita analisis menyeluruh tentang seberapa baik kinerja pengklasifikasi, menunjukkan kepada kita jumlah positif palsu, negatif palsu, positif sejati, dan negatif sejati. Dengan menormalisasi matriks kebingungan, kita dapat membandingkan kinerja model di berbagai kelas dengan lebih mudah, yang membantu kita mengidentifikasi di mana model tersebut unggul dan di mana ia kurang baik. Gambar 3.3 menyoroti matriks



kebingungan yang dinormalisasi untuk pemilihan fitur pohon keputusan dengan klasifikasi hutan acak.

3.11 STRATEGI ANTARA SVC, LOGISTIK, DAN POHON KEPUTUSAN

Menganalisis berbagai metode pemilihan fitur dan klasifikasi menggunakan dataset SECOM memberi kita wawasan baru tentang efektivitasnya dalam mendeteksi cacat pada manufaktur semikonduktor. Kami menerapkan SVC, regresi logistik, dan pohon keputusan untuk memilih fitur dan kemudian menggunakan model random forest untuk mengklasifikasikannya. Pendekatan ini membantu kami memperoleh pemahaman mendalam tentang bagaimana berbagai teknik memengaruhi kinerja.

Model random forest menjadi lebih baik dalam memilih data ketika kita memangkas data hanya ke bagian-bagian kunci, menggunakan SVC untuk memilih apa yang paling penting. Melihat hasilnya secara jelas menunjukkan bahwa model tersebut bagus dalam membedakan lulus dari gagal, yang berarti cara SVC dalam memilih apa yang akan dilihat membuat model bekerja lebih baik. Dengan mengidentifikasi hal-hal terpenting yang perlu dipertimbangkan, metode ini menghasilkan prediksi yang lebih dapat diandalkan.

Demikian pula, menggunakan regresi logistik untuk memilih fitur bekerja dengan baik. Pengklasifikasi random forest melakukan pekerjaan yang sangat baik setelah dilatih pada fitur-fitur yang dipilih. Matriks kebingungan menunjukkan beberapa tebakan yang salah, baik positif palsu maupun negatif palsu, tetapi secara keseluruhan, klasifikasinya cukup akurat. Ini memberi tahu kita bahwa meskipun regresi logistik bagus, kita mungkin dapat membuatnya bekerja lebih baik lagi untuk menangkap pola yang lebih halus dalam data.

Metode pohon keputusan untuk memilih fitur memberi kita pandangan bermanfaat lainnya. Metode ini memberi peringkat fitur berdasarkan seberapa pentingnya fitur tersebut, yang membantu pengklasifikasi random forest bekerja dengan baik. Matriks kebingungan menunjukkan bahwa pohon keputusan bagus dalam mengidentifikasi aspek-aspek kunci. Metode ini memiliki keseimbangan yang baik antara klasifikasi positif dan negatif yang benar.

Melihat hasil dari berbagai metode ini memberikan gambaran tentang keunggulan masing-masing pendekatan pemilihan fitur. Pemilihan fitur berbasis SVC melakukan pekerjaan yang fantastis dalam menyempurnakan dataset, sementara pohon keputusan dan regresi logistik memberikan manfaatnya masing-masing. Setiap teknik mengungkapkan area yang dapat ditingkatkan untuk meningkatkan kinerja, tetapi juga menunjukkan kekuatannya dalam membuat klasifikasi lebih akurat. Ke depannya, para peneliti harus fokus pada eksplorasi cara-cara baru untuk memilih fitur dan menyempurnakan algoritma untuk mencapai akurasi yang lebih baik.


3.12 KESIMPULAN

Pembahasan tentang metode pemilihan fitur yang dipasangkan dengan klasifikasi random forest untuk dataset SECOM menunjukkan peningkatan besar dalam mendeteksi cacat. SVC, regresi logistik, dan pohon keputusan masing-masing memainkan peran kunci dalam meningkatkan efektivitas model. SVC memberikan dataset yang disempurnakan dengan



akurasi klasifikasi yang tinggi, sementara regresi logistik dan pohon keputusan juga menghasilkan hasil yang memuaskan, masing-masing dengan kekuatan dan kelemahannya sendiri.

Singkatnya, pembahasan ini menyoroti betapa pentingnya memilih metode pemilihan fitur yang tepat untuk mendapatkan kinerja model terbaik. Membandingkan berbagai pendekatan memberikan wawasan yang menunjukkan seberapa baik pemilihan fitur bekerja untuk meningkatkan sistem deteksi kesalahan. Ke depannya, pekerjaan selanjutnya harus fokus pada peningkatan metode yang ada dan mengeksplorasi metode baru untuk mencapai akurasi dan keandalan yang lebih tinggi dalam manufaktur semikonduktor.



BAB 4

PEMODELAN PREDIKTIF UNTUK PENINGKATAN HASIL PRODUKSI

4.1 PENDAHULUAN

Persentase chip bebas cacat yang diproduksi dikenal sebagai hasil produksi (yield), dan dioptimalkan hingga tingkat tertinggi di dunia manufaktur semikonduktor yang sibuk. Industri semikonduktor terus berupaya untuk menyederhanakan prosedur produksi guna meminimalkan biaya dan waktu pemasaran serta memenuhi permintaan yang terus meningkat untuk chip berkualitas tinggi.

Namun, mencapai hasil produksi ideal merupakan tugas yang sulit yang dipengaruhi oleh berbagai variabel, seperti kinerja peralatan, kualitas material, dan varians proses. Secara historis, kontrol proses statistik (SPC), kontrol proses lanjutan (APC), dan teknik statistik lainnya telah digunakan dalam inisiatif peningkatan hasil produksi untuk melacak dan memodifikasi proses industri. Metode-metode ini telah terbukti membantu dalam menemukan dan mengurangi varians proses, tetapi seringkali mengabaikan hubungan kompleks yang ada antara variabel proses dan hasil produksi.

Deep learning – subbidang kecerdasan buatan (AI) – yang mengambil petunjuk dari struktur dan operasi otak manusia, telah semakin menonjol dalam beberapa tahun terakhir dan sepenuhnya mengubah sejumlah industri, termasuk produksi semikonduktor. Model deep learning menghadirkan jalur yang memungkinkan untuk meningkatkan prediksi hasil produksi semikonduktor karena kemampuannya untuk secara otomatis mengekstrak hubungan dan pola kompleks dari sejumlah besar data.

Seiring dengan semakin efisiennya algoritma untuk pelatihan dan inferensi, deep learning menemukan aplikasi di berbagai disiplin ilmu, termasuk mikrokontroler dan pusat data. Metode deep learning seperti model generatif dan algoritma evolusioner digunakan dalam manufaktur semikonduktor untuk banyak proses, termasuk optimasi proses, inspeksi optik otomatis, dan pembuatan photomask. Karena volume data yang besar, menghitung hasil produksi di semua langkah proses secara detail merupakan tugas yang sangat rumit yang membutuhkan sejumlah besar sumber daya untuk pembahasan brute force atau pendekatan heuristik yang efektif. Saat ini, data historis dapat digunakan untuk membuat inferensi tentang frekuensi kesalahan yang terjadi dan hubungan antar kesalahan; Sayangnya, tidak semua kesalahan, konfigurasi proses, dan kombinasi parameter didokumentasikan. Akibatnya, tidak mungkin untuk mengidentifikasi kesalahan tanpa celah. Merealisasikan potensi penuh teknologi semikonduktor AI di bidang ini membutuhkan upaya untuk mengatasi hambatan seperti memahami pergeseran dari pelatihan ke inferensi dan mengoptimalkan komputasi.

Bab ini mengkaji metode-metode yang menggunakan pembelajaran mendalam untuk memprediksi dan memaksimalkan hasil produksi semikonduktor. Dalam satu pembahasan, analisis komponen utama digunakan untuk memperkirakan hasil produksi dengan berfokus pada parameter uji untuk distribusi non-normal. Kami mengeksplorasi elemen-elemen penting dari metode ini, yang meliputi pengumpulan data, pra-pemrosesan, pembuatan model,



pelatihan, implementasi, dan peningkatan berkelanjutan. Produsen semikonduktor dapat memperoleh wawasan penting tentang proses manufaktur mereka, menentukan variabel yang memengaruhi hasil produksi, dan menerapkan strategi yang terfokus untuk meningkatkan hasil produksi dan produktivitas secara keseluruhan dengan memanfaatkan pembelajaran mendalam.

4.2 MENGENAL CELAH METODE KONVENSIONAL DAN HADIRNYA SOLUSI DIGITAL

Metode konvensional untuk meningkatkan hasil produksi semikonduktor telah dikembangkan selama bertahun-tahun dan menggabungkan prinsip-prinsip teknik, strategi pengendalian proses, dan metode statistik. Metode-metode ini sangat penting dalam menjaga stabilitas proses, meningkatkan hasil produksi secara keseluruhan, dan mengoptimalkan parameter. Namun, metode-metode ini memiliki beberapa kekurangan dan batasan yang dapat mengurangi efektivitasnya.

Tinjauan Umum Kontrol Proses Statistik


- Kontrol proses statistik adalah metode yang menggunakan analisis statistik data proses untuk memantau dan mengendalikan proses manufaktur. Salah satu kelemahan SPC adalah, meskipun baik dalam mengidentifikasi fluktuasi dalam proses dan menjaga stabilitas, SPC mungkin tidak mampu menangkap korelasi nonlinier yang rumit antara parameter proses dan hasil produksi.
- **Dampak:** Keterbatasan ini dapat mempersulit identifikasi ketergantungan dan interaksi kecil antar variabel, yang dapat mengakibatkan optimasi proses dan peningkatan hasil produksi yang kurang ideal.

Desain Eksperimen

- Desain eksperimen (DOE) adalah metode sistematis yang bertujuan untuk meningkatkan kualitas dan kinerja produk dengan memeriksa dan memperbaiki faktor-faktor proses. Meskipun DOE bermanfaat untuk optimasi proses, DOE seringkali bersifat reaktif, berfokus pada menemukan dan memperbaiki masalah setelah masalah tersebut muncul.
- **Dampak:** Kemampuan untuk secara proaktif meminimalkan kehilangan hasil produksi mungkin dibatasi oleh strategi reaktif ini, yang dapat menyebabkan peningkatan waktu henti, limbah, dan pengerjaan ulang.

Kontrol Proses Lanjutan

- Tujuan dari kontrol proses lanjutan adalah untuk mempertahankan kinerja yang diinginkan dengan menyesuaikan parameter proses melalui integrasi sensor, algoritma kontrol, dan model proses. Sistem APC mungkin tidak mampu mengelola sejumlah besar data yang dihasilkan oleh teknik fabrikasi semikonduktor kontemporer.
- **Dampak:** Pembatasan ini dapat mempersulit evaluasi kumpulan data yang rumit dengan berbagai sumber informasi, yang dapat menyebabkan hilangnya informasi penting yang dapat digunakan untuk meningkatkan hasil produksi.



Analisis Kegagalan

- Analisis kegagalan, juga dikenal sebagai analisis akar penyebab, adalah pemeriksaan metodis terhadap kekurangan atau kegagalan, dengan tujuan untuk menemukan alasan yang mendasarinya dan mencegah terulangnya kembali. Kelemahannya adalah meskipun analisis kegagalan sangat penting untuk memahami kekurangan, hal ini seringkali merupakan prosedur yang membutuhkan banyak tenaga dan sumber daya.
- Dampak: Skalabilitas dan kelincahan dapat dibatasi oleh analisis manual, yang akan menghambat pencegahan kesalahan yang cepat dan memperpanjang operasi perbaikan.

Tinjauan Umum Optimasi Proses Dan Peningkatan Berkelanjutan

- Untuk meningkatkan kinerja dan hasil produksi, proses manufaktur harus terus ditingkatkan melalui optimasi proses. Kelemahan metode optimasi proses tradisional adalah bahwa metode tersebut mungkin tidak dapat memprediksi tren hasil produksi di masa mendatang.
- Dampak: Produsen dapat kesulitan mencapai target produksi dan mempertahankan tingkat hasil produksi yang stabil tanpa kemampuan prediksi.

Meskipun metode konvensional masih merupakan alat yang berguna dalam industri manufaktur semikonduktor, menggabungkannya dengan menggunakan teknologi mutakhir, seperti pembelajaran mesin dan analitik canggih, dapat membantu kita mengatasi beberapa kelemahannya dan membuka kemungkinan baru untuk optimasi proses dan hasil produksi.

4.3 KEUNGGULAN MUTAKHIR DEEP LEARNING DALAM MENCETAK CHIP SEMPURNA

Berikut beberapa manfaat penerapan pembelajaran mendalam untuk peningkatan hasil produksi dan pemodelan prediktif dalam manufaktur semikonduktor.

Kemampuan Untuk Menangkap Interaksi Kompleks


- Struktur berlapis-lapis dari model pembelajaran mendalam memungkinkan mereka untuk secara efisien menggambarkan hubungan yang rumit dan nonlinier yang ada antara hasil produksi dan parameter proses.
- Mereka dapat mengungkap koneksi dan pola yang rumit dalam data yang mungkin sulit diidentifikasi oleh teknik statistik konvensional.

Pembelajaran Dan Representasi Fitur

- Rekayasa fitur manual tidak lagi diperlukan karena algoritma pembelajaran mendalam dapat secara otomatis mengekstrak fitur yang relevan dari data mentah.
- Kemampuan untuk memperoleh representasi data yang signifikan dapat menghasilkan model prediksi yang lebih andal dan akurat.

Mengelola Data Besar

- Model pembelajaran mendalam sangat efektif dalam mengatasi kesulitan data besar yang ada dalam produksi semikonduktor karena kemampuannya dalam memproses dan menginterpretasikan kumpulan data yang sangat besar.



Fleksibilitas

- Kerangka kerja pembelajaran mendalam menawarkan fleksibilitas dan kemampuan adaptasi yang tinggi terhadap berbagai jenis data dan area masalah.
- Karena kemampuannya untuk mendukung sejumlah besar sumber dan format data, produsen semikonduktor dapat memasukkan data ke dalam model prediktif mereka dari berbagai sumber.

Peningkatan Akurasi Prediktif

- Dalam berbagai aplikasi, kerangka kerja pembelajaran mendalam, terutama struktur canggihnya, seperti jaringan saraf konvolusional (CNN) dan jaringan saraf berulang (RNN), telah menunjukkan akurasi prediktif yang lebih baik daripada model statistik tradisional.
- Peningkatan akurasi ini dapat menghasilkan proyeksi hasil yang lebih akurat dan pengambilan keputusan yang lebih baik dalam industri manufaktur semikonduktor.

Prediksi Real-Time

- Dengan terus menganalisis data yang masuk dari proses manufaktur, kerangka kerja pembelajaran mendalam dapat digunakan secara real-time untuk menghasilkan prediksi kualitas hasil yang cepat.
- Pengambilan keputusan proaktif dan intervensi cepat memungkinkan optimalisasi parameter proses dan menghindari kehilangan hasil.


Identifikasi Anomali Dan Abnormalitas

- Model pembelajaran mendalam dapat dilatih untuk menemukan penyimpangan proses, cacat material, dan kerusakan peralatan, yang merupakan contoh anomali dan abnormalitas yang ditemukan dalam proses manufaktur semikonduktor.
- Gangguan produksi dapat diminimalkan dan kehilangan hasil produksi dapat dihindari dengan deteksi dini masalah-masalah ini.

Efisiensi Dan Skalabilitas

- Model pembelajaran mendalam dapat diskalakan dan diterapkan dalam skala besar di seluruh fasilitas manufaktur setelah dilatih.
- Hal ini memungkinkan prediksi hasil produksi yang andal di banyak lini produksi dan lokasi. Karena skalabilitasnya, produsen semikonduktor dapat menggunakan pemodelan prediktif untuk meningkatkan hasil produksi di seluruh bisnis mereka.

Produsen semikonduktor dapat memperoleh wawasan penting tentang proses manufaktur mereka, menentukan variabel yang memengaruhi hasil produksi, dan menerapkan strategi yang terfokus untuk meningkatkan hasil produksi dan produktivitas secara keseluruhan dengan memanfaatkan pembelajaran mendalam. Metode saat ini untuk menggunakan data metrologi untuk mengklasifikasikan hasil produksi menekankan penanggulangan kelas yang tidak seimbang dan pengisian data yang hilang. Sebagian besar masalah di dunia nyata memerlukan penggunaan analitik canggih sehingga solusi yang bijaksana dan cerdas dapat dikembangkan untuk memenuhi kebutuhan saat ini. Karena alasan ini, AI analitik yang menggunakan pendekatan pembelajaran mesin dan pembelajaran mendalam dapat menjadi sangat penting untuk pengembangan komputasi dan sistem yang didukung AI.




4.4 FONDASI PENTING DALAM DUNIA DEEP LEARNING


Memahami dasar-dasar pembelajaran mendalam sangat penting untuk memaksimalkan potensinya dalam meningkatkan hasil produksi semikonduktor. Mari kita periksa setiap ide utama secara lebih rinci.

Jaringan Neural

- Arsitektur dasar jaringan neural adalah jaringan node yang terhubung dan tersusun dalam lapisan. Lapisan keluaran menghasilkan prediksi model, lapisan tersembunyi melakukan perhitungan, dan lapisan masukan menerima data mentah. Fungsi aktivasi memberikan nonlinieritas pada jaringan dan memungkinkannya untuk mensimulasikan korelasi rumit dalam data; fungsi nonlinier diterapkan pada output setiap neuron. Beberapa contoh fungsi aktivasi umum meliputi Tanh, sigmoid, dan ReLU (rectified linear unit). Selama fase pelatihan, bobot dan bias adalah parameter yang terkait dengan koneksi antar neuron yang diubah untuk mengurangi perbedaan antara hasil yang diharapkan dan yang diamati.
- Mesin penguat gradien (GBM) telah menjadi alat yang ampuh untuk manufaktur semikonduktor, optimasi kondisi proses, dan pemilihan material. Dalam hal estimasi probabilistik, estimasi ketidakpastian, dan kinerja prediktif, model pembelajaran mesin ini sering kali mengalahkan jaringan saraf dalam. GBM sangat kompeten dalam hal-hal seperti optimasi kondisi proses untuk berbagai tahapan manufaktur semikonduktor, seperti litografi, etsa, dan deposisi. Insinyur proses yang ingin meningkatkan hasil dan mengurangi variabilitas dapat memperoleh manfaat besar dari kemampuan mereka untuk menawarkan perkiraan yang tepat dan estimasi ketidakpastian yang dapat dipercaya.




Gambar 4.1 Arsitektur FNN.




Arsitektur Pembelajaran Mendalam

- **Jaringan Neural Feedforward:** Jaringan neural feedforward (FNN) adalah tipe jaringan neural paling dasar, di mana data hanya bergerak dari input ke output dalam satu arah, tanpa loop atau siklus. Jaringan ini bekerja dengan baik untuk aplikasi klasifikasi dan regresi. Gambar 4.1 menunjukkan arsitektur FNN.
- **Jaringan Neural Konvolusional:** CNN dirancang khusus untuk mengelola informasi yang menyerupai grid, seperti foto. Lapisan konvolusional, pooling, dan fully connected membentuk strukturnya, yang memungkinkan mereka untuk merekam pola dan hierarki dalam ruang. Gambar 4.2 menggambarkan arsitektur CNN.
- **Jaringan Neural Rekuren:** RNN dibuat untuk mengelola data sekuensial yang bergantung secara temporal. Jaringan ini cocok untuk aplikasi seperti analisis deret waktu dan prediksi pemrosesan bahasa alami karena memiliki loop umpan balik yang memungkinkan informasi bertahan sepanjang waktu. Gambar 4.3 menunjukkan arsitektur RNN.
- **Jaringan Long Short-Term Memory (LSTM):** Jaringan LSTM adalah desain RNN yang menggunakan sel memori untuk mengatasi masalah gradien yang menghilang. Ketergantungan jangka pendek dapat dipelajari melalui LSTM, yang populer untuk tugas-tugas sekuensial.
- **Model Transformer:** Model transformer adalah perkembangan baru dalam arsitektur pembelajaran mendalam yang sebagian besar diterapkan pada tantangan yang melibatkan pemrosesan bahasa alami. Transformer secara efisien menangkap hubungan global dalam data sekuensial dengan menggunakan metode self-attention.




Gambar 4.2 Arsitektur CNN.



Model Instruksi Untuk Pembelajaran Mendalam

- Proses pengiriman data input melalui jaringan untuk menghitung prediksi disebut propagasi maju. Setelah melakukan komputasi dengan bobot dan biasnya sendiri, setiap lapisan mentransfer hasilnya ke lapisan berikutnya.
- Propagasi balik adalah metode untuk mengubah bobot dan bias dalam model sebagai respons terhadap variasi antara hasil yang diharapkan dan hasil aktual. Ini melibatkan penghitungan gradien fungsi kerugian terhadap setiap parameter dan mengubahnya menggunakan metode optimasi seperti Adam atau stochastic gradient descent (SGD).
- Fungsi kerugian adalah fungsi objektif yang menyatakan seberapa besar perbedaan antara hasil aktual dan hasil yang diproyeksikan. Kerugian entropi silang adalah fungsi kerugian populer untuk aplikasi klasifikasi, sedangkan mean squared error (MSE) digunakan dalam tugas regresi.



Gambar 4.3 Arsitektur RNN.

Menyesuaikan Hiperparameter Dan Model

- **Tingkat Pembelajaran:** Mengatur ukuran langkah saat memperbarui parameter. Memilih tingkat pembelajaran yang sesuai sangat penting untuk pelatihan dan konvergensi yang efektif.
- **Ukuran Batch:** Jumlah sampel yang ditangani dalam setiap iterasi pelatihan ditentukan oleh ukuran batch. Ini berdampak pada kebutuhan memori dan stabilitas proses pelatihan.
- **Jumlah Neuron dan Lapisan:** Arsitektur jaringan saraf, yang mencakup jumlah lapisan dan setiap lapisan neuron, memengaruhi kemampuan jaringan untuk mengenali hubungan dan pola yang rumit.



- **Metode Regularisasi:** Teknik seperti normalisasi batch, dropout, dan regularisasi L1/L2 membantu mencegah overfitting dan meningkatkan kapasitas kerangka kerja untuk generalisasi.

Evaluasi Dan Validasi Model

Biasanya, data dibagi menjadi beberapa subset untuk pengujian, validasi, dan pelatihan. Set pelatihan digunakan untuk melatih model, kinerja dipantau, hyperparameter set validasi diubah, dan efektivitas model akhir dievaluasi pada set pengujian. Kinerja model deep learning pada tugas klasifikasi dan regresi diukur menggunakan beberapa metrik, termasuk akurasi, presisi, recall, skor F1, dan mean absolute error (MAE). Berbagai kategori pengetahuan, termasuk pengetahuan prosedural, meta-, struktural, deskriptif, dan heuristik, dapat diterapkan di berbagai bidang aplikasi.

Pemanfaatan Dan Interpretasi Model

Model deep learning dapat diimplementasikan pada berbagai platform, seperti sistem tertanam, perangkat edge, dan layanan berbasis cloud. Membuat prediksi pada data baru yang belum pernah dilihat sebelumnya menggunakan model terlatih dikenal sebagai inferensi. Ini adalah proses menggunakan model terlatih untuk memproses data input dan menghasilkan prediksi sebagai output. Model konseptual berbasis pengetahuan dapat dikembangkan menggunakan berbagai teknik representasi pengetahuan, seperti aturan logis, semantik, jaringan, kerangka, dan produksi.

4.5 PERJALANAN DATA DARI SENSOR PABRIK HINGGA SIAP DIPELAJARI MESIN

Pemahaman menyeluruh tentang prosedur yang terlibat sangat penting ketika mengeksplorasi pengumpulan dan pra-pemrosesan data dalam konteks pemodelan prediktif berbasis pembelajaran mendalam untuk peningkatan hasil semikonduktor. Berikut penjelasan lengkapnya.

- **Pengumpulan Data:** Data sensor seperti suhu, tekanan, laju aliran, konsentrasi kimia, dan karakteristik lainnya dipantau oleh berbagai sensor selama proses manufaktur semikonduktor. Jenis sensor meliputi flowmeter, termokopel, sensor tekanan, dan peralatan spektroskopi.
- **Granularitas Data:** Tergantung pada prosesnya, data sensor biasanya dikumpulkan pada interval reguler, yang dapat berkisar dari milidetik hingga menit.
- **Sumber Data:** Peralatan manufaktur menyediakan data ini, yang kemudian dikumpulkan dan disimpan dalam basis data, repositori historis, dan gudang data.
- **Log Peralatan:** Mesin yang digunakan dalam pembuatan semikonduktor menghasilkan log yang mencatat data mengenai kinerja, pemeliharaan, dan operasi. Peristiwa, peringatan, resep, dan log status peralatan termasuk di antara beberapa jenis log.
- **Format Data:** Log dapat disimpan dalam format XML, CSV, atau format kepemilikan lainnya yang unik untuk produsen peralatan tertentu.
- **Pembersihan Data:** Untuk mengekstrak fitur-fitur penting dari log, yang seringkali mengandung noise dan informasi yang tidak relevan, pra-pemrosesan diperlukan.



- **Temuan Inspeksi dan Metrologi:** Kualitas dan integritas wafer dan chip semikonduktor dievaluasi menggunakan instrumen metrologi dan sistem inspeksi. Pengukuran dimensi kritis, jumlah cacat, peta cacat, dan peta wafer adalah contoh jenis data.
- **Integrasi Data:** Untuk analisis yang menyeluruh, data inspeksi dan metrologi harus digabungkan dengan data proses lainnya.
- **Penyelarasan:** Agar peta wafer dan peta cacat sesuai dengan data proses, penyelarasan dan registrasi mungkin diperlukan.
- **Informasi Masa Lalu:** Model prediktif dapat dilatih secara efektif menggunakan data historis dari proses manufaktur sebelumnya.
- **Kualitas Data:** Praproses yang cermat diperlukan karena data historis mungkin memiliki nilai yang hilang, informasi yang tidak konsisten, atau informasi yang sudah usang.
- **Praproses Data:** Ini melibatkan pembersihan data dan pengelolaan nilai yang hilang. Tergantung pada jenis nilai yang hilang, metode seperti imputasi, penghapusan, atau interpolasi digunakan.
- **Penghapusan dan Deteksi Pencilan:** Langkah ini melibatkan pencarian dan penghapusan pencilan yang dapat mengganggu hasil prosedur analitik atau pemodelan.
- **Pengurangan Kebisingan:** Metode seperti filter low-pass atau rata-rata bergerak menghilangkan kebisingan dari data sensor.
- **Penskalaan dan Normalisasi:** Untuk menjamin konsistensi dan meningkatkan konvergensi selama pelatihan model, karakteristik numerik diskalakan dan dinormalisasi ke rentang standar (seperti).
- **Standardisasi:** Untuk memperhitungkan perbedaan skala dan varians, karakteristik disesuaikan agar memiliki deviasi standar 1 dan rata-rata 0.
- **Pengurangan Dimensi:** Metode pengurangan dimensi, seperti pemilihan fitur atau analisis komponen utama, digunakan dalam rekayasa karakteristik untuk fokus pada karakteristik yang paling relevan dengan mengurangi dimensi dataset.
- **Fitur Deret Waktu:** Dari data deret waktu, elemen temporal diekstrak, termasuk rata-rata bergulir, nilai lag, dan penanda tren.
- **Fitur Khusus untuk Suatu Domain:** Fitur direkayasa dengan fokus pada proses produksi semikonduktor dan pengetahuan domain.
- **Integrasi Data:** Untuk memungkinkan analisis yang mendalam dan pemodelan yang akurat, sangat penting untuk memastikan bahwa berbagai sumber data (seperti data sensor, log peralatan, dan temuan metrologi) konsisten dan selaras satu sama lain.
- **Penggabungan dan Agregasi:** Dengan memanfaatkan kunci atau ID yang relevan untuk menggabungkan data dari beberapa sumber, data harus digabungkan pada granularitas yang diinginkan (misalnya, tingkat wafer, tingkat lot).
- **Pemisahan Data:** Untuk menilai kinerja model secara efektif, dataset harus dibagi menjadi subset yang berbeda untuk pengujian, validasi, dan pelatihan.



- **Pemisahan Berdasarkan Waktu:** Untuk mencegah kebocoran data dan mengevaluasi generalisasi model, ketergantungan temporal harus diperhitungkan dengan membagi data menjadi bagian-bagian kronologis.
- **Augmentasi Data:** Untuk meningkatkan ketahanan dan generalisasi model, lebih banyak data pelatihan dapat dihasilkan dengan memutar, membalik, atau menambahkan noise.

Membangun model prediktif yang akurat dan dapat dipercaya untuk peningkatan hasil dalam produksi semikonduktor membutuhkan pengumpulan dan pra-pemrosesan data yang efektif. Praktisi dapat memastikan bahwa model mereka dilatih pada data berkualitas tinggi dan mampu menangkap pola dan korelasi yang relevan dalam proses manufaktur dengan memilih dan mempersiapkan data secara cermat.

4.6 SIKLUS HIDUP PENGEMBANGAN MODEL DEEP LEARNING

Menggunakan pembelajaran mendalam untuk pemodelan prediktif dalam produksi semikonduktor membutuhkan pemahaman menyeluruh tentang tahap pembuatan dan pelatihan model. Sekarang mari kita periksa prosedur ini secara lebih detail.

- **Pengembangan Model:** Identifikasi dengan jelas tujuan model prediktif serta pernyataan masalahnya. Dalam manufaktur semikonduktor, peningkatan hasil produksi dapat mencakup deteksi anomali proses, optimasi parameter produksi, atau prediksi terjadinya cacat.
- **Persiapan Data:** Kumpulkan dan siapkan informasi yang dibutuhkan untuk melatih model. Ini mencakup pengumpulan informasi dari berbagai sumber, termasuk sensor, catatan peralatan, dan temuan inspeksi, kemudian melakukan rekayasa fitur, standardisasi data, dan pembersihan data.
- **Pemilihan Model:** Berdasarkan jenis data dan masalah yang ada, pilih arsitektur pembelajaran mendalam yang sesuai. Kerangka kerja Transformer, RNN, jaringan saraf feed-forward, dan CNN adalah contoh arsitektur umum.
- **Desain Arsitektur:** Jelaskan desain jaringan saraf, dengan mempertimbangkan jumlah lapisan, jenis lapisan (seperti rekuren dan konvolusional), dan mekanisme aktivasi yang digunakan di setiap lapisan.
- **Pelatihan Model:** Bagi dataset menjadi beberapa bagian yang berbeda untuk pengujian, validasi, dan pelatihan. Set validasi digunakan untuk melacak kinerja dan penyesuaian hyperparameter, set pengujian digunakan untuk menilai kinerja kerangka kerja yang telah selesai, dan set pelatihan digunakan untuk memperbarui parameter model.
- **Pemilihan Fungsi Kerugian:** Tergantung pada persyaratan tugas model prediktif, pilih fungsi kerugian yang sesuai. MSE dan MAE adalah fungsi kerugian populer untuk tugas regresi; kerugian cross-entropy sering digunakan untuk masalah klasifikasi.
- **Penyetelan Hyperparameter:** Untuk memaksimalkan kinerja model, sesuaikan hyperparameter, termasuk learning rate, ukuran batch, jumlah epoch, dan parameter regularisasi. Untuk menentukan kumpulan hyperparameter yang ideal, gunakan



strategi seperti metode optimasi hyperparameter otomatis, pencarian acak, atau pencarian grid.

- **Prosedur Instruksional:** Untuk menghitung prediksi untuk set pelatihan, gunakan propagasi maju. Untuk menghitung gradien fungsi kerugian dalam kaitannya dengan parameter model, gunakan backpropagasi. Kemudian gunakan algoritma untuk optimasi seperti Adam, RMSprop, atau SGD untuk memperbarui parameter. Metrik seperti kerugian pelatihan dan kerugian validasi dapat digunakan untuk melacak kemajuan pelatihan dan mengidentifikasi contoh overfitting atau underfitting.
- **Regularisasi:** Untuk menghindari overfitting dan meningkatkan kapasitas kerangka kerja untuk generalisasi, gunakan strategi regularisasi seperti normalisasi batch, dropout, dan regularisasi L1/L2.
- **Penghentian Dini:** Saat model bekerja pada set validasi, pantau prosesnya selama pelatihan, dan hentikan model ketika kinerjanya menurun, yang menunjukkan overfitting. Untuk menghindari overfitting, simpan parameter model yang sesuai dengan kerugian validasi terendah.
- **Evaluasi Model:** Dengan menggunakan metrik evaluasi yang sesuai, seperti akurasi, presisi, recall, skor F1, atau MAE, nilai model terlatih akhir pada set pengujian. Untuk mengevaluasi kemampuan model untuk melakukan generalisasi, bandingkan kinerjanya pada set pelatihan dan validasi dengan set pengujian.
- **Penyempurnaan Iteratif:** Berdasarkan wawasan dari evaluasi model dan masukan dari pakar bidang, lakukan iterasi pada proses konstruksi dan pelatihan model.


Untuk meningkatkan kekokohan dan kinerja model Anda, bereksperimenlah dengan berbagai metode pra-pemrosesan, hyperparameter, dan arsitektur. Para praktisi dapat secara signifikan meningkatkan efisiensi produksi dan kualitas produk dengan mengikuti langkah-langkah ini secara cermat untuk mengembangkan dan melatih model pembelajaran mendalam yang secara akurat menangkap hubungan rumit yang ditemukan dalam data manufaktur semikonduktor dan memprediksi hasil produksi.

4.7 MENGHUBUNGKAN KECERDASAN BUATAN DENGAN SISTEM PABRIK MODERN

Untuk menggunakan model prediktif dalam manufaktur semikonduktor, pengaturan pengembangan harus memberi jalan pada pengaturan produksi sambil mempertahankan kinerja waktu nyata, skalabilitas, dan keandalan. Ini adalah uraian lengkap tentang prosedur penerapan.

Konfigurasi Infrastruktur

- **Kebutuhan Perangkat Keras:** Tetapkan perangkat, seperti server, unit pemrosesan grafis, atau akselerator perangkat keras khusus untuk inferensi pembelajaran mendalam, yang diperlukan untuk mendukung penerapan model.
- **Tumpukan Perangkat Lunak:** Instal tumpukan perangkat lunak yang diperlukan, yang harus mencakup alat pemantauan dan manajemen tambahan, pra-pemrosesan data dan pustaka penyajian model (seperti TensorFlow Serving, TorchServe), dan kerangka kerja pembelajaran mendalam (seperti TensorFlow, PyTorch).



Pengemasan Model

- **Serialisasi Model:** Serialisasikan kerangka kerja pembelajaran mendalam yang telah dilatih ke dalam format yang dapat digunakan untuk penyebaran, seperti format SavedModel dari TensorFlow atau format TorchScript dari PyTorch.
- **Manajemen Ketergantungan:** Pastikan model disebar dengan semua ketergantungan yang diperlukan, seperti paket Python, kerangka kerja pembelajaran mendalam, dan pustaka khusus.

Penyebaran Model

- Dengan menggunakan kerangka kerja atau platform penyajian model, sebar model yang telah diserialisasi ke lingkungan produksi. Ini dapat mencakup penggunaan model sebagai kontainer Docker, API RESTful, atau layanan inferensi penyedia cloud.
- **Skalabilitas:** Pastikan infrastruktur penerapan memiliki kapasitas untuk berkembang guna memenuhi perubahan permintaan inferensi dan menangani berbagai beban kerja.

Menggabungkan Sistem Produksi Dengan Integrasi

- Siapkan sistem untuk memasukkan data waktu nyata, seperti log peralatan, aliran data sensor, dan temuan inspeksi. Lakukan pra-pemrosesan data sebelum memberikannya ke model yang diterapkan.
- **Menggabungkan Sistem Manufaktur:** Untuk memfasilitasi aliran data dan pengambilan keputusan yang lancar, integrasikan model prediktif dengan proses dan sistem produksi saat ini, seperti sistem eksekusi produksi, sistem kontrol proses, dan sistem manajemen mutu.

Pengamatan Dan Pencatatan

- **Memantau Kinerja Model:** Gunakan alat pemantauan untuk mengawasi kinerja model yang diterapkan secara waktu nyata, melacak variabel seperti tingkat kesalahan, latensi, throughput, dan penggunaan sumber daya.
- **Pencatatan dan Audit:** Untuk membantu dalam debugging, audit, dan pemecahan masalah, catat permintaan dan balasan inferensi serta metadata seperti stempel waktu, data input, dan prediksi model.

Keamanan Dan Kepatuhan

- **Keamanan Data:** Untuk melindungi informasi pribadi yang dikirim ke dan dari model yang diimplementasikan, gunakan protokol komunikasi untuk tujuan keamanan, akses kontrol, dan enkripsi data.
- **Kepatuhan:** Verifikasi bahwa implementasi mematuhi persyaratan hukum serta standar industri yang berkaitan dengan keamanan data, privasi, dan kontrol kualitas, termasuk standar ISO 27001, GDPR, HIPAA, dan SEMI.

Pemeriksaan Dan Pemeliharaan Terus Menerus

- **Mengoptimalkan Kinerja:** Untuk meningkatkan akurasi dan efisiensi dari waktu ke waktu, pantau eksekusi kerangka kerja yang diterapkan, dan sesuaikan parameter hiper, ubah arsitektur model, atau latih ulang kerangka kerja menggunakan data baru.



- **Toleransi Kesalahan:** Gunakan teknik seperti redundansi, failover, dan penskalaan otomatis untuk menjaga ketahanan sistem dan mengelola kegagalan dengan baik.
- **Pengelolaan Versi dan Pengembalian Versi:** Lacak versi model yang diterapkan, dan terapkan metode untuk mengembalikan ke iterasi sebelumnya jika terjadi masalah yang tidak terduga atau penurunan kinerja.

Instruksi Dan Bantuan Untuk Pengguna

- **Pelatihan Pengguna:** Ajarkan operator, insinyur, dan pengambil keputusan, di antara pengguna akhir lainnya, untuk memahami prediksi model, menggabungkannya ke dalam alur kerja mereka, dan menggunakan wawasan dari model untuk membuat keputusan yang tepat.
- **Pencatatan:** Untuk memaksimalkan kegunaan model yang diterapkan, buat dokumentasi dan panduan pengguna yang lengkap yang mencakup instruksi penggunaan, metode penerapan, langkah-langkah pemecahan masalah, dan praktik terbaik.

Produsen semikonduktor dapat secara efisien menerapkan model prediktif dalam pengaturan produksi, memfasilitasi pengambilan keputusan berbasis data, menyederhanakan prosedur manufaktur, dan meningkatkan hasil dan kualitas produk dengan mematuhi pedoman dan praktik terbaik tertentu.

4.8 PARAMETER KUNCI UNTUK MENGEVALUASI PERFORMA MODEL


Bagian penting dari evaluasi efektivitas dan keandalan model prediktif dalam produksi semikonduktor adalah analisis kinerja dan ukuran evaluasi. Berikut adalah pemeriksaan menyeluruh dari elemen-elemen ini.

Metrik Klasifikasi

Dalam manufaktur semikonduktor, tugas-tugas seperti deteksi cacat atau kontrol kualitas dan metrik klasifikasi sangat penting untuk menilai efektivitas kerangka kerja prediktif. Ringkasan tingkat tinggi dari kinerja model diberikan oleh akurasi – yaitu, proporsi kejadian yang diidentifikasi dengan tepat. Presisi mengukur ketahanan model terhadap positif palsu, yang sangat penting dalam situasi di mana alarm palsu dapat menimbulkan biaya yang mahal. Recall, juga dikenal sebagai sensitivitas, mengukur kemampuan model untuk mendeteksi setiap kejadian positif; ini sangat penting ketika pengurangan negatif palsu sangat penting. Ketika ada ketidakseimbangan antara presisi dan recall, skor F1, yang merupakan rata-rata harmonik keduanya, menyeimbangkan keduanya dan sangat membantu.

Metrik Regresi

Metrik regresi berguna dalam industri manufaktur semikonduktor untuk aktivitas seperti estimasi parameter proses dan prediksi tingkat hasil. Ukuran rata-rata kesalahan model diukur oleh MAE, yang memberikan gambaran yang jelas tentang seberapa akurat perkiraan tersebut. MSE, yang menghukum lebih berat untuk kesalahan yang lebih besar, mengukur rata-rata selisih kuadrat antara nilai aktual dan nilai yang diproyeksikan. Karena memiliki satuan ekspresi yang sama dengan variabel target, root mean squared error (RMSE), yang diturunkan dari MSE, sering digunakan untuk interpretasi.



Metrik Tambahan

Kurva Receiver Operating Characteristic (ROC) dan kurva presisi-recall adalah dua alat tambahan yang melampaui metrik tipikal dan menawarkan wawasan yang lebih dalam tentang kinerja model, terutama dalam tugas klasifikasi biner. Area di bawah kurva ROC, atau AUC-ROC, meringkas kinerja ini menjadi nilai skalar tunggal, sedangkan kurva ROC menggambarkan bagaimana tingkat positif sejati dan tingkat positif palsu dipertukarkan pada berbagai ambang batas untuk pengambilan keputusan. Sebaliknya, kurva presisi-recall memberikan pemahaman rinci tentang pertukaran antara akurasi dan recall, yang sangat membantu dalam dataset yang tidak seimbang.

Analisis Kinerja

Untuk mengevaluasi keandalan model dan menentukan area yang membutuhkan pengembangan, teknik analisis kinerja, termasuk validasi silang, perbandingan model, dan analisis kesalahan sangat penting. Validasi silang memberikan wawasan tentang stabilitas dan ketahanan dengan membagi dataset menjadi berbagai subset untuk pelatihan dan pengujian, membantu dalam memperkirakan kapasitas generalisasi suatu kerangka kerja. Dengan membandingkan model, praktisi dapat menentukan model mana yang berkinerja terbaik pada data pengujian atau validasi. Analisis kesalahan, di sisi lain, mengeksplorasi jenis dan tren kesalahan yang dilakukan model, mengarahkan iterasi dan peningkatan di masa mendatang.

4.9 PENERAPAN PRAKTIS AI UNTUK MENJAGA KUALITAS DAN EFISIENSI PABRIK

Penjelasan tentang pembahasan kasus dan penggunaan pemodelan prediktif untuk meningkatkan hasil produksi semikonduktor disajikan di sini.


Identifikasi Dan Klasifikasi Cacat

Dalam proses manufaktur semikonduktor, pendekatan pemodelan prediktif banyak digunakan untuk tujuan identifikasi dan klasifikasi cacat.

Model prediktif mampu mengenali dan mengkategorikan beberapa jenis cacat pada wafer atau chip semikonduktor, seperti partikel, goresan, atau pola yang tidak biasa, dengan memeriksa data sensor, hasil metrologi, dan gambar inspeksi. Untuk memahami pola dan fitur rumit yang menunjukkan adanya cacat, model ini menggunakan arsitektur pembelajaran mendalam seperti CNN. Hal ini memungkinkan manajemen kualitas proaktif dan meminimalkan kehilangan hasil produksi.

Kontrol Dan Optimasi Proses

Pemodelan prediktif sangat penting untuk mengatur parameter penting dan menyederhanakan proses manufaktur untuk meningkatkan hasil produksi semikonduktor. Model prediktif dapat menentukan kondisi proses terbaik, mengantisipasi kegagalan peralatan atau kebutuhan perawatan, dan menyarankan perubahan untuk meningkatkan hasil dan produktivitas dengan memeriksa data proses masa lalu dan log peralatan. Model ini menggunakan metode seperti pembelajaran penguatan dan analisis deret waktu untuk secara dinamis mengoptimalkan parameter proses dan menyesuaikan diri dengan perubahan pengaturan produksi.



Perawatan Prediktif

Penggunaan pemodelan prediktif yang penting dalam industri semikonduktor bertujuan untuk memaksimalkan waktu operasional peralatan dan meminimalkan waktu henti dengan mengantisipasi kerusakan peralatan sebelum terjadi. Model prediktif dapat mengantisipasi kegagalan peralatan, mengidentifikasi perilaku abnormal, dan merencanakan tugas perawatan jauh-jauh hari dengan mengevaluasi data sensor, log peralatan, dan catatan perawatan. Dengan menggunakan metode pembelajaran mesin seperti RNN atau mesin vektor pendukung untuk mengenali tren yang menunjukkan kerusakan atau degradasi peralatan, model ini memungkinkan prosedur perawatan prediktif dan meminimalkan waktu henti yang tidak terjadwal.

Prediksi Dan Optimasi Hasil Produksi

Prediksi dan optimasi hasil produksi merupakan tujuan mendasar dalam proses manufaktur semikonduktor, karena peningkatan hasil produksi yang kecil sekalipun dapat memberikan manfaat ekonomi yang substansial.

Untuk memperkirakan tingkat hasil produksi dan menentukan area yang perlu ditingkatkan, model prediktif memeriksa berbagai faktor yang memengaruhi hasil produksi, seperti kualitas material, faktor lingkungan, dan parameter proses. Untuk memperkirakan ketergantungan hasil produksi, mengoptimalkan parameter proses, dan mengurangi variabilitas, model-model ini menggunakan metode statistik, algoritma pembelajaran mesin, dan pendekatan optimasi. Hal ini pada akhirnya meningkatkan total hasil produksi dan profitabilitas.

Deteksi Kesalahan Dan Analisis Akar Penyebab

Pemodelan prediktif memainkan peran kunci dalam proses deteksi kesalahan dan analisis akar penyebab manufaktur semikonduktor, membantu dalam identifikasi dan mitigasi masalah yang memengaruhi hasil produksi dan kualitas produk. Model prediktif memindai data sensor, log peralatan, dan data kinerja historis untuk mengidentifikasi anomali dan penyebab yang mendasarinya serta menyarankan langkah-langkah perbaikan. Model-model ini menggunakan sistem pakar, metode inferensi kausal, dan algoritma deteksi anomali untuk mengidentifikasi lokasi kesalahan, memahami penyebab yang mendasarinya, dan menerapkan perbaikan terfokus yang meningkatkan hasil dan stabilitas proses.

Pembahasan kasus dan aplikasi ini menunjukkan betapa fleksibel dan bermanfaatnya pendekatan pemodelan prediktif untuk meningkatkan hasil, menyederhanakan alur kerja, dan menjamin kualitas produk di industri manufaktur semikonduktor. Produsen chip dapat memperoleh wawasan baru, meningkatkan keunggulan operasional, dan mempertahankan keunggulan kompetitif di pasar dengan memanfaatkan analitik canggih, algoritma pembelajaran mesin, dan keahlian domain.

4.10 MENUJU ERA KECERDASAN BUATAN GENERASI BARU DI LANTAI FABRIKASI

Mempelajari kemungkinan arah dan tren dalam pemodelan prediktif untuk peningkatan hasil manufaktur semikonduktor memberikan informasi yang mendalam tentang



perkembangan dan kemajuan di masa depan yang dapat membentuk industri ini. Berikut adalah uraian lengkapnya.

Arsitektur Pembelajaran Mendalam Tingkat Lanjut

Diproyeksikan bahwa kemajuan di masa depan dalam arsitektur pembelajaran mendalam akan sepenuhnya mengubah pemodelan prediktif manufaktur semikonduktor. Investigasi lebih lanjut terhadap struktur yang canggih, seperti jaringan kapsul, mekanisme perhatian, dan jaringan saraf grafik, berpotensi meningkatkan efisiensi dalam menangkap hubungan dan ketergantungan yang rumit dalam data manufaktur. Model prediktif yang lebih andal dan akurat dapat dimungkinkan oleh desain ini, terutama untuk pekerjaan yang melibatkan sumber data berdimensi tinggi dan beragam.

Ai Yang Dapat Dijelaskan

Untuk meningkatkan interpretasi dan transparansi model, teknik AI yang dapat dijelaskan (XAI) menjadi semakin diperlukan, karena pengambilan keputusan berbasis AI semakin sering digunakan dalam manufaktur semikonduktor. Untuk membantu pemangku kepentingan memahami, memvalidasi, dan mempercayai keluaran model prediktif, upaya pembahasan di masa mendatang akan berkonsentrasi pada pembuatan teknik XAI yang menawarkan wawasan tentang bagaimana model prediktif membuat penilaian. Mekanisme perhatian, analisis pentingnya fitur, dan teknik penjelasan yang tidak bergantung pada model adalah beberapa teknik kunci yang akan membantu memajukan XAI dalam manufaktur semikonduktor.

Augmentasi Data Spesifik Domain

Bidang pembahasan yang krusial adalah pengembangan metode augmentasi data spesifik domain yang sesuai dengan industri manufaktur semikonduktor. Metode ini bertujuan untuk mengurangi masalah kelangkaan data, meningkatkan generalisasi model, dan menghasilkan data sintesis yang meniru pengaturan manufaktur aktual. Di masa depan, dimungkinkan untuk menghasilkan kumpulan data yang representatif dan beragam untuk melatih model prediktif dengan memanfaatkan teknik augmentasi spesifik domain, autoencoder variasional, dan jaringan adversarial generatif.

Fusi Data Multimodal

Dalam pemodelan prediksi produksi semikonduktor, penggabungan sumber data multimodal, seperti sensor, gambar, dan catatan tekstual, akan menjadi lebih umum. Investigasi selanjutnya akan berkonsentrasi pada perumusan strategi untuk fusi data multimodal, yang akan memberikan pemeriksaan dan simulasi menyeluruh dari prosedur manufaktur yang rumit. Metode seperti transfer learning, arsitektur berbasis fusi, dan pembelajaran multi-tugas akan mempermudah integrasi sumber data yang berbeda dan meningkatkan kemampuan pemodelan prediktif.

Pembelajaran Terfederasi Dan Komputasi Tepi

Kedua konsep ini akan menjadi alat yang inovatif untuk mengimplementasikan model prediktif dalam pengaturan manufaktur semikonduktor. Latensi diturunkan dengan menggunakan komputasi tepi, yang juga meningkatkan reaktivitas dengan memfasilitasi inferensi dan pengambilan keputusan secara real-time langsung di rantai manufaktur.



Pembelajaran terfederasi menjaga keamanan dan privasi data dengan menjadikan pelatihan model kolaboratif bertanggung jawab di seluruh perangkat tepi yang tersebar tanpa bertukar data sensitif. Pemodelan prediktif terdesentralisasi dalam produksi semikonduktor akan dimungkinkan oleh perkembangan di masa mendatang dalam protokol komunikasi, algoritma pembelajaran terfederasi, dan infrastruktur komputasi tepi.

Teknologi Kembar Digital

Dalam produksi semikonduktor, teknologi kembar digital akan sangat penting untuk memungkinkan optimasi berbasis simulasi dan pemodelan prediktif. Kembaran digital menawarkan platform untuk pemantauan, analisis, dan peningkatan sistem produksi secara real-time. Mereka adalah salinan virtual dari proses manufaktur aktual. Model prediktif akan diintegrasikan ke dalam pengaturan kembar digital di masa mendatang, memungkinkan pengambilan keputusan proaktif untuk peningkatan hasil produksi, analisis skenario, dan pemeliharaan prediktif.

Aplikasi Komputasi Kuantum

Pemodelan prediktif dalam manufaktur semikonduktor adalah proses yang membutuhkan komputasi yang tinggi, dan komputasi kuantum dapat merevolusinya. Potensi untuk perhitungan yang jauh lebih cepat secara eksponensial dihadirkan oleh algoritma kuantum, seperti yang digunakan dalam pembelajaran mesin kuantum dan optimasi kuantum, yang seharusnya membuat pelatihan model, optimasi, dan inferensi menjadi lebih efektif. Investigasi selanjutnya akan meneliti kepraktisan implementasi komputasi kuantum dalam fabrikasi semikonduktor, mengatasi hambatan yang terkait dengan skalabilitas perangkat keras, pengurangan kesalahan, dan pembuatan algoritma.

Pertimbangan Etika Dan Regulasi

Masalah-masalah ini akan semakin menonjol seiring dengan meluasnya pemodelan prediktif di seluruh industri produksi semikonduktor. Pembentukan praktik terbaik, standar, dan pedoman untuk tata kelola data, transparansi algoritma, dan penerapan AI yang bertanggung jawab dalam produksi semikonduktor akan menjadi tujuan utama proyek-proyek di masa mendatang. Mendorong penggunaan teknologi pemodelan prediktif yang tepat dan mengatasi masalah etika akan membutuhkan kerja sama dari lembaga akademis, otoritas regulasi, dan pelaku industri.

Para pembuat semikonduktor dapat sepenuhnya memanfaatkan pemodelan prediktif untuk meningkatkan hasil produksi, menyederhanakan operasi, dan mendorong inovasi industri dengan merangkul arah dan tren baru ini. Kemampuan pemodelan prediktif untuk manufaktur semikonduktor akan mengalami perubahan revolusioner karena pembahasan yang berkelanjutan, kerja sama tim, dan terobosan teknologi.

4.11 KESIMPULAN

Singkatnya, prediksi peningkatan hasil produksi semakin akurat, menandakan revolusi dalam produksi semikonduktor. Pemodelan prediktif telah menjadi bagian penting dari optimasi proses, peningkatan kualitas produk, dan efisiensi operasional di fasilitas produksi




semikonduktor berkat kombinasi teknologi mutakhir, pendekatan kreatif, dan keahlian di bidangnya.

Investigasi ini telah menyoroti peran penting pemodelan prediktif dalam berbagai aspek manufaktur semikonduktor. Model prediktif telah membuktikan kemampuannya untuk menguraikan pola kompleks, mengekstrak wawasan yang dapat ditindaklanjuti, dan membekali para pengambil keputusan dengan pandangan ke depan yang diperlukan untuk menavigasi kompleksitas produksi semikonduktor kontemporer. Wawasan ini telah diterapkan pada deteksi dan klasifikasi cacat, optimasi proses, pemeliharaan prediktif, dan prediksi hasil, di antara aplikasi lainnya.

Lebih lanjut, karena jumlah titik data yang kecil, model pembelajaran mendalam tidak diperiksa dalam karya ini; namun demikian, model tersebut harus dimasukkan dalam pembahasan selanjutnya. Jelas bahwa lintasan model prediktif dalam manufaktur semikonduktor akan terus berkembang seiring kita melihat ke masa depan. Tren yang muncul yang akan mengubah permainan dan membuka jalan bagi inovasi dan penemuan termasuk XAI, komputasi tepi, dan augmentasi data spesifik domain.

Namun di tengah semua kegembiraan seputar kemajuan teknologi, sangat penting untuk menekankan betapa pentingnya isu etika, kepatuhan hukum, dan penerapan AI yang tepat. Seiring dengan meluasnya pemodelan prediktif, menjaga norma etika, melindungi privasi data, dan menjamin keterbukaan algoritma akan sangat penting untuk membangun kerja sama, kepercayaan, dan ekosistem inovasi dan kemajuan yang berkelanjutan. Perjalanan pemodelan prediktif untuk peningkatan hasil dalam manufaktur semikonduktor pada dasarnya adalah kisah tiga orang yang tidak pernah berhenti mengejar kesempurnaan. Pemodelan prediktif seperti mercusuar yang membimbing kita melalui labirin bisnis semikonduktor, menunjukkan kepada kita jalan menuju masa depan di mana kualitas, efisiensi, dan presisi bekerja sama untuk mendorong batas-batas kemungkinan.



BAB 5


AI UNTUK DETEKSI CACAT SEMIKONDUKTOR

5.1 PENDAHULUAN

Semikonduktor merupakan tulang punggung teknologi modern dan merupakan komponen penting dalam teknologi manufaktur. Oleh karena itu, memastikan produksi yang sempurna sangat penting – dan terlebih lagi mengingat kekurangan semikonduktor yang terjadi saat ini. Idealnya, teknologi deteksi cacat untuk wafer semikonduktor harus mempertimbangkan wafer secara keseluruhan.

Ketika ditemukan cacat, biasanya dicatat pada peta bin wafer untuk mengetahui berapa banyak cacat serupa yang ada dan apakah cacat tersebut terkonsentrasi di area tertentu dari seluruh permukaan wafer. Metode ini secara efektif mengidentifikasi cacat sistemik dan memungkinkan penghapusan dini produk cacat dari proses manufaktur. Namun, metode ini tidak memberikan informasi yang cukup detail untuk membedakan beberapa jenis cacat.

Tujuan utama bab ini adalah untuk memperluas tugas penentuan lokasi cacat dan lebih berfokus pada klasifikasi cacat menurut jenisnya. Upaya ini sangat penting, karena membantu dalam penentuan kesalahan yang mungkin tidak membuat produk sepenuhnya tidak berguna. Karena cacat dapat dikelompokkan, menjadi mudah untuk merespons dengan tepat untuk memulihkan chip yang masih layak jual, sehingga memanfaatkan sumber daya sebaik mungkin dan mengurangi kerugian. Untuk tujuan ini, citra die semikonduktor dianalisis. Citra ini diambil dari foto resolusi tinggi dari masing-masing chip pada wafer dan memberikan visi mikroskopis dari bidang semikonduktor dan gambaran tentang jenis dan tingkat cacat. Gambar 5.1 menunjukkan kategorisasi cacat dalam citra die semikonduktor.



Gambar 5.1 Kategorisasi Cacat Menggunakan Citra Die Semikonduktor.

Pembuatan wafer semikonduktor adalah proses yang kompleks dan rumit karena merupakan aktivitas yang terdiri dari begitu banyak tahapan yang saling terkait. Mulai dari pertumbuhan kristal silikon hingga fabrikasi mikro struktur transistor, setiap proses membutuhkan disiplin dan kontrol untuk memenuhi persyaratan kualitas yang ditetapkan.




Selain itu, proses pembuatan semikonduktor sangat kompleks menurut semua standar, dan jika dikombinasikan dengan pentingnya komponen-komponen yang membentuk perangkat elektronik, menjadi jelas mengapa pendekatan manajemen kualitas yang komprehensif diperlukan.

Karena beragamnya tuntutan dalam produksi semikonduktor, berbagai metode inspeksi digunakan di semua tahap produksi. Teknik-teknik ini dapat diklasifikasikan ke dalam berbagai strategi yang mencakup analisis makro dan mikroanalisis subjek. Misalnya, pengujian listrik dan analisis gelombang mikro memberikan informasi tentang kinerja fungsional, sementara kamera optik dan mikroskop elektron pemindai (SEM) membantu dalam menganalisis fitur skala nano.

Namun, karena teknik-teknik ini beragam, ada beberapa masalah yang muncul dari aspek identifikasi dan klasifikasi cacat dan oleh karena itu memerlukan pendekatan terpadu yang akan memanfaatkan kekuatan teknik sambil menghindari kekurangannya. Operasi deteksi cacat dapat ditingkatkan dengan bantuan analitik data dan algoritma pembelajaran mesin serta metode berbasis kecerdasan buatan (AI); ini akan membantu menjaga kontrol kualitas tinggi di seluruh proses manufaktur semikonduktor. Gambar 5.2 menunjukkan cacat pada berbagai tahapan produksi.

5.2 TONGGAK SEJARAH DAN KEMAJUAN MANUFAKTUR CHIP GLOBAL

Metode pembuatan dan pemeriksaan semikonduktor dapat digambarkan sebagai kemajuan bertahap dengan pengembangan teknik baru yang konstan. Kemajuan tersebut telah membantu pengembangan industri semikonduktor dengan menciptakan jalur untuk menghasilkan chip yang lebih kompleks. Berikut adalah gambaran rinci tentang tonggak dan kemajuan utama yang telah membentuk kondisi industri saat ini:



Gambar 5.2 Menunjukkan Cacat Pada Wafer Semikonduktor Selama Produksi.

1. Teknik Fabrikasi Semikonduktor Awal

- Ketika manufaktur semikonduktor masih dalam tahap awal, prosesnya sebagian besar manual dan primitif. Transistor dan sirkuit terpadu (IC) awal difabrikasi menggunakan teknik seperti fotolitografi dan etsa kimia.
- Tembaga umumnya digunakan sebagai material semikonduktor, tetapi silikon lebih disukai karena kelimpahannya dan karakteristik semikonduktor yang menguntungkan.


2. Pengenalan Lingkungan Ruang Bersih



- Teknologi ruang bersih diformalkan pada tahun 1960-an, meskipun ini adalah periode ketika pertama kali diperkenalkan dalam produksi semikonduktor. Ruang bersih adalah lingkungan yang dirancang untuk memiliki tingkat partikel udara yang rendah, karena ini penting dalam perlindungan material semikonduktor.
- Klasifikasi ruang bersih masih dinamis karena ada peningkatan berkelanjutan dalam sistem filtrasi, ventilasi, dan pengendalian kontaminasi.

3. Kemajuan dalam Fotolitografi

- Fotolitografi menjadi proses teknologi kunci di bidang perangkat semikonduktor pada wafer silikon. Pada awal fotolitografi, wafer dilapisi dengan bahan fotosensitif yang dikenal sebagai photoresist, disinari cahaya melalui masker, dan kemudian diukir secara kimia untuk mereplikasi pola tersebut.
- Pada tahun-tahun berikutnya, peningkatan dalam proses fotolitografi seperti litografi ultraviolet dalam dan ultraviolet ekstrem memungkinkan pembuatan fitur halus dan lebih banyak transistor. Gambar 5.3 menggambarkan perkembangan historis ukuran fitur IC dan teknologi fotolitografi.



Gambar 5.3 Perkembangan historis ukuran fitur IC dan teknologi fotolitografi.

4. Pengenalan Integrasi Proses

- Pada tahun 1970-an, gagasan menggabungkan berbagai langkah manufaktur menjadi satu proses yang lancar mulai menjadi penting. Metode ini membantu membuat komponen elektronik yang lebih canggih dengan menyatukan banyak bagian yang kompleks.
- Menggabungkan langkah-langkah seperti menempatkan material di permukaan, memotong bagian, dan menambahkan material tertentu adalah bagian dari



integrasi proses. Ini membantu menciptakan bagian dan koneksi yang detail pada komponen silikon yang digunakan dalam elektronik.

5. Pengenalan Wafer Stepper dan Scanner

- Wafer stepper dan scanner mengubah cara pembuatan semikonduktor dengan memungkinkan seluruh permukaan wafer terpapar cahaya sekaligus, yang mempercepat proses dan menghasilkan lebih banyak chip.
- Stepper dan scanner menggunakan lensa khusus dan sistem canggih untuk menempatkan desain sirkuit secara akurat dan konsisten pada wafer silikon.

6. Munculnya Alat Metrologi dan Inspeksi Semikonduktor

- Seiring dengan semakin kecilnya ukuran komponen dalam perangkat semikonduktor, sangat penting untuk memiliki alat pengukuran dan pengecekan yang akurat. Alat-alat seperti SEM, mikroskop gaya atom (AFM), dan sistem inspeksi optik kini sangat penting untuk melihat bagian-bagian kecil semikonduktor dan menemukan kesalahan kecil apa pun.
- Alat-alat ini membantu perusahaan yang membuat semikonduktor memeriksa ukuran perangkat mereka, menemukan kesalahan apa pun, dan memastikan semuanya dibuat dengan benar selama seluruh proses produksi.

7. Integrasi Sistem Kontrol Proses Lanjutan

- Sistem kontrol proses lanjutan (APC) menggunakan analitik data dan algoritma pembelajaran mesin untuk memeriksa, menganalisis, dan mengoptimalkan proses fabrikasi semikonduktor secara real-time. Sistem APC memungkinkan produsen semikonduktor untuk mencapai kualitas produk yang konsisten dan memaksimalkan hasil produksi.
- Sistem APC menggabungkan sensor, aktuator, dan mekanisme umpan balik untuk menyesuaikan parameter proses dan mempertahankan kinerja optimal.

8. Munculnya Litografi Komputasional

- Litografi komputasional telah muncul sebagai pendukung penting teknik pembuatan pola semikonduktor canggih. Dengan memanfaatkan model dan algoritma komputasional, produsen semikonduktor dapat mensimulasikan dan mengoptimalkan proses litografi yang kompleks untuk mencapai resolusi dan fidelitas pola yang lebih tinggi.
- Litografi komputasional sangat penting untuk merancang dan memproduksi perangkat semikonduktor generasi berikutnya dengan ukuran fitur yang lebih kecil dan kepadatan transistor yang lebih tinggi.

9. Pengenalan Sistem Peninjauan dan Klasifikasi Cacat

- Seiring dengan semakin kompleksnya perangkat semikonduktor, kebutuhan akan sistem peninjauan dan klasifikasi cacat yang lebih baik semakin meningkat. Sistem ini menggunakan algoritma pembelajaran mesin dan teknik analisis gambar untuk secara akurat mendeteksi, mengkategorikan, dan menganalisis kesalahan pada wafer semikonduktor.



- Sistem peninjauan dan klasifikasi cacat memungkinkan produsen semikonduktor untuk dengan cepat mendiagnosis kesalahan, mengoptimalkan parameter proses, dan meningkatkan kualitas produk.

10. Integrasi Teknologi Industri 4.0

- Prinsip-prinsip Industri 4.0, seperti proses otomatis, konektivitas, dan pengambilan keputusan berbasis data, menjadikan manufaktur semikonduktor lebih efisien dan lincah. Robotika canggih, perangkat internet of things, dan platform analitik berbasis cloud mendefinisikan ulang cara kerja fasilitas manufaktur semikonduktor.
- Teknologi Industri 4.0 memungkinkan pemeliharaan prediktif, optimasi proses secara real-time, dan strategi manufaktur adaptif, sehingga meningkatkan produktivitas, fleksibilitas, dan kualitas dalam manufaktur semikonduktor.

5.3 RINTANGAN UTAMA DALAM PENGAWASAN KUALITAS SEMIKONDUKTOR

Inspeksi semikonduktor menghadapi beberapa tantangan, yang terkait erat dengan dorongan perusahaan untuk berinovasi dan ukuran semikonduktor yang semakin mengecil. Tantangan utama adalah meningkatnya kompleksitas desain semikonduktor. Setiap lompatan dalam generasi semikonduktor menyebabkan IC berubah menjadi struktur yang semakin kompleks, yang dicirikan oleh lebih banyak lapisan, ukuran fitur yang lebih halus, dan toleransi yang lebih ketat. Akibatnya, jalinan kerumitan yang kusut menghadirkan keterbatasan yang harus diatasi oleh skema deteksi yang ambisius untuk secara akurat menangkap setiap kesalahan atau penyimpangan di sepanjang beberapa lapisan dan bagian yang saling terkait.

Selain itu, lapisan kompleksitas lain ditambahkan selama proses inspeksi karena permintaan yang tak henti-hentinya untuk throughput tinggi dalam manufaktur. Fasilitas semikonduktor beroperasi dengan kecepatan luar biasa, didorong oleh nafsu yang tak terpuaskan akan semikonduktor. Dengan demikian, sistem inspeksi harus mampu menangani volume wafer atau chip yang besar dengan mudah dan akurat. Teknik investigasi klasik, yang memadai ketika industri berjalan dengan kecepatan lebih lambat, tidak dapat mengimbangi lini produksi yang bergerak cepat saat ini. Oleh karena itu, perlu dikembangkan alat inspeksi otomatis.


Selain itu, bagi produsen semikonduktor, mencapai hasil yang lebih tinggi sambil mempertahankan kualitas tinggi akan terus menjadi salah satu aspek paling menantang dalam pembuatan produk dengan kinerja dan keandalan yang diharapkan yang dibutuhkan oleh aplikasi komputasi dan komunikasi kritis. Kebutuhan akan peningkatan hasil merupakan faktor kunci untuk menjaga perusahaan semikonduktor tetap sangat kompetitif dan untuk mempertahankan profitabilitas yang sehat di pasar yang sangat kompetitif. Kebutuhan ini juga semakin menantang seiring dengan semakin kompleksnya perangkat semikonduktor. Inspeksi semikonduktor berfungsi sebagai pendorong utama untuk peningkatan hasil melalui identifikasi dan karakterisasi cacat yang berpotensi memengaruhi kinerja dan keandalan produk. Kebutuhan untuk meningkatkan target hasil sambil mempertahankan kualitas tinggi membutuhkan kemampuan untuk mengembangkan skema karakterisasi dan klasifikasi cacat yang ampuh yang memanfaatkan algoritma pembelajaran mesin dan AI untuk mendeteksi

cacat dengan presisi yang lebih tinggi sambil menyederhanakan proses pengoptimalan operasi manufaktur.

Selain itu, sistem APC menggunakan teknik canggih untuk memanipulasi sistem, yang menambah lapisan kompleksitas ekstra dalam inspeksi semikonduktor. Perangkat APC yang berada di garis depan pemantauan dan kontrol waktu nyata memerlukan integrasi simbiosis dengan fakta inspeksi untuk memulai modifikasi guna optimasi hasil produksi. Fakta yang kuat, kemampuan analitik, dan interoperabilitas yang lancar antara perangkat inspeksi semikonduktor dan perangkat manufaktur sangat penting untuk mewujudkan integrasi simbiosis ini, dan pemodelan kompleks serta strategi analitik prediktif sangat penting untuk mengantisipasi dan mencegah cacat kemampuan sebelum kegagalan terjadi, sementara perangkat semikonduktor memenuhi permintaan pasar yang terus meningkat di tengah perubahan teknologi yang meluas.

5.4 KEUNGGULAN ARSITEKTUR CNN UNTUK KLASIFIKASI GAMBAR

Pengembangan dan aplikasi beberapa jenis jaringan saraf tiruan telah dilakukan baik dalam pembahasan maupun produksi. Meskipun demikian, jaringan saraf konvolusional (CNN) telah menjadi sorotan karena hasil luar biasa yang telah dicapai di bidang pengenalan gambar, terutama pada dataset seperti basis data MNIST, CIFAR-10, dan ImageNet.



Gambar 5.4 Arsitektur jaringan saraf konvolusional.

Kemampuan CNN untuk memodelkan sifat gambar yang menyerupai grid dan kebutuhan komputasi yang lebih kecil daripada jaringan saraf konvensional, karena neuron yang terorganisasi secara spasial dan mekanisme pooling, menjadi alasan kinerja superiornya



dalam aplikasi ini. Terlebih lagi, CNN menunjukkan kapasitas yang luar biasa untuk mengenali perbedaan antara sejumlah besar kelas.

Bahkan, CNN mewakili jenis pembelajaran ujung-ke-ujung yang mengurangi kebutuhan kontribusi manusia. Desainnya menggabungkan proses ekstraksi fitur dan klasifikasi, sehingga menjadikannya sangat tepat untuk tugas pengenalan gambar yang efisien. CNN memiliki empat lapisan utama: konvolusi, aktivasi rectified linear unit (ReLU), pooling, dan lapisan penghubung. Setelah beberapa putaran konvolusi dan pooling, CNN menggunakan lapisan penghubung untuk melakukan penalaran pada tingkat yang lebih tinggi, menghitung skor kelas untuk data yang masuk. Dalam kasus dengan banyak kelas, mereka menggunakan fungsi SoftMax. Fungsi ini memberikan probabilitas untuk setiap kelas input, memastikan semua probabilitas berjumlah 1. Gambar 5.4 menyoroti arsitektur CNN.

5.5 INSPIRASI ARSITEKTUR KLASIFIKASI UNTUK DETEKSI CACAT

Di masa lalu, CNN menghadapi tantangan besar karena membutuhkan sejumlah besar data berlabel, yang menyebabkan biaya pemrosesan yang tinggi. Masalah ini membaik ketika orang-orang menciptakan kumpulan data berlabel besar seperti ImageNet, CIFAR-10, CIFAR-100, dan basis data MNIST. Selain itu, peningkatan dalam komputasi paralel dengan unit pemrosesan grafis (GPU) dan kluster terdistribusi besar menurunkan batas komputasi. Hal ini memungkinkan untuk menangani kumpulan data besar ini dengan lebih baik.

Tantangan pengenalan visual skala besar ImageNet (ILSVRC) memiliki dampak yang sangat besar dalam mendorong jaringan saraf dalam untuk visi komputer. ILSVRC mempermudah pembangunan dan evaluasi struktur jaringan saraf yang lebih kompleks dengan menyediakan standar untuk mengukur berbagai sistem klasifikasi gambar. Tantangan ImageNet menghasilkan dua sistem klasifikasi gambar utama: Jaringan VGG (VGG-Net) dan Jaringan Residual (ResNet). Simonyan dan Zisserman menciptakan VGG-Net pada tahun 2014, yang memiliki dampak signifikan pada eksplorasi struktur jaringan yang lebih dalam. VGG-Net menggunakan filter konvolusi 3×3 yang sangat kecil, yang membantu jaringan mendeteksi detail kecil dalam gambar sambil menjaga jumlah parameter tetap terkendali. Desain ini memungkinkan jaringan untuk tumbuh hingga 16–19 lapisan bobot, mencapai akurasi tinggi sebesar 7,3% pada ILSVRC 2014. Peningkatan kedalaman jaringan meningkatkan kinerja klasifikasi, menetapkan standar baru untuk arsitektur CNN.

ResNet, yang diperkenalkan oleh Microsoft Research Asia pada tahun 2015, membawa perubahan besar dengan struktur jaringan 152 lapisan yang mengubah permainan. Terobosan utama ResNet adalah pembelajaran residual. Ini melibatkan pembelajaran fungsi residual yang berkaitan dengan lapisan input alih-alih hanya mempelajari pemetaan yang mendasarinya. Metode ini mempermudah pengoptimalan jaringan yang sangat dalam dengan mengatasi masalah degradasi. Masalah ini terjadi ketika penambahan lebih banyak lapisan menghasilkan kinerja yang lebih buruk. Desain ResNet memanfaatkan sepenuhnya kedalaman yang jauh lebih besar. Hal ini menghasilkan akurasi yang lebih baik, dan memenangkan ILSVRC 2015 dengan tingkat kesalahan rendah sebesar 3,6%.



Berlandaskan pada fondasi yang diletakkan oleh karya-karya inovatif ini, pembahasan kami bertujuan untuk menggunakan metode transfer learning dan mengadaptasi desain jaringan berkinerja tinggi ini untuk proyek Deep Learning for Anomaly Detection and Classification (DLADC) kami. Dengan memanfaatkan fitur unik VGG-Net dan ResNet, kami berharap dapat memperluas batasan deteksi dan klasifikasi anomali, meningkatkan akurasi dan efektivitas dalam menemukan dan memilah anomali dalam berbagai dataset.

5.6 AI PRESISI UNTUK PABRIK MODERN

Pembahasan tentang penggunaan CNN untuk memeriksa dan menemukan cacat pada semikonduktor terus berkembang. CNN memiliki keunggulan dibandingkan metode pembelajaran mesin biasa. Mereka dapat mempelajari pola kompleks langsung dari gambar semikonduktor tanpa perlu campur tangan manusia atau membuat fitur unik.

Kemampuan ini terbukti bermanfaat dalam pembuatan chip dan wafer. Hal ini memungkinkan produsen untuk mendeteksi cacat, yang membantu mereka menjaga produk mereka tetap berkualitas tinggi dan andal. CNN memiliki kemampuan untuk mendeteksi pola dan struktur kompleks dalam gambar semikonduktor.

Mereka dapat memilih fitur menggunakan lapisan konvolusi dan pooling pada tingkat detail yang berbeda. Berkat pengaturan seperti grid pada gambar semikonduktor, CNN dapat mendeteksi cacat kecil seperti partikel, goresan, atau perubahan pola yang mungkin menunjukkan masalah manufaktur. Terlebih lagi, CNN fleksibel dalam tugas deteksi cacat. Mereka dapat beradaptasi dengan perbedaan dalam gambar semikonduktor yang disebabkan oleh hal-hal seperti berbagai metode fabrikasi, material, dan pengaturan peralatan.

CNN cocok untuk inspeksi semikonduktor. Mereka dapat menangani banyak informasi visual dan bekerja dengan baik pada sampel baru. Melatih CNN pada berbagai cacat membantu mereka mendeteksi lebih banyak masalah. Terdapat dataset berlabel untuk inspeksi semikonduktor, seperti Standar dan Pedoman SEMI (Semiconductor Equipment and Materials International) untuk Cacat dalam Manufaktur Semikonduktor. Selain itu, teknologi akselerasi perangkat keras yang lebih baik seperti GPU dan akselerator khusus, memungkinkan integrasi sistem inspeksi berbasis CNN yang lancar di pabrik chip. Teknologi ini juga meningkatkan output dan skalabilitas.

Sebagai kesimpulan, CNN menunjukkan potensi besar untuk inspeksi semikonduktor. Mereka menawarkan cara otomatis, akurat, dan terukur untuk mendeteksi cacat dan mengontrol kualitas dalam produksi semikonduktor. Seiring kemajuan teknologi di bidang ini, CNN akan memainkan peran kunci dalam membuat produksi semikonduktor lebih efektif dan andal.

5.7 PROSES PENGUMPULAN DATA INSPEKSI DIGITAL


1. Citra Wafer

- **Lingkungan Manufaktur:** Orang mengambil citra wafer di pabrik fabrikasi semikonduktor (fab). Tempat-tempat ini memiliki kontrol ketat, seperti ruang bersih



(cleanroom), untuk menjaga tingkat kontaminasi tetap rendah dan memastikan data tetap baik.

- **Sistem Pencitraan Otomatis:** Sistem pencitraan otomatis dengan kamera beresolusi tinggi mengambil gambar wafer. Sistem ini dapat menjadi bagian dari peralatan manufaktur semikonduktor atau ada sebagai stasiun inspeksi terpisah.
- **Pencitraan Berurutan:** Kamera mengambil gambar wafer satu demi satu saat wafer melewati berbagai langkah fabrikasi, seperti deposisi, litografi, etsa, dan anil. Pencitraan langkah demi langkah ini membantu produsen untuk mengawasi bagaimana permukaan wafer berubah dan segera mendeteksi masalah atau cacat apa pun.
- **Anotasi Metadata:** Produsen menambahkan metadata seperti ID wafer, nomor lot, langkah fabrikasi, dan stempel waktu ke gambar wafer. Ini memudahkan untuk melacak dan menelusuri wafer.




Gambar 5.5 Contoh wafer silikon.

Gambar 5.5 menggambarkan citra contoh wafer silikon.

2. Citra Die

- **Ekstraksi Die:** Teknik pemrosesan citra seperti segmentasi dan pemotongan membantu mengekstrak citra die dari citra wafer. Metode ini menemukan dan mengisolasi setiap chip (die) individual pada wafer untuk menghasilkan citra tingkat die untuk inspeksi.
- **Pencitraan Resolusi Tinggi:** Citra die, seperti halnya citra wafer, diambil dengan kamera resolusi tinggi. Ini memastikan tampilan detail setiap chip. Gambar resolusi tinggi membantu menemukan cacat kecil dan fitur aneh yang dapat memengaruhi seberapa baik chip tersebut bekerja.
- **Berbagai Sudut Pandang:** Kamera dapat mengambil citra die dari berbagai sudut (seperti dari atas atau miring). Ini menangkap berbagai fitur permukaan dan membantu menganalisis cacat.



3. Citra Cacat

- **Lokalisasi Cacat:** Algoritma otomatis atau operator manusia menemukan cacat pada citra wafer atau die. Setelah mereka menemukan cacat ini, mereka menandai area dengan cacat untuk dilihat lebih dekat nanti.
- **Pencitraan Perbesaran Tinggi:** Gambar cacat diambil dengan perbesaran tinggi untuk menunjukkan cacat secara detail. Ini seringkali melibatkan penggunaan mikroskop khusus, seperti SEM atau AFM, untuk melihat hal-hal sekecil nanometer.
- **Klasifikasi Cacat:** Gambar cacat diurutkan berdasarkan jenis, ukuran, bentuk, dan seberapa parahnya. Ini membantu pembuat fokus pada cara terpenting untuk memperbaiki cacat dan meningkatkan proses mereka untuk mencegah cacat serupa terjadi lagi.

4. Anotasi Metadata

- **Anotasi Semantik:** Bersamaan dengan penandaan cacat pada gambar, informasi tambahan seperti jenis cacat, ukurannya, lokasinya, dan seberapa parahnya ditambahkan ke data gambar. Ini memberikan informasi latar belakang lebih lanjut saat melihat cacat.
- **Integrasi Basis Data:** Gambar cacat yang dianotasi dan informasi terkait masuk ke basis data pusat atau sistem manajemen data. Ini membantu orang menemukan, menganalisis, dan membuat keputusan tentang data selama pembuatan chip.

5.8 TEKNIK PEMBERSIHAN DAN PENGUATAN DATA GAMBAR

Mempersiapkan gambar semikonduktor untuk analisis pembelajaran mesin sangat penting. Orang sering menggunakan metode ini untuk membuat data gambar lebih akurat dan bermanfaat:

1. **Normalisasi:** Normalisasi mengubah nilai setiap piksel gambar ke skala umum, biasanya $[0, 1]$ atau $[-1, 1]$. Ini menjaga intensitas piksel tetap sama di seluruh gambar, sehingga model pembelajaran mesin dapat menemukan lebih banyak pola dan fitur dalam data.
2. **Augmentasi:** Teknik augmentasi gambar menciptakan lebih banyak contoh pelatihan dari gambar sumber dengan melakukan perubahan seperti rotasi, pembalikan, penskalaan, atau pemotongan. Proses ini berdampak pada rentang dan kekuatan data pelatihan, mengurangi risiko overfitting, dan meningkatkan kemampuan model untuk melakukan generalisasi.
3. **Pengurangan Kebisingan:** Metode pengurangan kebisingan membersihkan atau mengurangi elemen dan distorsi yang tidak diinginkan dalam gambar, yang dapat terjadi karena hal-hal seperti kebisingan sensor, debu, atau kompresi gambar. Pendekatan umum mencakup filter penghalus seperti Gaussian blur atau median filtering, yang membantu mempertahankan fitur gambar penting sambil mengurangi noise.


Penggunaan metode pra-pemrosesan ini berdampak pada seberapa baik gambar semikonduktor dipersiapkan untuk dianalisis dengan model pembelajaran mesin. Ini



memastikan bahwa model dapat belajar dan memilih pola dan fitur yang bermakna dari data secara akurat, yang mengarah pada sistem yang lebih andal dan efisien untuk memeriksa semikonduktor.

5.9 BARISAN MODEL LEGENDARIS YANG MENGUBAH CARA AI BELAJAR

1. **LeNet:** Yann LeCun dan timnya menciptakan LeNet pada tahun 1990-an. Ini adalah salah satu desain CNN pertama. LeNet memiliki lapisan yang berbeda, seperti lapisan konvolusi, lapisan max-pooling, dan lapisan yang terhubung sepenuhnya. Meskipun tidak serumit desain yang lebih baru, LeNet tetap bekerja dengan baik untuk tugas-tugas pengurutan gambar dasar, seperti yang ada dalam pemeriksaan semikonduktor. Tata letaknya yang sederhana membuka pintu bagi CNN yang lebih canggih. Ini menunjukkan betapa kuatnya pembelajaran mendalam untuk bekerja dengan gambar.
2. **AlexNet:** AlexNet, yang dikembangkan oleh Alex Krizhevsky dan timnya pada tahun 2012, menandai langkah besar ke depan dalam desain CNN. Strukturnya memiliki beberapa lapisan konvolusi, dengan lapisan max-pooling tepat setelahnya, dan lapisan terhubung di bagian akhir. Ketika AlexNet memenangkan ILSVRC, hal itu menunjukkan betapa bagusnya pembelajaran mendalam untuk mengurutkan gambar. Orang-orang telah menggunakan model ini di banyak bidang, termasuk memeriksa semikonduktor, karena dapat menangani data gambar yang kompleks dan tetap dapat mengurutkan gambar.
3. **VGG:** Karen Simonyan dan Andrew Zisserman mengembangkan jaringan VGG pada tahun 2014. Jaringan ini menonjol karena strukturnya yang seragam, yang menggunakan filter konvolusi kecil (3×3) dan lapisan max-pooling. Desain seragam jaringan VGG membuatnya sederhana namun bagus dalam mengklasifikasikan gambar. Arsitektur ini mengambil pendekatan langsung untuk membuat jaringan lebih dalam (hingga 19 lapisan) sambil tetap menjaga kebutuhan komputasi. Hal ini terbukti bermanfaat dalam memilah gambar semikonduktor di mana kejelasan dan ketepatan sangat penting.
4. **ResNet:** Kaiming memperkenalkan ResNet. Pada tahun 2015, ia dan timnya menciptakan metode terobosan untuk pembelajaran mendalam yang disebut pembelajaran residual. Ini melibatkan pembuatan koneksi pintasan (atau lewati) yang melewati satu atau lebih lapisan. Koneksi ini memungkinkan jaringan yang sangat dalam, seringkali dengan ratusan lapisan, untuk dilatih dengan memecahkan masalah gradien yang menghilang, yang sering menghambat pelatihan jaringan yang dalam. ResNet telah mencapai kinerja terbaik dalam banyak tugas klasifikasi gambar, dan orang-orang memujinya karena kekuatan dan efektivitasnya. Kemampuannya untuk terus berkinerja baik seiring bertambahnya kedalaman menjadikannya pilihan yang tepat untuk pekerjaan kompleks inspeksi semikonduktor.



5.10 MENYUSUN STRATEGI AGAR MODEL AI BELAJAR DENGAN CERDAS DAN CEPAT

1. Pemisahan Data

- **Tujuan:** Pemisahan data memainkan peran kunci dalam pelatihan dan pengecekan seberapa baik model CNN bekerja. Ini melibatkan pemecahan dataset menjadi tiga bagian berbeda: set untuk pelatihan, validasi, dan pengujian.
- **Set Pelatihan:** Set untuk pelatihan merupakan bagian besar dari dataset dan membantu melatih model CNN. Saat dilatih, model belajar untuk mengenali pola dan fitur dalam gambar semikonduktor beserta labelnya.
- **Set Validasi:** Set ini membantu menyesuaikan pengaturan dan mengawasi kinerja model selama pelatihan. Dengan memeriksa kinerja model pada data validasi secara teratur, kita dapat melakukan perubahan untuk mencegahnya terlalu banyak atau terlalu sedikit menyesuaikan diri dengan data.
- **Set Pengujian:** Set pengujian membantu memeriksa seberapa baik kinerja model yang telah dilatih. Ini memberikan penilaian yang adil tentang kemampuan model untuk bekerja dengan data baru, memastikan model bekerja dengan baik dalam kasus dunia nyata.

2. Penyetelan Hyperparameter

- **Tingkat Pembelajaran:** Tingkat pembelajaran menentukan seberapa besar langkah-langkah saat memperbarui parameter selama pelatihan. Ini adalah pengaturan kunci yang memiliki pengaruh besar pada seberapa cepat model meningkat dan seberapa baik kinerjanya secara keseluruhan. Kita dapat menggunakan metode tingkat pembelajaran dan metode tingkat pembelajaran adaptif (seperti Adam) untuk mengubah tingkat pembelajaran seiring berjalannya pelatihan.
- **Ukuran Batch:** Ukuran batch menentukan berapa banyak sampel yang diperiksa dalam setiap putaran pelatihan. Batch yang lebih besar membantu mencapai tujuan lebih cepat, tetapi membutuhkan lebih banyak memori dan daya komputasi. Metode seperti normalisasi batch dan akumulasi gradien dapat membantu menjaga pelatihan tetap stabil saat menggunakan batch besar.
- **Parameter Regularisasi:** Trik regularisasi seperti regularisasi L1 dan L2 atau dropout menghentikan overfitting. Hal ini dilakukan dengan menjaga nilai parameter tetap terkendali atau mematikan unit selama pelatihan. Kekuatan regularisasi bergantung pada hyperparameter. Ini perlu disesuaikan agar model bekerja dengan optimal.
- **Pencarian Hyperparameter:** Ini melibatkan pencarian berbagai kombinasi hyperparameter untuk membuat model bekerja lebih baik. Anda dapat menggunakan metode seperti pencarian grid, pencarian acak, dan optimasi Bayesian untuk memeriksa berbagai opsi hyperparameter dan menemukan yang terbaik.

3. Algoritma Optimasi

- **Stochastic Gradient Descent:** Stochastic gradient descent (SGD) adalah cara untuk melatih model pembelajaran mesin dalam jaringan saraf dalam. Ini berbeda dari metode penurunan gradien biasa. SGD menyesuaikan pengaturan model untuk titik




data individual atau kelompok kecil daripada melihat semua data sekaligus. Pendekatan ini membuat perhitungan lebih cepat dan membantu model belajar lebih cepat. SGD bekerja dengan baik dengan dataset besar di mana tidak mungkin untuk memproses semuanya sekaligus.

- **Adam:** Adam adalah algoritma optimasi laju pembelajaran yang terbuka untuk input. Ia menggunakan momentum dan RMSprop. Ia mengubah kecepatan pelatihan untuk setiap parameter berdasarkan momen pertama dan kedua dari gradien. Ini menghasilkan konvergensi yang lebih cepat dan standardisasi yang lebih baik.
- **RMSprop:** RMSprop adalah algoritma lain yang menyesuaikan laju pembelajaran. Ia menggunakan rata-rata bergerak dari gradien kuadrat untuk menghitung laju pelatihan untuk setiap parameter dalam algoritma. Ini memecahkan masalah gradien yang menghilang atau meledak dengan mengubah laju pembelajaran secara langsung berdasarkan riwayat gradien terbaru.
- **Fungsi Kerugian:** Fungsi kerugian yang Anda gunakan bergantung pada apa yang ingin Anda lakukan dengan inspeksi semikonduktor Anda. Jika Anda mengelompokkan banyak hal ke dalam beberapa kategori, cross-entropy untuk beberapa kategori adalah pilihan yang tepat. Untuk keputusan ya atau tidak, binary cross-entropy bekerja dengan baik. Ketika Anda perlu memprediksi angka, mean squared error dapat melakukannya.

Dengan melihat cara membagi data, menyesuaikan pengaturan, dan memilih trik matematika yang tepat, perusahaan dapat membangun dan meningkatkan model CNN yang bekerja dengan baik untuk memeriksa semikonduktor. Ini membantu mereka mendeteksi cacat dan menjaga kualitas tetap tinggi saat membuat komponen elektronik kecil ini.

5.11 PARAMETER EVALUASI KINERJA MODEL PREDIKTIF

1. **Akurasi:** Akurasi adalah statistik dasar yang menunjukkan persentase item yang dikelompokkan dalam suatu dataset. Ini memberikan gambaran lengkap tentang seberapa tepat model tersebut dengan menunjukkan berapa banyak prediksi yang sesuai dengan label sebenarnya. Untuk pemeriksaan semikonduktor, akurasi adalah tanda kunci seberapa baik model tersebut mendeteksi cacat atau hal-hal aneh dalam gambar semikonduktor. Tetapi akurasi saja mungkin tidak menceritakan keseluruhan cerita dengan dataset yang tidak merata, di mana satu kelompok jauh lebih besar daripada yang lain. Jadi, meskipun akurasi memberikan informasi penting tentang seberapa bermanfaat model tersebut, sebaiknya digunakan bersama dengan ukuran lain untuk mendapatkan gambaran yang lebih baik tentang seberapa baik model tersebut bekerja.
2. **Presisi:** Presisi mengukur seberapa baik model tersebut menghindari positif palsu dengan menghitung rasio prediksi positif sejati terhadap semua prediksi positif yang dibuat model. Metrik ini sangat penting dalam inspeksi semikonduktor karena menunjukkan seberapa baik model tersebut dapat mendeteksi cacat nyata tanpa



menandai bagian yang baik sebagai buruk. Presisi tinggi berarti model tersebut menghasilkan sangat sedikit alarm palsu, yang sangat penting untuk mengurangi tindakan atau langkah tindak lanjut yang tidak perlu yang disebabkan oleh positif palsu ini. Presisi berfungsi sebagai metrik kinerja vital yang dapat digunakan produsen untuk mengevaluasi seberapa andal dan tepercaya sistem deteksi cacat di lingkungan produksi semikonduktor.

3. **Recall (Sensitivitas):** Recall, juga disebut tingkat positif sejati, mengevaluasi seberapa baik model dapat menunjukkan semua kasus positif. Hal ini dilakukan dengan membandingkan bagian prediksi positif sejati dengan semua kejadian positif aktual dalam dataset. Dalam pengujian chip, recall memainkan peran kunci dalam memastikan deteksi cacat yang menyeluruh. Ini menunjukkan seberapa baik model dapat menemukan semua bagian yang rusak tanpa melewatkan satu pun. Recall yang tinggi berarti model mengidentifikasi sebagian besar kasus positif, yang menurunkan kemungkinan cacat yang tidak terdeteksi lolos dari inspeksi. Produsen fokus pada recall ketika melewatkan cacat dapat memiliki konsekuensi yang mendalam. Ini menyoroti betapa pentingnya memiliki deteksi cacat yang ketat di jalur produksi chip.
4. **Skor F1:** Skor F1 menyeimbangkan antara presisi dan recall dengan menghitung rata-rata harmoniknya. Ini menawarkan penilaian menyeluruh tentang seberapa baik kinerja suatu model dengan mempertimbangkan baik false positive maupun false negative. Di bidang inspeksi semikonduktor, skor F1 berfungsi sebagai metrik evaluasi lengkap yang menjelaskan hubungan antara presisi dan recall. Skor F1 yang tinggi menunjukkan bahwa model mencapai perpaduan optimal antara presisi dan recall, mengurangi false alarm sambil menangkap semua kejadian positif. Produsen menggunakan skor F1 untuk memeriksa efektivitas dan keandalan keseluruhan sistem deteksi cacat, memastikan mereka mengevaluasi kinerjanya di berbagai kondisi operasi.
5. **Area di bawah Kurva ROC:** Area di bawah kurva karakteristik operasi penerima (ROC), atau AUC-ROC, menilai seberapa baik suatu model dapat membedakan kelas yang berbeda. Ini dilakukan dengan menunjukkan tingkat true positive terhadap tingkat false positive pada berbagai tingkat ambang batas. Skor AUC-ROC yang lebih tinggi berarti model dapat membedakan kelas dengan lebih baik, dengan tingkat true positive yang lebih tinggi dan tingkat false positive yang lebih rendah pada titik keputusan yang berbeda. Dalam inspeksi semikonduktor, AUC-ROC memainkan peran kunci untuk mengukur seberapa baik model dapat mendeteksi perbedaan antara komponen yang rusak dan yang baik. Produsen mengandalkan AUC-ROC untuk memeriksa akurasi penyortiran keseluruhan model dan kemampuannya untuk membuat pilihan yang tepat saat melihat gambar semikonduktor.
6. **Matriks Konfusi:** Matriks konfusi menunjukkan seberapa baik model memprediksi dibandingkan dengan label aktual. Matriks ini menampilkan positif sejati, positif palsu, negatif sejati, dan negatif palsu. Ini memberi kita wawasan penting tentang kinerja model di berbagai kelas, memungkinkan kita untuk melihat lebih dekat apa yang



dilakukannya dengan baik dan di mana ia kurang berhasil. Dalam inspeksi semikonduktor, matriks konfusi membantu produsen menemukan area spesifik di mana model unggul atau kesulitan. Ini memungkinkan mereka untuk fokus pada peningkatan. Dengan melihat matriks konfusi, produsen dapat lebih memahami bagaimana model memprediksi dan membuat pilihan yang lebih cerdas untuk meningkatkan kemampuannya dalam mendeteksi dan menyortir cacat.

Masing-masing metrik evaluasi ini memberi kita wawasan berbeda tentang seberapa baik model pembelajaran mendalam bekerja untuk memeriksa semikonduktor. Hal ini membantu produsen untuk meningkatkan sistem deteksi cacat mereka dan menghasilkan perangkat semikonduktor berkualitas tinggi.

5.12 MEMBUKTIKAN KETANGGUHAN KECERDASAN BUATAN DI LANTAI FABRIKASI

Pada bab ini, kita telah meneliti secara saksama seberapa baik kinerja model CNN dalam menilai citra semikonduktor. Kami menjalankan pengujian yang cermat untuk mengevaluasi berbagai desain CNN, seperti AlexNet, VGG, dan ResNet, menggunakan dataset citra semikonduktor dari pabrik. Kami memilih dataset ini dan menambahkannya untuk memastikan cakupannya luas dan representatif. Untuk meningkatkan kualitas dan variasi dataset, kami menggunakan metode seperti normalisasi dan augmentasi data. Hal ini memungkinkan kami untuk melatih dan mengevaluasi model dengan lebih baik.

Ketika kami menggali lebih dalam hasil eksperimen kami, kami menemukan beberapa hal menarik. Model CNN bagus dalam mendeteksi dan memilah cacat pada citra semikonduktor. Mereka berhasil lebih dari 90% dari waktu, terlepas dari model mana yang kami gunakan. Ini menunjukkan bahwa pembelajaran mendalam sangat efektif untuk memeriksa semikonduktor. Model-model ini mampu memperhatikan detail dan pola kecil dalam citra semikonduktor. Terlebih lagi, kami menemukan bahwa model CNN dapat menangani berbagai lingkungan dan pencahayaan dengan cukup baik, yang penting di pabrik semikonduktor.

Terlepas dari poin-poin kuat ini, kami menemukan beberapa batasan dan area untuk perbaikan. Salah satu masalah besar adalah bagaimana model CNN cenderung mengalami overfitting ketika dilatih pada dataset kecil atau tidak merata. Selain itu, melatih jaringan saraf dalam pada dataset semikonduktor yang besar itu kompleks. Hal ini menciptakan tantangan logistik, membuat kami berpikir tentang bagaimana menggunakan sumber daya kami dengan baik dan meningkatkan skala pekerjaan kami.

Jika dibandingkan dengan cara lama dalam memeriksa semikonduktor, model CNN menunjukkan peningkatan yang besar. Mereka berkinerja lebih baik daripada sistem berbasis aturan atau alat pembelajaran mesin biasa, terbukti lebih akurat, lebih cepat, dan lebih baik dalam menangani berbagai jenis gambar semikonduktor. Dengan belajar sendiri dari data mentah, model CNN menunjukkan bahwa mereka pandai mendeteksi cacat kecil dan memilah komponen semikonduktor setiap saat.

Meskipun demikian, menerapkan model CNN di pabrik dunia nyata memiliki masalahnya sendiri. Hal ini mencakup kebutuhan akan sejumlah besar data berlabel, komputer



yang canggih, dan cara untuk memahami apa yang diprediksi oleh model. Terlepas dari hambatan-hambatan ini, potensi yang ditunjukkan oleh model CNN menyoroti kemampuannya untuk menyebabkan revolusi dalam cara kita memeriksa semikonduktor. Ini membuka pintu bagi kontrol kualitas yang lebih baik dan cara untuk mengurangi cacat.


Sebagai penutup, pembahasan kami menunjukkan bagaimana model CNN memiliki dampak yang sangat besar pada inspeksi semikonduktor. Dengan menggunakan bagian-bagian yang baik dari metode pembelajaran mendalam dan memperbaiki masalah yang kami temukan, para pembuat dapat menemukan cara baru untuk membuat produk semikonduktor lebih baik dan lebih andal. Ke depannya, kita perlu terus melakukan pembahasan dan pengembangan untuk mengatasi masalah saat ini dan membuat model yang menggunakan pembelajaran mendalam bekerja lebih baik lagi untuk inspeksi semikonduktor sehari-hari di pabrik.

5.13 KESIMPULAN

Sebagai kesimpulan, pembahasan kami mengamati dengan saksama bagaimana CNN pembelajaran mendalam dapat digunakan untuk memeriksa semikonduktor. Kami menunjukkan bahwa model CNN akurat dalam menemukan dan memilah cacat pada gambar semikonduktor melalui pengujian dan peninjauan yang cermat. Hasil kami membuktikan bahwa CNN bekerja dengan baik, dengan akurasi lebih dari 90% di berbagai pengaturan dan sampel. Temuan ini menunjukkan bahwa metode pembelajaran mendalam memiliki pengaruh besar pada inspeksi semikonduktor, memberikan para pembuat alat baru untuk mengontrol kualitas dan mengurangi cacat. Kami tidak dapat cukup menekankan betapa berharganya pembelajaran mendalam dalam pengujian semikonduktor.

Dengan menggunakan model CNN, para pembuat dapat meningkatkan cara mereka menemukan cacat, meningkatkan kualitas produk, dan memangkas biaya produksi. Penggunaan metode pembelajaran mendalam menandai perubahan besar dalam cara kita mengontrol kualitas semikonduktor, memungkinkan deteksi cacat yang otomatis, efisien, dan tepat dalam skala besar. Pembahasan di masa mendatang harus berfokus pada peningkatan struktur CNN, peningkatan metode pelatihan, dan menemukan cara baru untuk menggunakan pembelajaran mendalam dalam pembuatan semikonduktor.

Selain itu, upaya untuk menciptakan dataset standar, kerangka kerja pengujian, dan alat untuk memahami proses akan menjadi kunci untuk membantu lebih banyak orang menggunakan pembelajaran mendalam dalam kontrol kualitas semikonduktor dan memastikan kesesuaiannya dengan praktik industri.



BAB 6

PEMBELAJARAN MESIN UNTUK PERANGKAT SEMIKONDUKTOR

6.1 PENDAHULUAN

Ekspansi dan implementasi luas teknologi baru semikonduktor telah menjadi kekuatan pendorong utama di balik revolusi komputer abad ke-21. Lebih lanjut, fabrikasi semikonduktor kini diakui sebagai fokus utama inovasi publik di berbagai negara. Misalnya, Undang-Undang Demonstrasi Chip Eropa (UE), yang disahkan pada tahun 2023, dan Undang-Undang CHIPS dan Sains (AS), yang disahkan pada tahun 2022, keduanya telah memberlakukan langkah-langkah subsidi yang signifikan untuk mempromosikan produksi chip semikonduktor, komunikasi, keterlibatan, dan lapangan kerja. Semikonduktor berkinerja tinggi semakin populer sebagai hasil dari aplikasi yang muncul seperti kecerdasan buatan berbasis komputer (CAI) yang membutuhkan daya pemrosesan yang besar.

Oleh karena itu, sejumlah pendekatan telah dikembangkan dan diusulkan, termasuk penggabungan 3D, fotonik silikon, dan kombinasi heterogen, dan ini merupakan gerbang menuju semikonduktor secara keseluruhan. Tujuan yang menyatukan semua pendekatan adalah untuk mencapai lebar garis terkecil (pitch) dengan mengorbankan struktur yang sangat kompleks. Perkembangan ini memungkinkan chip atau bagian chip untuk beroperasi secara independen dengan menggunakan koneksi pada tingkat wafer dan chip. Jika dibandingkan dengan skema penggabungan konvensional, mereka dapat menciptakan kerangka kerja yang sangat membingungkan. Kompleksitas strategi dan pembuatannya meningkatkan produksi kerangka kerja yang sukses.

Untuk mengumpulkan data dan mengevaluasi batas siklus, kegunaan item, ketebalan lapisan, posisi susunan, bagian material, dan kualitas listrik, metrologi menggunakan berbagai metode pengukuran, mengubah satuan pengukuran dan peralatan. Menurut Abd Al Rahman dan Mousavi, pasar untuk perangkat keras peninjauan dan estimasi semikonduktor mencakup berbagai perangkat seperti perangkat keras estimasi lapisan penutup, ketebalan film, akurasi lapisan, bentuk tiga lapis, contoh dan perangkat pemeriksaan ketidaksempurnaan wafer non-desain, dan perangkat investigasi lapisan penutup.

Kontrol proses adalah tanggung jawab utama metrologi dalam industri semikonduktor, dan metrologi sangat penting untuk kelangsungan hidup industri. Misalnya, perangkat 3D NAND menggunakan material seperti lapisan tebal dan keras; desain yang sangat padat; dan lebih dari 100 lapisan. Heterogenitas geologis yang tinggi, ambiguitas dalam material, dan tegangan wafer adalah beberapa faktor yang meningkatkan kesulitan dalam mencapai estimasi yang akurat. Selain itu, produksi memori akses acak dinamis (Measure) semakin memperumit proses.

Namun, akan selalu ada kebutuhan akan perangkat teknologi dengan fungsionalitas yang lebih besar. Teknik semikonduktor masa depan, seperti penggabungan canggih, diharapkan akan lebih padat dan membutuhkan arsitektur yang jauh lebih rumit. Seiring perangkat menjadi lebih kecil dan lebih tiga dimensi (3D) dalam desainnya, metrologi menjadi



semakin diperlukan. Lebih dari setengah tahapan manufaktur untuk beberapa komoditas melibatkan estimasi atau penggambaran. Industri semikonduktor sedang menuju masa depan di mana seharusnya dimungkinkan untuk menentukan sifat dan kondisi setiap partikel di dalam perangkat 3D.

Jarak interkoneksi dasar sekarang submikron, dan dalam beberapa aplikasi, ketebalan lapisan yang diizinkan untuk penggabungan semikonduktor telah meningkat lebih dari 100 kali lipat dalam sepuluh tahun terakhir. Pola menuju perluasan ketebalan kerangka kerja diperkirakan akan berlanjut dari sini, menghadirkan kesulitan besar baik dalam perencanaan maupun penanganan aktual. Beberapa pembahasan telah menunjukkan bahwa menganalisis keandalan prosedur semikonduktor yang akan datang adalah penghalang utama. Banyak perangkat semikonduktor memiliki banyak komponen yang memiliki berbagai fungsi. Oleh karena itu, pembahasan dan penguatan lebih lanjut diperlukan untuk mendukung kemajuan metrologi saat ini.

Selama operasi fabrikasi semikonduktor, penyelesaian tujuan inspeksi menyeluruh terhadap produk yang sebagian diproduksi memerlukan sejumlah peralatan metrologi dan waktu yang terbatas. Perusahaan sekarang melakukan inspeksi dan pengujian secara sembarangan untuk kontrol kualitas guna menghemat uang, tetapi ini tidak selalu menghasilkan kontrol kualitas yang menyeluruh atau menjamin hasil yang luar biasa. Prosedur metrologi yang sekarang digunakan perlu diperiksa selama tahap penanganan tertentu, dan perkiraannya dipenuhi di stasiun metrologi yang diidentifikasi dengan jelas, sehingga mengakibatkan waktu penanganan yang tidak perlu.

Oleh karena itu, metrologi virtual (VM) dapat mengatasi kualitas pengujian dan peninjauan yang konsisten untuk produk semikonduktor canggih. Untuk mengevaluasi hasil interaksi pabrik yang dibahas, VM menggunakan faktor siklus, informasi peralatan pembuatan, dan wafer yang diuji untuk informasi metrologi yang sebenarnya. Meskipun tidak semua produk dapat dikenakan metrologi aktual, VM dapat digunakan untuk memenuhi kebutuhan inspeksi yang "lengkap". Metode ini dapat menggantikan penyelidikan kontinu inline dengan tinjauan terpisah mengingat pengaturan dan pengujian model mesin virtual yang tepat. VM, juga disebut sebagai deteksi halus, telah menemukan kegunaan yang bermanfaat di berbagai industri perakitan di masa lalu. Meskipun aplikasi ini benar-benar membutuhkan pembahasan lebih lanjut, mereka telah banyak diuntungkan dari keberhasilan penggunaan mesin virtual di industri semikonduktor.

Misalnya, untuk menurunkan biaya produksi, pabrik bertujuan untuk menurunkan tingkat pengambilan sampel. Sistem pengambilan sampel cerdas (ISD) mendukung VM, namun, tingkat yang ditetapkan membatasi kemampuan adaptasi. Pembahasan ini mengusulkan metode pengambilan sampel otomatis (ASD) yang secara dinamis menyesuaikan tingkat pengambilan sampel secara real-time berdasarkan kebenaran VM untuk menjamin efisiensi dan kinerja jangka panjang. Proses semikonduktor ini dikembangkan oleh Cheng dan lainnya untuk mencapai tujuan mekanisasi lengkap dalam bisnis pembuatan roda mobil. Para penemu mendemonstrasikan pengaturan yang layak dari tiga mesin, satu inline, satu bor, dan satu stasiun metrologi tambahan yang tidak terhubung, yang bekerja bersama untuk



menciptakan fasilitas produksi roda otomatis. Kegunaan VM ini dalam pembuatan lapisan tembaga (CCL), komponen dasar untuk lembaran sirkuit kertas yang digunakan dalam berbagai perangkat, telah diteliti oleh Kim dan rekan-rekan.

Dengan menggunakan data terverifikasi dari produsen CCL, tiga parameter kualitas menjadi subjek harapan selama terapi. Mirip dengan bagaimana pembuatan serat karbon diintegrasikan ke dalam kerangka AVM, para pembuat dapat melacak informasi pembuatan, memulai penelusuran balik informasi pembuatan (PDT), menghubungkannya dengan benda kerja yang diproduksi secara khusus, dan menyelesaikan penilaian menyeluruh terhadap proses pembuatan serat karbon. Penerapan teknologi pemeliharaan virtual pada motor komersial di bidang penerbangan telah ditunjukkan dengan baik oleh Enrico dan rekan-rekan. dan penerapan VM untuk produksi dan pemesanan perangkat ultra-akurat ditemukan baik pada motor komersial di bidang penerbangan maupun produksi perangkat ultra-akurat.

Oleh karena itu, dengan memeriksa pola perakitan yang berkelanjutan ini, dapat disimpulkan dengan aman bahwa VM adalah kemajuan mekanis penting dari Industri 4.0 yang melampaui harapan target metrologi tradisional. Penting bagi perusahaan untuk memahami bahwa fondasi mesin virtual sekarang mencakup sebagian besar logika Industri 4.0 seperti internet of things (IoT), kerangka kerja fisik digital, big data modern, dan manufaktur tanpa cacat. Penilaian semikonduktor di masa depan diperkirakan akan sangat bergantung pada VM. Seiring meningkatnya kompleksitas bundling, ukuran inklusi berkurang, dan teknik bundling canggih seperti wafer-ke-wafer dan pass-on-to-wafer secara dinamis menggantikan siklus normal, sehingga memerlukan lebih banyak pembahasan berkelanjutan. Selain itu, VM dapat memainkan peran besar dalam desain bundling mutakhir, yang diakui oleh beberapa penilaian sebagai tantangan utama seiring meningkatnya ketebalan konstruksi. Munculnya kecerdasan buatan yang lebih cepat dan kemudahan bundel AI-ML (kecerdasan buatan–pembelajaran mesin) sumber terbuka telah menyebabkan berkembangnya spekulasi APC (kontrol fase canggih) semikonduktor baru-baru ini, termasuk mesin virtual (VM), yang bermanfaat untuk pengembangan bundling. Untuk mengatasi masalah ketepatan prediksi yang ditimbulkan oleh komputasi inovatif yang canggih, inovasi berkelanjutan dalam VM diperlukan.

Produksi yang menyeluruh dan implikasi potensial VM untuk sektor ini sangat penting. Karena alasan ini, bab ini melakukan upaya terdepan tersebut. Bab ini mengumpulkan dan menganalisis topik-topik VM yang relevan dengan fabrikasi semikonduktor, dan merangkum pembahasan terbaik yang tersedia. Bab ini mengaudit dan memeriksa taktik mesin virtual yang diadopsi di setiap kelompok siklus berdasarkan hierarki proses manufaktur semikonduktor. Analisis fundamental yang sama pentingnya dilakukan untuk menyelidiki tantangan yang terus-menerus muncul dalam implementasi lebih lanjut fabrikasi semikonduktor, serta analisis komparatif tentang potensi masa depan.

6.2 SEJARAH DAN LOMPATAN TEKNOLOGI PERANGKAT SEMIKONDUKTOR

Dalam ranah perangkat keras, pengoperasian perangkat semikonduktor terus menjadi contoh kreativitas manusia dan kemajuan teknologi. Selama bertahun-tahun, perangkat semikonduktor telah mengalami kemajuan yang signifikan dan peningkatan yang luar biasa.



Perangkat-perangkat ini, yang awalnya berupa dioda dan semikonduktor, telah berevolusi menjadi landasan penemuan modern dan bertanggung jawab atas era canggih yang kita jalani saat ini.

Bagian ini dimulai dengan pemeriksaan lintasan yang dapat diverifikasi dari perangkat semikonduktor, menyoroti pencapaian penting mereka dan perubahan dinamis yang telah membentuk kemajuan mereka. Melalui perjalanan ini, kita memiliki pemahaman yang lebih dalam tentang jalinan rumit penemuan logis dan pencapaian desain yang telah mendorong perangkat semikonduktor ke kondisi kritisnya saat ini.

Perangkat Semikonduktor

Perangkat semikonduktor adalah komponen elektronik yang didasarkan pada sifat listrik unik semikonduktor. Zat-zat ini berada di tengah-tengah antara domain pemandu dan pemisah dalam hal konduktivitas. Material semikonduktor penting meliputi semikonduktor alami seperti silikon, germanium, dan galium arsenida. Komponen elektronik ini, yang memanfaatkan kemampuan listrik semikonduktor yang luar biasa, merupakan dasar dari banyak aplikasi kreatif.


Kemajuan Dalam Evolusi Perangkat Semikonduktor

Bagian ini memberikan ringkasan yang jelas dan ringkas tentang evolusi inovasi semikonduktor. Bagian ini mencakup momen-momen penting, kemajuan, dan tren yang telah membentuk bidang ini, dari penemuan semikonduktor awal hingga sirkuit terkoordinasi saat ini. Bagian ini memberikan pemahaman mendasar tentang lingkungan empiris, membuka jalan untuk memahami keadaan saat ini dan potensi arah masa depan untuk perangkat semikonduktor.

Secara khusus, peningkatan skala inovasi semikonduktor oksida logam komplementer (CMOS) yang berkelanjutan, sesuai dengan hukum Moore, telah lama menjadi pendorong utama dalam industri semikonduktor. Pengurangan ukuran semikonduktor dan sirkuit yang berkelanjutan telah memungkinkan kemajuan signifikan dalam daya komputasi dan proliferasi perangkat elektronik di berbagai aplikasi.

Semikonduktor Awal

Istilah "semikonduktor awal" mengacu pada konfigurasi dasar semikonduktor yang dibuat pada paruh kedua tahun 1940-an dan pertengahan tahun 1950-an. Kami telah menemukan dampak lain, yang sekarang disebut sebagai dampak semikonduktor, dalam investigasi terbaru kami menggunakan penyearah kontak titik. Efek ini bergantung pada penggunaan sebagian kecil material semikonduktor dibandingkan dengan pendekatan konvensional yang menggunakan sebagian besar material tersebut. Ini adalah komponen keadaan kuat utama yang digunakan dalam banyak aplikasi praktis, menggantikan tabung vakum. Jika dibandingkan dengan tabung vakum, semikonduktor awal ini lebih kecil, lebih andal, dan mengonsumsi daya lebih sedikit, yang merupakan kemajuan signifikan dalam perangkat keras. Investigasi dan pekerjaan pendahuluan yang dilakukan selama periode ini menetapkan kerangka kerja untuk semikonduktor modern.



Sirkuit Terpadu

Kilby menemukan sirkuit terpadu, yang secara fundamental mengubah lanskap perangkat keras dengan menggabungkan beberapa komponen pada satu substrat semikonduktor. Karya penting Kilby pada paruh kedua tahun 1950-an meletakkan dasar bagi era canggih perangkat elektronik berkinerja tinggi dan berukuran lebih kecil. Versi yang lebih kecil dari sirkuit listrik, yang terdiri dari resistor, kapasitor, dioda, dan semikonduktor disebut sirkuit terpadu (IC).

Ini sebagian besar diproduksi pada silikon, substrat semikonduktor kecil. Elemen-elemen ini bekerja bersama untuk menyelesaikan tugas-tugas tertentu seperti penanganan, penyimpanan memori, dan peningkatan sinyal. Ketika banyak komponen digabungkan menjadi satu chip, dimungkinkan untuk mengurangi ukuran, meningkatkan kinerja, dan menggunakan lebih sedikit energi daripada ketika sirkuit elektronik terpisah digunakan. Rangkaian terkoordinasi sangat penting untuk menyuplai daya ke beberapa perangkat modern.

6.3 TREN INOVASI TERBARU DI AMBANG ERA DIGITAL MASA DEPAN

Kemajuan Yang Muncul

Beberapa perkembangan mutakhir telah terjadi dalam satu setengah abad terakhir. Inovasi perakitan, informasi, dan video bekerja sama untuk menciptakan kemajuan baru yang lebih efektif. Pengembangan teknologi biopsi cairan menangani fase penting dalam perjuangan melawan penyakit yang sedang berlangsung. Biopsi cairan menawarkan beberapa keunggulan dibandingkan biopsi jaringan tradisional. Biopsi cairan berfungsi sebagai alternatif yang baik dalam kasus di mana biopsi jaringan tidak masuk akal. Selain itu, biopsi cairan memberikan gambaran komprehensif tentang kesehatan pasien secara keseluruhan, sedangkan biopsi jaringan hanya memberikan fragmen informasi berdasarkan sampel. Bahkan, DNA pertumbuhan yang beredar sering terdeteksi dalam biopsi cairan karena sering bermigrasi dari jaringan kanker ke aliran darah.

Dengan kemajuan struktur otak konvolusional dan pembelajaran mendalam, visi mesin telah mulai melampaui kemampuan manusia dalam pengenalan gambar. Saat ini, inovasi visi mesin menunjukkan berbagai aplikasi yang diantisipasi di beberapa domain, termasuk mengemudi otonom, diagnosis medis, penilaian jaminan perlindungan, pemantauan ketinggian air, berkebun, dan banyak lagi. Jaringan saraf konvolusional (CNN), yang dapat dilatih menggunakan algoritma backpropagation, secara konsisten mengungguli struktur pembelajaran mendalam lainnya dalam tugas-tugas seperti pengenalan gambar dan ucapan. Mereka juga membutuhkan lebih sedikit evaluasi batas daripada model pembelajaran mendalam feedforward lainnya, yang menjadikannya pilihan yang menarik di ruang pembelajaran mendalam. Potensi komputer kuantum tidak terbatas, tetapi pengembangannya sangat sulit dan mahal.

Alasan mengapa daya pemrosesan komputer pribadi kuantum kecil belum melampaui superkomputer mudah dipahami. Namun, IBM memajukan penggunaan komputasi kuantum pada tahun 2016 dengan menjadi perusahaan pertama yang menyediakan layanan komputasi awan untuk komputer kuantum kepada masyarakat umum. Lebih dari 20 publikasi ilmiah yang



menunggu diseminasi kini memiliki platform eksplorasi berkat penemuan ini. Saat ini, lebih dari 50 organisasi di seluruh dunia, termasuk inisiatif besar dan bisnis baru yang tak terhitung jumlahnya, sedang berupaya mewujudkan PC kuantum. Orang-orang percaya bahwa era kuantum telah tiba sebagai hasil dari perkembangan ini.

Keuntungan Dari Kemajuan Yang Meningkat

Inovasi dan sains memainkan peran penting dalam memajukan kemajuan manusia. Seberapa pun majunya teknologi, penting untuk diingat bahwa mesin masih merupakan produk penemuan manusia, yang dimaksudkan untuk digunakan oleh manusia. Mereka yang mendapat manfaat dari perangkat mekanis ini tidak boleh menekan keinginan bawaan mereka untuk bekerja, karena ketergantungan yang berlebihan pada mesin dapat menyebabkan ketidaksetujuan sosial. Namun, ini tidak berarti bahwa perkembangan baru menghambat kemajuan manusia. Mirip dengan aspek kehidupan sehari-hari lainnya, inovasi adalah urusan dua sisi. Pilihan kita menentukan bagaimana kita menggunakannya. Tidak masuk akal untuk meremehkan kontribusi yang dapat diberikan pembahasan dan inovasi terhadap kemajuan manusia karena individu secara konsisten menunjukkan pengetahuan mereka yang unggul.

Peningkatan Eksekusi

Chip cerdas merupakan inovasi pendukung yang dibutuhkan untuk 5G dan IoT, yang akan semakin mendorong teknologi ini dan meningkatkan perangkat pintar, rumah pintar, dan bidang lainnya, selain meningkatkan inklusi informasi dan digitalisasi. Sektor semikonduktor akan menghadirkan kemajuan yang lebih signifikan dan peluang yang menguntungkan, dan permintaan akan chip hanya akan terus meningkat.

Kesadaran dan pembelajaran mendalam manusia yang semakin meningkat berarti bahwa industri semikonduktor perlu memenuhi persyaratan kinerja yang semakin tinggi dalam hal efisiensi energi dan komputasi. Saat ini, bisnis semikonduktor akan mengalami perkembangan yang cukup besar di bidang inovasi rekayasa PC dan penyederhanaan komputasi. Berbeda dengan generasi sebelumnya, elektronik modern lebih kecil dan lebih serbaguna, menawarkan tingkat kustomisasi yang lebih tinggi. Untuk memenuhi kebutuhan pelanggan yang sederhana, industri semikonduktor terutama akan mendukung perangkat frekuensi radio baru dan chip yang lebih kecil dalam situasi khusus ini.

6.4 IMPLEMENTASI AI DAN ML PADA PROTOKOL MANUFAKTUR SEMIKONDUKTOR

Protokol Equipment Communications Standard/Generic Equipment Model (SECS/GEM) dari Semiconductor Equipment and Materials International (SEMI) memudahkan komunikasi antara komputer host dan peralatan semikonduktor di sektor manufaktur semikonduktor. SEMI mengembangkan SECS/GEM dengan tujuan meningkatkan otomatisasi pabrik melalui komunikasi yang terstandarisasi. Dalam sistem manufaktur cerdas, host yang mengelola dan mengumpulkan data dari peralatan membentuk lapisan tepi, sedangkan peralatan itu sendiri terdapat dalam lapisan peralatan. Namun, antarmuka SECS/GEM yang ada saat ini kurang memiliki analisis data dinamis pada tingkat perangkat keras, yang mengakibatkan masalah latensi saat mentransfer input ke lapisan tepi/cloud untuk analisis.



Untuk mengatasi masalah latensi ini dan memungkinkan pemrosesan data dinamis pada tingkat peralatan, pembahasan mengusulkan protokol komunikasi baru untuk antarmuka SECS/GEM. Antarmuka SECS/GEM saat ini menambahkan latensi yang signifikan ketika mengirim data dari peralatan ke lapisan edge/cloud karena tidak menawarkan analisis data dinamis. Nguyen melakukan eksperimen menggunakan pesan SECS/GEM untuk mengukur lag transfer variabel data dari perangkat keras ke host. Lag yang cukup besar yang dapat memengaruhi produktivitas terungkap dari data tersebut. Untuk mengatasi hal ini, mereka mengusulkan arsitektur untuk sistem yang mencakup modul "Mesin Analisis Data" onboard. Modul ini memungkinkan peralatan untuk melakukan tugas analisis yang ditentukan host, sehingga menghilangkan kebutuhan transfer data ke host.

Para penulis memasukkan "Stream 22" baru dalam protokol SECS/GEM, yang memungkinkan host untuk membangun, menghubungkan, dan memulai operasi analitik khusus dan yang telah ditentukan sebelumnya pada peralatan serta melaporkan dan mengidentifikasi hasilnya. Dengan memungkinkan host untuk menetapkan tugas analisis data ke peralatan secara dinamis dan mengumpulkan hasilnya, protokol yang diusulkan ini dapat mengurangi penggunaan bandwidth jaringan dan meningkatkan efisiensi manufaktur cerdas semikonduktor dengan memungkinkan reaksi waktu nyata.

Model deteksi cacat dibangun menggunakan You Only Look Once versi 2 (YOLOv2) sesuai model referensi. YOLOv2 adalah algoritma deteksi objek yang terkenal yang melakukan deteksi melalui regresi, menggunakan banyak lapisan pooling yang berbeda dengan konvolusi untuk mengubah gambar masukan menjadi tensor 3D. Gambar masukan ke model YOLOv2 berukuran 448×448 piksel, yang meningkatkan resolusi dan menyempurnakan pengklasifikasi untuk kinerja yang lebih baik. Untuk meningkatkan dimensi kritis gambar abu-abu mikroskop elektron pemindaian (CD-SEM) berdasarkan fitur-fiturnya, kontras dan kecerahan gambar disesuaikan secara dinamis. Hal ini dicapai menggunakan teknologi pencampuran linier gambar. Dua gambar, gambar asli I_0 dan gambar saluran transparan kedua I_1 , digabungkan secara linier berdasarkan bobot. Rumus pencampurannya adalah:

$$g(x) = \lambda I(x) + (1 - \lambda) I_1(x) \quad (6.1)$$

Dalam gambar gabungan g , nilai piksel yang dihasilkan pada posisi x dipertimbangkan di mana λ adalah bobot yang mengontrol penggabungan nilai piksel pada posisi yang sesuai di kedua gambar.

Sistem memproses gambar abu-abu CD-SEM secara otomatis dengan mengekstraknya dari basis data server CD-SEM, melakukan pra-pemrosesan, dan kemudian menggunakan model deteksi cacat untuk mengidentifikasi cacat. Jika cacat terdeteksi, sistem menyimpan output cacat ini ke dalam data CD-SEM sebagai gambar tinjauan. Sistem juga memicu email alarm untuk memberi tahu para insinyur. Para insinyur dapat melihat data CD-SEM terperinci dan gambar tinjauan melalui antarmuka pengguna khusus. Sistem mendukung deteksi batch gambar CD-SEM untuk meningkatkan efisiensi. Misalnya, sistem dapat memproses hingga 188 gambar abu-abu dalam satu batch, menampilkan hasilnya dengan kotak pembatas yang



menunjukkan cacat (merah untuk cacat, hijau untuk tidak ada cacat). Sistem mengurangi kebutuhan para insinyur untuk meninjau setiap gambar secara manual dan meningkatkan kemampuan inspeksi cacat inline, sehingga meningkatkan manfaat ekonomi bagi pabrik. Dengan mendeteksi wafer yang rusak secara real-time dan segera memberi tahu para insinyur, sistem ini membantu mengurangi dampak pada produk dan meningkatkan hasil.

Dalam pembahasan ini, materi Nguyen, H. mengembangkan skema materi pembelajaran mendalam terawasi yang kuat yang bertujuan untuk mengklasifikasikan dan melokalisasi berbagai jenis cacat pada gambar SEM dengan presisi tinggi. Model ensemble yang diusulkan mengintegrasikan desain sebagai tulang punggung dan memanfaatkan model yang dipilih secara eksperimental berdasarkan preferensi yang di-ensemble secara strategis untuk mendapatkan hasil setelah menggabungkan prediksi dari model-model tersebut. Pendekatan ini meningkatkan kinerja baik dalam klasifikasi maupun deteksi cacat.

Model ini secara efisien mengkategorikan kelas-kelas yang rusak, seperti runtuhnya garis, jembatan mikro, dan celah mikro, serta menangani perubahan tingkat skenario kerusakan tingkat piksel dalam kategori-kategori ini. Selain itu, model ini secara tepat meregresikan wilayah kerusakan dengan menyediakan kotak pembatas yang ditandai dengan lebar, koordinat pusat, tinggi, dan skor kepercayaan deteksi.

Untuk lebih mengoptimalkan deteksi kesalahan, strategi pembelajaran mesin tanpa pengawasan diterapkan untuk mendapatkan gambar SEM tanpa noise tanpa kebenaran dasar yang jelas. Metode ini bermanfaat dalam menghilangkan kesalahan positif palsu dan meminimalkan dampak noise stokastik pada piksel yang terstruktur. Analisis kerapatan spektral daya menunjukkan bahwa hanya noise komponen frekuensi tinggi yang dibiarkan. Bersamaan dengan mempertahankan frekuensi komponen rendah yang terkait dengan struktur suara fitur perangkat.

Pipeline inspeksi cacat ini meningkatkan akurasi deteksi cacat. Proses ini tidak akan mengubah dimensi panjang kawat/jarak kawat (L/S) pada pitch yang agresif. Karena desain sirkuit terus menyusut untuk mematuhi hukum Moore, metode inspeksi cacat konvensional ini menjadi kurang efektif, seringkali menyebabkan deteksi cacat palsu dan metrologi yang salah. Model berbasis pembelajaran mendalam mengatasi keterbatasan ini, meningkatkan klasifikasi dan lokalisasi deteksi berbagai kategori cacat dengan presisi dan akurasi yang lebih besar.

Seiring manufaktur semikonduktor bergerak menuju node 3 nm, mengurangi kesalahan penempatan tepi (EPE) sangat penting untuk fungsi perangkat IC yang tepat. EPE mengevaluasi keandalan pola yang dihasilkan dalam proses multi-patterning dengan mengintegrasikan cacat overlaying dan dimensi kritis (CD). Kemajuan ML baru-baru ini telah memberikan peluang baru untuk meningkatkan kinerja dan efisiensi prosedur optimasi EPE.

Kyon dan lainnya meninjau pembahasan terbaru yang menerapkan pembelajaran mesin/pembelajaran mendalam untuk meningkatkan metrologi overlay virtual, mengurangi kesalahan overlay, dan meningkatkan metode optimasi mask untuk pengurangan EPE. Tinjauan ini membahas tujuan, dataset, fitur input, model, temuan utama, dan keterbatasan.



Hasil menunjukkan potensi besar ML dalam meningkatkan EPE dalam manufaktur semikonduktor.

Samsung memulai produksi 3 nm "awal" pada tahun 2022, menggunakan arsitektur gate-all-around, menawarkan kepadatan transistor 16% lebih tinggi, kinerja 23% lebih tinggi, dan daya 45% lebih rendah dibandingkan dengan proses "5 nm" yang tidak ditentukan. Taiwan Semiconductor Manufacturing Company (TSMC) mengumumkan produksi massal proses N3 "3 nm" pada Desember 2022, dengan proses N3E yang disempurnakan dimulai pada semester kedua tahun 2023. Ini adalah proses fabrikasi semikonduktor. Pada IEDM (International Electron Devices Meeting) 2022, TSMC mengungkapkan bahwa N3 memiliki jarak antar gerbang kontak 45 nm dan N3E memiliki jarak antar logam minimum 23 nm, dengan luas sel SRAM sebesar $0,0199 \mu m^2$ untuk N3 dan $0,021 \mu m^2$ untuk N3E. Seiring dengan penyusutan node, diperlukan lebih banyak kecerdasan dalam pengisian, karena hal ini dapat memengaruhi waktu dan integritas sinyal dari pengisian semua lapisan.

Makalah ini, Prosesor AI Integrasi Heterogen Chiplet, membahas desain prosesor AI berbasis chiplet bernama ABSx, yang mengintegrasikan beberapa unit pemrosesan neural (NPU) dan chiplet memori bandwidth tinggi (HBM3) pada interposer lapisan redistribusi (RDL) multilayer. Aspek desain utama meliputi saluran data berkecepatan tinggi, dengan penekanan pada perlunya saluran data berkecepatan tinggi antara NPU dan HBM untuk memfasilitasi pemrosesan paralel dan pemrosesan dekat memori, yang sangat penting untuk tugas-tugas AI.

- **Desain Interposer:** Pertimbangan untuk integritas sinyal, distribusi daya, dan pengkabelan kepadatan tinggi untuk memastikan komunikasi dan manajemen daya yang efektif di seluruh chiplet.
- **Arsitektur NPU Intra-Chiplet:** Desain arsitektur NPU untuk mempertahankan pengumpanan data berkelanjutan ke unit floating-point, memastikan pemrosesan yang efisien.
- **Keandalan Bonding:** Mengatasi masalah keandalan bonding statis dan dinamis yang disebabkan oleh banyaknya micro-bump, yang penting untuk menjaga integritas struktural prosesor.
- **Stabilitas Termal:** Memastikan stabilitas termal dengan menganalisis fluks panas dan pengaruh panas timbal balik serta menerapkan strategi pembuangan panas yang efektif untuk mengelola beban termal.
- **Hubungan Antar-Chiplet:** Menyoroti pentingnya hubungan antar-chiplet dan dampaknya terhadap efisiensi kinerja keseluruhan prosesor.

Kriteria desain berfokus pada pengoptimalan efisiensi kinerja, memastikan integrasi chiplet yang andal, dan menjaga stabilitas termal. Arsitektur chiplet digunakan untuk mengatasi kesulitan yang muncul akibat ledakan data dalam komputasi, yang diperlukan untuk model AI skala besar. Chiplet berbasis AI ABSx merupakan solusi yang tepat untuk kebutuhan pemrosesan data AI, memberikan jalan ke depan untuk menangani beban kerja yang kompleks sejalan dengan menjaga keandalan kinerja tinggi.

Dalam Yoo dan lainnya, para peneliti menyajikan cara kerja teknik pemrosesan bahasa alami (NLP) untuk mengevaluasi data teks yang berkaitan dengan pemeliharaan peralatan



serta masalah kualitas di industri manufaktur semikonduktor. Dalam rangka mengumpulkan informasi yang mendalam dari data yang tidak terstruktur ini, para peneliti melakukan sejumlah langkah penting dalam pengembangan mesin NLP internal. Pada awalnya, para peneliti melakukan pra-pemrosesan semua data teks, yang mencakup detail tentang pemeliharaan peralatan serta masalah kualitas secara berurutan untuk membuat korpus. Kamus semikonduktor digunakan untuk melakukan analisis masalah kualitas pada semikonduktor. Analisis ini juga menggunakan teknik bag-of-words, bag-of-N-grams, dan term frequency-inverse document frequency (TF-IDF) untuk mengukur dokumen dan mengekstrak fitur-fitur penting. Visualisasi frasa dan asosiasi frasa kunci di berbagai pabrik dianalisis, dan perbedaan signifikan antara jenis peralatan ditemukan dengan menggunakan uji chi-square. Pada akhirnya, analisis burst mengidentifikasi waktu-waktu ketika frekuensi frasa penting meningkat pesat.

Temuan menunjukkan bahwa pabrik dan model yang berbeda memiliki tren masalah kualitas dan karakteristik pemeliharaan peralatan yang berbeda. Hal ini menawarkan informasi yang mendalam yang dapat membantu produsen semikonduktor meningkatkan produktivitas dan kualitas.

Penggunaan teknik NLP oleh penulis untuk menganalisis data teks tidak terstruktur menunjukkan potensi pendekatan ini untuk mengekstrak wawasan yang bermakna dari banyaknya informasi yang tersedia dalam operasi semikonduktor. Dengan mengungkap pola dan perbedaan dalam masalah kualitas dan pemeliharaan, analisis NLP dapat membantu produsen mengoptimalkan proses mereka dan meningkatkan kinerja secara keseluruhan.

Yoo dan timnya menyajikan metode komprehensif yang menggabungkan simulasi desain berbantuan komputer teknologi (TCAD) dengan teknik ML canggih untuk mencapai optimasi multi-target untuk proses BCD (Bipolar-CMOS-DMOS (Double-diffused metal oxide semiconductor)). Aspek kunci dari pendekatan ini adalah pembangkitan data, di mana ia menggunakan 150 titik sampel Latin hypercube untuk secara menyeluruh mencakup ruang parameter dan menghasilkan data penting untuk pelatihan model melalui simulasi TCAD. Data dasar ini digunakan untuk membangun hubungan yang akurat antara variabel proses dan karakteristik listrik (ET-spec) perangkat target.

Langkah selanjutnya adalah pemodelan regresi, dan model dilatih untuk memprediksi ET-spec peralatan berdasarkan parameter prosedur. Model auto-regresi dipilih karena kebugarannya yang tinggi, memungkinkan penggunaan model pengganti alih-alih simulasi TCAD langsung untuk secara signifikan mengurangi biaya komputasi selama proses optimasi iteratif. Dalam proses optimasi, algoritma genetik (GA) digunakan untuk secara efisien mencari minimum global dengan menjelajahi ruang solusi yang luas. Proses optimasi menggunakan penjumlahan berbobot dari skor kebugaran untuk mengelola sifat multi-target dari masalah tersebut, memastikan bahwa parameter perangkat yang berbeda dioptimalkan secara bersamaan.

Untuk memeriksa berbagai bagian dari Pareto front, beberapa solusi GA dimulai dari titik awal yang berbeda. Simulasi TCAD digunakan dalam validasi untuk memverifikasi efektivitas parameter proses yang dioptimalkan yang ditemukan oleh GA. Tahap ini menjamin



bahwa perbaikan yang disarankan dapat diterapkan dari sudut pandang praktis dan juga secara konseptual masuk akal.

Metode baru ini dibandingkan dengan alur optimasi yang ada pada langkah perbandingan dan manfaat. Alur optimasi yang ada menargetkan perangkat secara berurutan dan memerlukan banyak iterasi. Strategi yang diusulkan, di sisi lain, mencapai tingkat penargetan 87% dan secara drastis mengurangi waktu penyelesaian dari 30 hari menjadi hanya tiga hari dengan mengoptimalkan semua variabel di semua perangkat sekaligus.

Metode ini secara efisien menyelesaikan kesulitan dan pertimbangan yang melekat pada pengembangan proses BCD, menawarkan solusi yang andal untuk produksi semikonduktor generasi berikutnya dengan menggabungkan model regresi berbasis AI dengan simulasi TCAD dan menggunakan GA untuk optimasi.

Melalui pemeriksaan fungsi jaringan saraf yang tidak dapat dikloning secara fisik (NN PUF), yang diimplementasikan pada papan evaluasi field-programmable gate array (FPGA) SAKURA-G, artikel evaluasi kinerja perangkat otentikasi AI yang diimplementasikan pada SAKURA-G membahas masalah keamanan yang terkait dengan AI. NN PUF memanfaatkan variasi dalam produksi integrasi skala besar (LSI) untuk menghasilkan identifikasi unik (ID) untuk verifikasi perangkat dengan menggabungkan jaringan saraf dan fungsi yang tidak dapat dikloning secara fisik. Makalah mengevaluasi kinerja NN PUF berdasarkan difusivitas, kestabilan, keacakan, dan keunikan. Metodenya meliputi implementasi NN PUF, sirkuit PUF, dan metode otentikasi.

NN PUF mengintegrasikan jaringan saraf multilayer menggunakan kerangka jaringan tabel pencarian (LUT). Jaringan saraf memiliki tingkat input 1.024 LUT. Dua lapisan disematkan menggunakan masing-masing 360 dan 60 LUT. Lapisan produksi mencakup sepuluh LUT. NN dimaksudkan untuk mengidentifikasi angka yang ditulis tangan menggunakan dataset MNIST, dengan input 784 bit sebagai batasan PUF.

Untuk mode otentikasi sirkuit fungsi yang tidak dapat dikloning secara fisik, NN PUF menggunakan pasangan tantangan dan respons untuk otentikasi perangkat. Produk akhir dari jaringan saraf terhubung ke sirkuit – misalnya, flip-flop tipe D yang menghasilkan respons PUF dengan mengekstrak perbedaan dalam penundaan propagasi sinyal. Variasi penundaan ini, karena perbedaan manufaktur LSI, membantu menghasilkan ID unik.

Metrik evaluasinya adalah keacakan, kestabilan, penyebaran, dan keunikan. Keacakan mengukur keseragaman kemunculan 0/1 dalam ID yang dihasilkan, yang dievaluasi oleh bobot Hamming, yang ditandai sebagai bagian dari ukuran ID. Kestabilan menilai kemampuan duplikasi ID untuk tantangan input yang sama, diperkirakan dengan jarak intra-Hamming tantangan yang sama (SC Intra-HD). Penyebaran menentukan bagaimana ID berubah dengan tantangan input yang berbeda, dinilai oleh intra-HD tantangan yang berbeda (DC Intra-HD), dan keunikan mengevaluasi varians ID antara perangkat yang berbeda, dinilai oleh inter-HD tantangan yang sama (SC Inter-HD).

Metode ini menyediakan kerangka kerja komprehensif untuk mengevaluasi kinerja NN PUF pada papan FPGA canggih, menekankan pentingnya variasi proses dalam kinerja PUF.




Metode untuk secara efektif menggunakan teknik pembelajaran mendalam untuk mencari kesamaan dalam peta cacat wafer disajikan dalam makalah “Pencarian kesamaan peta cacat wafer menggunakan pembelajaran mendalam dalam manufaktur semikonduktor.” Langkah pertama dalam prosedur ini adalah mengubah gambar pemindaian cacat mentah menjadi representasi skala abu-abu dari kepadatan cacat, pengurangan noise, dan distribusi cacat. Untuk ekstraksi fitur, digunakan CNN yang telah dilatih sebelumnya, yaitu ResNet. Setelah dilatih pada dataset yang cukup besar, jaringan ini mengambil gambar skala abu-abu dan mengekstrak vektor fitur berdimensi tinggi yang menangkap properti cacat penting.

Model pencarian K-nearest neighbor dikembangkan dengan menggunakan ruang fitur, di mana vektor dihasilkan. n gambar teratas diidentifikasi, yang sama dengan gambar kueri, sehubungan dengan vektor fiturnya, dan ini memungkinkan ekstraksi peta cacat serupa secara efektif dari dataset yang lebih besar.

Saat menerima model pencarian dari jarak jauh, solusi ini menggunakan kerangka kerja gRPC untuk menyederhanakan komunikasi antara klien dan server sehingga klien dapat melakukan permintaan secara lokal. Akurasi dan tingkat memori sistem yang luar biasa ditunjukkan oleh tiga pencarian teratas, yang memiliki akurasi 100% dan tingkat recall 92%. Bahwa fitur pencarian menemukan 10.000 foto serupa teratas dalam waktu kurang dari empat detik adalah bukti betapa cepatnya fitur tersebut bekerja. Metode ini secara signifikan meningkatkan akurasi dan efisiensi analisis cacat dalam produksi semikonduktor.

Makalah menyajikan pendekatan baru untuk menyelesaikan penanganan prosedur numerik dalam pembuatan perangkat semikonduktor berkapasitas tinggi, khususnya berfokus pada deteksi dan prediksi lebar film dalam proses pengendapan uap kimia (CVD).

Aspek kunci dari metode yang diusulkan mencakup implementasi VM, yang memanfaatkan parameter produksi untuk memprediksi nilai pengukuran secara real-time, mengurangi kebutuhan pengambilan sampel fisik dan memperpendek waktu siklus. Keterbatasan sebagian besar strategi VM saat ini yang digunakan dalam model nonlinier universal adalah kesulitan dalam menangkap perubahan mendadak dalam proses produksi yang berfluktuasi. Selain itu, metode ML tradisional hanya memberikan nilai prediksi tanpa menilai kepercayaan hasil, yang menyebabkan akurasi lebih rendah ketika berurusan dengan data berdimensi tinggi dan ukuran sampel kecil.



Gambar 6.1 Pendapatan global konsumen elektronik.




Regresi proses lasso-Gaussian (LGPR) adalah cara untuk mengatasi keterbatasan ini; model LGPR didasarkan pada kerangka kerja pembelajaran just-in-time. LGPR menggabungkan kekuatan regresi lasso untuk pemilihan fitur dan regresi proses Gaussian untuk prediksi akurat dan kuantifikasi ketidakpastian. Hasil eksperimen menunjukkan bahwa sistem VM berbasis LGPR lebih stabil dan akurat dibandingkan dengan pendekatan tradisional, memungkinkan prediksi ketebalan film secara real-time yang lebih baik dalam proses CVD. Hal ini, pada gilirannya, mendukung pengendalian proses statistik yang efektif dan deteksi dini kondisi abnormal dalam manufaktur semikonduktor volume tinggi. Makalah berfokus pada analisis cacat dalam manufaktur semikonduktor, yang terorganisir dengan rapi menjadi tiga fase: klasifikasi cacat, pemantauan tren cacat, dan klasifikasi detail.

Metode transfer learning berbasis CNN digunakan untuk klasifikasi cacat otomatis untuk mendukung para insinyur dalam pekerjaan analitis mereka. Metodologi ini melibatkan penggunaan teknologi deep learning untuk membantu para insinyur dalam fase pertama dan ketiga analisis cacat, mengurangi biaya tenaga kerja hingga sepertiga dibandingkan dengan pekerjaan inspeksi manual. Transfer learning diperkenalkan untuk mengurangi jumlah data pelatihan berlabel yang dibutuhkan untuk klasifikasi, terutama ketika data berlabel yang andal terbatas, sehingga meningkatkan akurasi klasifikasi menggunakan sejumlah data berlabel andal yang terbatas. Makalah membahas adopsi pengawasan yang tidak akurat karena pelabelan manual yang tidak konsisten dan pemanfaatan transfer learning untuk mengurangi kebutuhan akan sejumlah besar data pelatihan dengan label kebenaran.

6.5 PROMOSI MANUFAKTUR MENGGUNAKAN AI DAN ML

Melihat permintaan global akan semikonduktor untuk IC, sangat penting untuk mempromosikan manufaktur IC dengan menggunakan teknologi AI dan ML. Sebuah makalah putih Deloitte yang mengeksplorasi peluang yang tersedia bagi perusahaan IC mengatakan bahwa ekonomi industri sebelumnya telah berlipat ganda dan sekarang tiga kali lipat. Permintaan besar akan IC memicu pengembangan chip AI; ini melibatkan hampir semua algoritma ML dan pembelajaran mendalam, yang termasuk dalam payung AI. Saat ini, skema untuk pertumbuhan manufaktur semikonduktor di India harus diumumkan. Pertumbuhan sektor elektronik, yang semikonduktornya merupakan blok bangunan, dibahas dalam. Pendapatan global konsumen elektronik digambarkan pada Gambar 6.1.

Ekonomi terbaik dunia telah berubah secara drastis karena meningkatnya manufaktur IC. Poin yang perlu dicatat di sini adalah bahwa telah terjadi evolusi 360 derajat tidak hanya dalam AI atau semikonduktor tetapi dalam keduanya. Pendapatan dunia dari elektronik konsumen yang ditunjukkan pada Gambar 6.1 memberi kita gambaran tentang peningkatan drastis permintaan elektronik, yang memiliki semikonduktor sebagai blok bangunan dasarnya. Perkembangan bertahap dalam permintaan IC melibatkan banyak teknologi seperti IoT, AI/ML, dan pembelajaran mendalam. Permintaan global untuk semikonduktor dari tahun 2020 hingga 2030 ditunjukkan pada Gambar 6.2.




Gambar 6.2 Permintaan semikonduktor dari tahun 2020 hingga 2030 di AS.

Bab ini memberi kita gambaran sekilas tentang aplikasi semua algoritma ML dalam manufaktur semikonduktor dan deteksi cacat. Pembahasan ini membahas tentang pembelajaran mesin untuk semikonduktor. Pembahasan ini mengungkapkan bahwa dengan bantuan algoritma pembelajaran mendalam, deteksi kesalahan SECS/GEM dapat dilakukan. Dalam desain prosesor berbasis AI, semikonduktor juga dapat diproduksi. NLP digunakan untuk mengekstrak fitur. Klasifikasi semikonduktor juga dapat dilakukan melalui algoritma pembelajaran mesin.

Gambar 6.2 menyoroti pertumbuhan drastis dalam produksi semikonduktor, yang pada gilirannya digunakan dalam produksi komponen seperti dioda, transistor, IC, tabung vakum, perangkat tampilan, dan optoelektronik. Komponen-komponen ini berakhir di berbagai sektor seperti otomotif, manufaktur, kedirgantaraan dan pertahanan, perawatan kesehatan, dan jaringan serta telekomunikasi. Produksi semikonduktor terkonsentrasi di beberapa wilayah, dengan 54,5% pangsa pendapatan berada di Eropa, Asia-Pasifik, dan Afrika Selatan. Toshiba Corporation, Microchip Technology, NXP Semiconductors N.V., Texas Instruments, dan Qualcomm adalah kontributor utama pertumbuhan ini.

6.6 KESIMPULAN

Dalam pembahasan ini, banyak algoritma berbasis AI yang berbeda diterapkan untuk meningkatkan produksi dan deteksi kesalahan pada semikonduktor. Dari pembahasan ini, serta dengan mengamati pertumbuhan pasar, dapat disimpulkan bahwa ada banyak peluang untuk desain IC berbasis semikonduktor serta produksi IC. Untuk memenuhi permintaan ini, banyak algoritma ML dan algoritma pembelajaran mendalam dapat diterapkan untuk meningkatkan produksi dan mengurangi cacat, dan penelitian lebih lanjut juga diperlukan untuk lebih mendigitalisasi dunia ini.



BAB 7

ANALISIS NUMERIK BIOSENSING BIOFET SILINDRIS BERBASIS ML


7.1 PENDAHULUAN

Transistor efek medan (FET) merupakan kemajuan penting dalam bidang elektronik, yang memiliki berbagai jenis untuk berbagai penggunaan dan aplikasi. Kemampuan adaptasinya sangat berharga di sektor biomedis, di mana mereka melayani berbagai tujuan klinis. Biosensor berbasis FET digunakan untuk mendiagnosis dan memantau penyakit seperti Alzheimer, kanker, HIV, dan penyakit kardiovaskular (PJK). Namun, selektivitas dan faktor pengisian non-kesatuan dapat menimbulkan sedikit penyimpangan dalam pengukuran waktu nyata.

Dengan kemajuan ilmu pengetahuan dan teknologi, FET telah menemukan aplikasi dalam perangkat medis penting, seperti defibrillator, sistem pengiriman obat, deteksi biomolekul tanpa label, dosimetri in vivo, pemantauan CVD, alat bantu dengar, dan perangkat implan lainnya. Di antara perangkat tersebut, biosensor berbasis FET (BioFET) banyak dipelajari karena potensinya sebagai alternatif yang ekonomis dan dapat diandalkan untuk sensor klinis konvensional.

BioFET sangat terkenal karena akurasi dan respons liniernya yang tinggi, sehingga cocok untuk dosimetri in vivo selama radioterapi. Grenier et al. menyoroti penggunaan FET dalam transformasi bakteri, yang penting untuk prosedur medis seperti transfusi DNA dan elektroporasi. Selanjutnya, Morf et al. menggambarkan sensor THz berdasarkan bolometer MOSFET yang terhubung dengan antena, berguna di bidang biomedis untuk deteksi jarak jauh bahan kimia berbahaya dan karakterisasi material (deteksi barang selundupan tanpa menggunakan radiasi pengion).

Biosensor adalah alat yang dibuat untuk identifikasi biomolekul secara cepat. Dalam bioelektronik, BioFET semakin populer karena sensitivitas dan skalabilitasnya yang luar biasa. Biosensor ini berfungsi dengan memanfaatkan karakteristik molekuler, seperti konstanta dielektrik dan kepadatan muatan, dari zat biokimia untuk deteksi tanpa label, memungkinkan pengenalan langsung biomolekul tanpa perlu entitas berlabel. Mekanisme deteksi utama dalam BioFET berpusat pada modulasi dielektrik parameter penginderaan. Gambar 7.1 menguraikan prinsip dasar serta mekanisme deteksi dasar BioFET.



Gambar 7.1 Prinsip perangkat fundamental pada BioFET silindris.

Tegangan ambang berfungsi sebagai parameter penginderaan utama dalam BioFET, dilengkapi dengan metrik seperti kemiringan subambang, arus OFF, rasio I_{ON}/I_{OFF} , dan transkonduktansi untuk evaluasi sensitivitas. Dalam BioFET, rongga direkayasa dalam lapisan oksida gerbang untuk secara efektif mengimobilisasi biomolekul. Fitur struktural ini mengubah potensial listrik dan distribusi medan setelah imobilisasi biomolekul, sehingga menyebabkan perubahan pada tegangan ambang. Perubahan ini mencerminkan sensitivitas biosensor terhadap biomolekul tertentu, memfasilitasi deteksi melalui modulasi sifat dielektrik. Biosensor yang efektif menunjukkan sensitivitas yang lebih tinggi, yang bermanifestasi sebagai pergeseran tegangan ambang yang signifikan sebagai respons terhadap keberadaan biomolekul. Berbagai varian BioFET telah dilaporkan dan dijelaskan dalam literatur. Ahangani dan rekan-rekan. dan Li dan rekan-rekan. telah mengeksplorasi sensitivitas melalui dinamika tegangan ambang dan variasi parameter lainnya. Baru-baru ini, Pratap dan rekan-rekan. dan Chakraborty dan rekan-rekan. memelopori desain BioFET silindris baru menggunakan transistor tanpa sambungan, menggunakan beragam metrik penginderaan untuk deteksi biomolekul. Gao dan rekan-rekan. mendemonstrasikan FET nanowire yang beroperasi di rentang subambang untuk aplikasi penginderaan protein dan pH. Gautam dan rekan-rekan. dan Pour dan rekan-rekan. menyoroti FET silindris untuk aplikasi penginderaan gas. Ukuran spesies biokimia berkisar dari milimeter hingga femtometer. Dam dan rekan-rekan. mencapai sensitivitas yang kuat dengan biosensor glukosa berbasis FET yang menargetkan deteksi glukosa oksidase. Baru-baru ini, Koshti dan rekan-rekan. memperkenalkan biosensor berbasis FET untuk mendeteksi virus COVID-19.

Selama dekade terakhir, para peneliti telah mengeksplorasi berbagai desain BioFET yang dipresentasikan oleh berbagai penulis. Biosensor ini telah diteliti dengan konfigurasi struktural, material oksida, dan fungsi kerja yang berbeda. Namun, belum ada laporan sebelumnya tentang peningkatan sensitivitas melalui optimasi doping untuk memodulasi tegangan ambang pada sensor ini. Fokus utama bab ini adalah untuk mengoptimalkan profil



doping di daerah sumber, drain, dan kanal untuk mencapai peningkatan sensitivitas yang signifikan pada BioFET. Dalam aplikasi praktis, biasanya diharapkan rongga di dalam BioFET tetap terisi sebagian karena keadaan yang tidak dapat dihindari.

Oleh karena itu, penting untuk memeriksa bagaimana rongga yang terisi sebagian memengaruhi sensitivitas biosensor. Faktor pengisian, yang menunjukkan fraksi volume rongga yang ditempati oleh biomolekul, memainkan peran penting dalam konteks ini. Terlepas dari pentingnya hal ini, pembahasan komprehensif tentang efek faktor pengisian pada sensitivitas BioFET masih kurang dalam literatur terkait. Oleh karena itu, tujuan kedua penelitian dalam bab ini adalah untuk menyelidiki secara komprehensif pengaruh faktor pengisian terhadap sensitivitas tegangan ambang dalam konteks aplikasi biosensing.

Biosensor tradisional sering menghadapi tantangan terkait sensitivitas, spesifisitas, dan adaptabilitas. Namun, algoritma pembelajaran mesin (ML) dapat secara efektif mengatasi masalah ini dan secara signifikan meningkatkan kinerja biosensor. ML, sebuah disiplin ilmu dalam kecerdasan buatan (AI), memberdayakan komputer untuk belajar dari data dan membuat prediksi atau keputusan berdasarkan informasi tersebut. Dalam biosensing, algoritma ML dapat menganalisis data kompleks yang dihasilkan oleh biosensor, meningkatkan akurasi, dan mengotomatiskan proses pengambilan keputusan. Dengan memanfaatkan ML, biosensor dapat diubah menjadi instrumen yang lebih ampuh untuk mendeteksi dan memantau penyakit, polutan, dan racun.

Diskusi ini secara singkat berpusat pada dua aspek utama: memanfaatkan pembelajaran mesin untuk analisis data dan menerapkan ML dalam desain sensor. Terakhir, secara singkat membahas tantangan dan peluang untuk memajukan biosensor berbasis ML. Selain itu, ML memungkinkan biosensor untuk beradaptasi dengan kondisi lingkungan yang bervariasi dan mengoptimalkan kinerja melalui pembelajaran berkelanjutan. Kemampuan ini sangat penting untuk aplikasi dunia nyata, di mana faktor lingkungan dapat berfluktuasi dari waktu ke waktu. Biosensor berbasis ML juga menjanjikan integrasi dengan platform internet of things (IoT), memfasilitasi pemantauan jarak jauh dan transmisi data waktu nyata untuk meningkatkan kegunaan dan aksesibilitas. Gambar 7.2 menunjukkan dasar-dasar prinsip di balik integrasi ML dan rekayasa BioFET.

FET silindris telah dipilih di sini karena kemampuannya untuk secara efektif mengontrol aliran pembawa muatan dan mempertahankan integritas elektrostatik, karena desain gerbang di sekitarnya. Bagian pertama secara singkat meninjau literatur, mengidentifikasi kesenjangan penelitian, dan menguraikan ruang lingkup pembahasan saat ini. Bagian kedua menguraikan kalibrasi BioFET, proses fabrikasi, pengaturan simulator, dan metodologi yang digunakan. Pada bagian ketiga, temuan penting dan grafik yang sesuai dibahas, dengan fokus pada dampak doping, variasi suhu, dan faktor pengisian pada sensitivitas tegangan ambang. Terakhir, bagian keempat merangkum temuan utama, membahas aplikasi potensial, dan menggarisbawahi aspek inovatif dari penelitian saat ini.

Langkah	Tahapan	Deskripsi
Langkah 1	Pengumpulan dan Pra-pemrosesan Data	Mengumpulkan data sensor mentah dari BioFET, dan melakukan pra-pemrosesan pada data yang telah dikumpulkan.

Langkah 2	Ekstraksi Fitur dan Pembagian Data	Mengekstrak fitur-fitur relevan dari data yang dikumpulkan, kemudian membagi dataset menjadi set pelatihan (<i>training</i>) dan set pengujian (<i>testing</i>).
Langkah 3	Pemilihan, Pelatihan, dan Evaluasi Model	Memilih model ML (contoh: SVM, <i>random forest</i> , jaringan saraf) berdasarkan karakteristik data. Melatih model dengan dataset pelatihan, dan menilai kinerja menggunakan dataset pengujian (misalnya: akurasi, sensitivitas, spesifisitas).
Langkah 4	Optimasi dan Implementasi	Melakukan penalaan halus (<i>fine-tuning</i>) parameter model untuk meningkatkan kinerja (misalnya: <i>grid search</i> , validasi silang). Menerapkan model yang telah dilatih untuk prediksi waktu nyata atau masa depan pada BioFET.
Langkah 5	Integrasi dan Interpretasi	Mengintegrasikan model pembelajaran mesin ke dalam sistem biosensor. Menginterpretasikan prediksi dan hasil model untuk memperoleh wawasan biologis yang bermakna.


Gambar 7.2 Diagram alir dasar yang menjelaskan implementasi pembelajaran mesin dalam mempelajari BioFET.

7.2 PANDUAN KALIBRASI DAN PEMODELAN SIMULATOR BioFET

Kalibrasi Dan Karakteristik Biofet

BioFET silindris dikalibrasi dengan nilai standar untuk mengoptimalkan sensitivitas. Gerbang polisilikon dengan fungsi kerja 4,96 eV dipilih karena kesederhanaan fabrikasinya dan rentang suhu operasi yang luas dibandingkan dengan gerbang logam. Pasokan bias dibatasi hingga 1 V, yang merupakan standar untuk BioFET skala nano.

Afinitas elektron ditetapkan pada 4,17 eV. Nilai terkalibrasi dari celah pita energi, kerapatan keadaan efektif dalam pita valensi, dan pita konduksi pada suhu kamar masing-masing adalah 1,08 eV, $1,04 \times 10^{19}/\text{cm}^3$, dan $2,8 \times 10^{19}/\text{cm}^3$. Gambar 7.3a dan 7.3b menyajikan tampilan 3D dan 2D dari BioFET yang diusulkan. Memilih desain rongga dua sisi simetris dibandingkan konfigurasi satu sisi menawarkan keuntungan seperti peningkatan probabilitas pengisian, pengurangan konsumsi daya, dan peningkatan sensitivitas arus. Dimungkinkan untuk menanamkan rongga di dalam lapisan oksida gerbang SiO_2 . Langkah-langkah fabrikasi terperinci untuk BioFET digambarkan pada Gambar 7.3c menggunakan format diagram alir.





Gambar 7.3 (a) Tampilan 3D, (b) Tampilan 2D, dan (c) Diagram alir proses fabrikasi, yang menggambarkan langkah-langkah fabrikasi dasar BioFET silindris.

Spesifikasi Pra-Penyiapan Tcad


Investigasi numerik BioFET silindris dianalisis menggunakan nilai-nilai yang tercantum dalam Tabel 7.1 pada simulator ATLAS TCAD. Untuk meniru kondisi waktu nyata, model terkait harus dimasukkan selama simulasi: model Shockley-Read-Hall (SRH) mendukung pembangkitan dan rekombinasi pembawa muatan, model mobilitas bergantung konsentrasi (CONMOB) menghubungkan profil pengotor dengan mobilitas medan rendah pada suhu ruangan, dan model mobilitas bergantung medan listrik paralel (FLDMOB) memperhitungkan mobilitas bergantung medan. Untuk menyelesaikan persamaan diferensial nonlinier dan kompleks, metode Newton-Gummel digunakan, yang mengintegrasikan iterasi yang terpisah dan terhubung.



Gambar 7.3 (Lanjutan)

Pemodelan Sifat Elektro-Fisik Biomolekul

Biomolekul didefinisikan berdasarkan kerapatan muatan spesifiknya (ρ) dan konstanta dielektriknya (K_{bio}). Misalnya, DNA non-hibridisasi membawa muatan negatif dan menunjukkan kerapatan muatan dan konstanta dielektrik yang bervariasi. Sebaliknya, biomolekul netral seperti urikase, zein, dan streptavidin hanya memiliki konstanta dielektrik. Berbagai biomolekul uji yang digunakan dalam penelitian ini tercantum dalam Tabel 7.1.



Tabel 7.1 Parameter Struktural

Parameter	Nilai
Panjang Saluran (L_{CH})	30 nm
Radius Sumber/Saluran/Saluran Keluar (R_B)	10 nm
Tipe Material Sumber	tipe-n
Tipe Material Saluran	tipe-p Silikon (Si)
Tipe Material Saluran Keluar (Drain)	tipe-n
Fungsi Kerja Gerbang (Gate work function)	4,96 eV
Doping Saluran (N_c)	$10^{10}/cm^3$
Doping Sumber (N_s)	1×10^{13} hingga $5 \times 10^{20}/cm^3$
Doping Saluran Keluar (N_D)	1×10^{13} hingga $5 \times 10^{20}/cm^3$
Panjang Sumber/Saluran Keluar	10 nm
Ketebalan Lapisan Oksida (t_{ox})	6 nm
Ketebalan Rongga (Cavity)	$t_1 = 1$ nm; $t_2 = 4$ nm; $t_3 = 1$ nm
Panjang Rongga (Cavity)	$L_{CH1} = L_{CH2} = 14$ nm; $L_{CH3} = 2$ nm
Oksida Gerbang	Silikon Dioksida (SiO_2)
Prategangan (Biasing)	$V_{DS} = (0 - 1)V$ $V_{GS} = (0 - 1)V$
Panjang Oksida	30 nm
Biomolekul	
Biomolekul Netral	
Uricase ($K=1,54$) [29] bio	Streptavidin ($K_{bio} = 2.1$) [50]
Protein ($K_{blo} = 2,5$) [29]	Biotin ($K_{blo} = 2,63$) [51]
ChOX ($K_{lo} = 3,3$) [29]	APTES ($K_o = 3,57$) [50]
Hidroprotein ($K_{blo} = 5$) [52]	Keratin ($K_{bio} = 8$) [53]
Biomolekul bermuatan	
DNA [54]	
$K = 5; p = 1 \times 10^{11}/cm^2$	$K_{bio} = 5; p = +1 \times 10^{11}/cm^2$


Penelitian ini mencakup berbagai biomolekul dengan kerapatan muatan yang berbeda untuk memeriksa variasi pola sensitivitas. Dengan mempertimbangkan biomolekul bermuatan dan netral, penelitian ini bertujuan untuk memberikan analisis sensitivitas biosensor yang komprehensif dan realistis.

Ketika rongga kosong, rongga tersebut berisi udara dengan konstanta dielektrik $K_{air} = 1$. Memasukkan biomolekul uji (dengan $K_{bio} \neq 1$) ke dalam rongga menyebabkan perubahan tegangan ambang dan karakteristik perangkat lainnya. Variasi ini terjadi karena biomolekul mengubah kapasitansi oksida gerbang dan medan listrik lateral, sehingga memodifikasi distribusi potensial di sepanjang kanal. Pergeseran relatif pada tegangan ambang berfungsi sebagai ukuran kualitatif dalam investigasi biosensing BioFET.

Penting untuk dicatat bahwa sementara biomolekul memengaruhi kapasitansi oksida dan dengan demikian memengaruhi medan listrik lateral, doping memengaruhi medan listrik



horizontal dengan menyesuaikan penghalang potensial pada sambungan sumber-kanal dan drain-kanal. Metodologi numerik yang digunakan untuk analisis sensitivitas secara ringkas diwakili dalam diagram alir yang ditunjukkan pada Gambar 7.4.




Gambar 7.4 Bagan alir yang menggambarkan ringkasan metodologi yang digunakan untuk analisis sensitivitas.

7.3 DETEKSI BIOMOLEKUL UNTUK APLIKASI KLINIS

Deteksi dini beberapa penyakit kronis dapat dicapai secara efektif menggunakan BioFET silindris. Ini termasuk kondisi seperti kanker ovarium atau payudara, penyakit Alzheimer, dan karsinoma hepatoseluler (HCC), di mana biomolekul spesifik memainkan peran penting dalam skrining penyakit. BioFET dapat mendeteksi urikase ($K_{\text{bio}} = 1,54$), yang penting untuk mencegah nefropati asam urat, dan streptavidin ($K_{\text{bio}} = 2,1$), yang digunakan dalam uji imunologi dan blotting. Biomolekul lain yang dapat dideteksi termasuk kolesterol oksidase ($K_{\text{bio}} = 3,3$), yang umum digunakan dalam biokatalisis, dan aminopropil trietoksilsilan ($K_{\text{bio}} = 3,57$), yang penting untuk proses silanisasi. Tabel 7.2 merinci pergeseran tegangan ambang yang diamati ketika biomolekul ini terlokalisasi di dalam rongga nanogap biosensor (BioFET).

Tabel 7.2 Pergeseran Tegangan Ambang untuk Biomolekul yang Berbeda


Biomolekul	Pergeseran Tegangan Ambang (ΔV_t)
Uricase	39,0281 mV
Streptavidin	74,5910 mV
Kolesterol Oksidase	134,914 mV
Aminopropil Trietoksilsilan	141,048 mV
$N_S = N_D: 10^{19} / \text{cm}^3 L_1 = L_2: 14 \text{ nm}$	$N_C: 10^{10} / \text{cm}^3 \quad V_{DS}: 0,5 \text{ V}$



--	--

Pengaruh Doping

Meningkatkan doping sumber dan drain dalam pola yang identik akan menghasilkan dua efek utama: Efek 2 dan Efek 1. Ketika doping sumber dan drain ditingkatkan dengan laju yang sama dari nilai rendah ke nilai tinggi, sebagian besar daerah deplesi akan menembus ke dalam kanal daripada sumber (sambungan sumber-kanal) atau drain (sambungan drain-kanal), yang pada dasarnya adalah Efek 1. Lebar lapisan deplesi agregat terus berkurang dengan peningkatan doping, yang pada dasarnya adalah Efek 2. Jadi, baik Efek 1 maupun Efek 2 akan hadir ketika doping sumber dan drain ditingkatkan dari nilai rendah ke nilai tinggi. Efek 2 lebih dominan pada doping rendah, yang menyebabkan pengurangan lebar lapisan deplesi, sehingga meningkatkan panjang kanal efektif. Efek 1 lebih dominan pada doping tinggi, yang menyebabkan penetrasi lapisan deplesi ke dalam kanal, sehingga mengakibatkan penurunan panjang kanal efektif. Kedua efek ini ditunjukkan dalam diagram alur pada Gambar 7.5. Notasi doping s_t_u menunjukkan doping sumber ($1 \times 10^5/\text{cm}^3$), kanal ($1 \times 10^4/\text{cm}^3$), dan drain ($1 \times 10^4/\text{cm}^3$) dalam urutan yang sama, dan notasi S_C_D menunjukkan sumber_kanal_drain, masing-masing. Nilai doping D_A – D_H ditentukan dalam Tabel 7.3.




Gambar 7.5 Visualisasi efek doping pada panjang kanal efektif.

Gambar 7.6 menggambarkan variasi sensitivitas tegangan ambang di berbagai biomolekul. Awalnya, tegangan ambang meningkat karena panjang kanal efektif yang lebih panjang pada tingkat doping yang lebih rendah (Efek 2), yang memerlukan tegangan gerbang yang lebih tinggi untuk mengaktifkan FET. Peningkatan tegangan gerbang ini menghasilkan tegangan ambang yang lebih tinggi, yang menyebabkan peningkatan sensitivitas pada tegangan gerbang yang lebih rendah. Sebaliknya, pada tingkat doping yang lebih tinggi,

panjang kanal efektif menurun (Efek 1), yang memerlukan tegangan gerbang yang lebih rendah (tegangan ambang) untuk aktivasi perangkat.

Oleh karena itu, sensitivitas menurun seiring dengan peningkatan tingkat doping. Tegangan ambang menunjukkan peningkatan awal yang kemudian diikuti oleh penurunan seiring dengan peningkatan tingkat doping sumber dan drain secara seragam, seperti yang diilustrasikan pada sisipan Gambar 7.6. Perlu dicatat, ketika biomolekul hadir di dalam rongga pada tingkat doping rendah, tegangan ambang berubah lebih dari ~400%, menunjukkan sensitivitas yang substansial, yang sangat penting untuk aplikasi biosensing.



Gambar 7.6 Sensitivitas tegangan ambang (SVt) pada doping berbeda untuk berbagai biomolekul uji. ([SISIPAN] Menunjukkan variasi tegangan ambang pada doping berbeda untuk berbagai biomolekul uji.)

Meskipun mencapai sensitivitas persentase tinggi pada tingkat doping rendah bermanfaat, konduktivitas perangkat berkurang dalam kondisi tersebut, sehingga membatasi penggunaan doping rendah pada BioFET. Oleh karena itu, keseimbangan antara sensitivitas dan konduktivitas harus dicapai melalui tingkat doping yang dioptimalkan untuk mencapai kinerja optimal. Selain itu, keberadaan biomolekul bermuatan memengaruhi nilai tegangan ambang. Biomolekul bermuatan positif menarik elektron dari substrat, menciptakan saluran pada tegangan gerbang yang lebih rendah dan mengurangi tegangan ambang dibandingkan dengan biomolekul netral.

Sebaliknya, biomolekul bermuatan negatif meningkatkan tegangan ambang. Oleh karena itu, sensitivitas tegangan ambang menunjukkan tren yang serupa untuk biomolekul bermuatan seperti yang diamati pada biomolekul netral. Memahami dinamika ini sangat penting untuk menyesuaikan desain BioFET dengan interaksi biomolekul spesifik dan mengoptimalkan kinerjanya dalam berbagai aplikasi biologis dan lingkungan. Perlu dicatat bahwa perubahan relatif pada Vt signifikan pada tingkat doping yang lebih tinggi dan minimal pada tingkat doping yang lebih rendah, yang merupakan kebalikan dari tren yang diamati pada perubahan persentase sensitivitas.



Tabel 7.3 m enyajikan data tentang kemiringan subambang (SS) dan sensitivitas kemiringan subambang (S_{SS}) di berbagai tingkat doping simetris. Kemiringan subambang diperoleh dari kurva $\log(I_{DS})-V_{GS}$ (karakteristik transfer) dan berkorelasi terbalik dengan kapasitansi deplesi. Pada tingkat doping yang lebih rendah, di mana Efek 2 mendominasi, lebar deplesi menurun seiring peningkatan dopi n g, m enghasilkan kapasitansi deplesi yang lebih tinggi dan kemiringan subambang yang lebih rendah (SS menunjukkan hubungan terbalik nonlinier dengan kapasitansi deplesi).

				$K_{bio} = 5$	
Label Doping		ρ		ρ	ρ
$N_S-N_C-N_D- (cm^{-3})$		$-1 \times 10^{11} \text{ cm}^{-2}$		0	$+1 \times 10^{11} \text{ cm}^{-2}$
D_A	$10^{13}_-10^{10}_-10^{13}$	SS	71,943	72,016	72,949
		S_{SS}	25,11756	25,0421	24,07005
D_B	$10^{14}_-10^{10}_-10^{14}$	SS	71,933	71,957	71,999
		S_{SS}	24,08303	24,05791	24,0545
D_C	$10^{15}_-10^{10}_-10^{15}$	SS	71,413	71,417	71,476
		S_{SS}	24,04949	24,04556	23,98249
D_D	$10^{16}_-10^{10}_-10^{16}$	SS	71,2799	71,28	71,281
		S_{SS}	23,82677	23,82673	23,82566
D_E	$10^{17}_-10^{10}_-10^{17}$	SS	71,206	71,209	71,212
		S_{SS}	23,67215	23,66915	23,66604
D_F	$10^{18}_-10^{10}_-10^{18}$	SS	71,144	71,146	71,149
		S_{SS}	23,96603	23,964	23,96058
D_G	$10^{19}_-10^{10}_-10^{19}$	SS	77,467	77,612	77,761
		S_{SS}	37,11498	36,99703	36,87624
D_H	$10^{20}_-10^{10}_-10^{20}$	SS	93,946	94,072	94,226
		S_{SS}	44,17691	44,10204	44,01065
SS: (mV/decade) ⁻¹		S_{SS} : (Percentage)			
$S_{SS} = \left \frac{SS_{(air)} - SS_{(bio)}}{SS_{(air)}} \right \times 100$					
(7.1)					

Tabel 7.3 Variasi SS dan SSS pada Doping Simetris yang Berbeda


Sebaliknya, pada tingkat doping yang lebih tinggi, yang didominasi oleh Efek 1, kemiringan subambang meningkat seiring dengan doping. Kemiringan subambang yang lebih tinggi menunjukkan variabilitas yang lebih signifikan dalam arus drain untuk rentang tegangan gerbang yang sama, menunjukkan perubahan yang lebih jelas pada tingkat doping yang lebih tinggi. Minimum lokal dalam pola kemiringan subambang terlihat jelas pada Tabel 7.3. Biomolekul bermuatan positif sedikit meningkatkan arus ON, sedangkan biomolekul bermuatan negatif sedikit menurunkannya dibandingkan dengan biomolekul netral.

Peningkatan arus ON ini meningkatkan karakteristik subambang, yang menyebabkan peningkatan kemiringan subambang, meskipun perubahan relatifnya berkurang. Yang penting, tegangan ambang menunjukkan perubahan relatif yang lebih besar daripada kemiringan



subambang, menyoroti sensitivitasnya yang unggul sebagai metrik untuk menganalisis kinerja biosensor. Memahami dinamika ini sangat penting untuk memajukan biosensor berbasis FET menuju peningkatan sensitivitas dan keandalan dalam konteks biologis dan lingkungan yang kompleks. Strategi optimasi dapat memanfaatkan wawasan ini untuk menyempurnakan desain dan kinerja sensor.


Gambar 7.7 mengilustrasikan perubahan sensitivitas tegangan ambang, disertai dengan sisipan yang menunjukkan sensitivitas kemiringan subambang, seiring dengan peningkatan tingkat doping (i) drain (dengan doping sumber dan kanal konstan) dan (ii) sumber (dengan doping drain dan kanal konstan) dari tingkat doping referensi (DRD: $N_C = 10^{10}/\text{cm}^3$ dan $N_S = N_D = 10^{19}/\text{cm}^3$). Tingkat doping referensi yang dipilih tinggi, sehingga peningkatan lebih lanjut pada doping sumber atau drain akan meningkatkan sensitivitas tegangan ambang dan sensitivitas kemiringan subambang karena adanya Efek 2 pada doping tinggi. Perlu dicatat, sensitivitas jauh lebih tinggi ketika doping drain melebihi doping sumber. Tingkat doping terperinci (D_{D1} – D_{D3} dan D_{S1} – D_{S3}) diuraikan dalam Tabel 7.4, yang juga mengilustrasikan pola kemiringan subambang dan tegangan ambang yang diamati pada doping asimetris yang berbeda, mengungkapkan minimum lokal pada tingkat doping referensi. Gambar 7.8 menunjukkan variasi sensitivitas yang diamati dengan berbagai biomolekul netral.



Gambar 7.7 Sensitivitas tegangan ambang (SVt) pada doping asimetris yang berbeda untuk berbagai biomolekul uji. (Menunjukkan variasi sensitivitas kemiringan subambang pada doping asimetris yang berbeda untuk berbagai biomolekul uji.)

Peningkatan konstanta dielektrik spesies biokimia menyebabkan peningkatan kapasitansi oksida di dalam rongga. Peningkatan kapasitansi oksida gerbang ini memperkuat interaksi antara pembawa muatan dan gerbang. Akibatnya, baik tegangan ambang maupun kemiringan subambang menunjukkan perubahan yang lebih nyata pada nilai K_{bio} yang lebih tinggi (relatif terhadap skenario rongga kosong), menunjukkan peningkatan sensitivitas biosensor terhadap biomolekul dengan K_{bio} yang lebih tinggi. Tabel sisipan pada Gambar 7.8

menguraikan variasi sensitivitas tegangan ambang dan sensitivitas kemiringan subambang untuk berbagai biomolekul bermuatan, menyoroti sensitivitas yang lebih kuat terhadap biomolekul bermuatan negatif karena peningkatan kopling gerbang-ke-saluran.




Gambar 7.8 Sensitivitas tegangan ambang dan sensitivitas kemiringan subambang dengan adanya berbagai biomolekul netral.

Meningkatkan konstanta dielektrik biomolekul meningkatkan kapasitansi oksida gerbang, memperkuat interaksi antara pembawa muatan dan gerbang. Hal ini meningkatkan sensitivitas biosensor berbasis FET, khususnya terhadap biomolekul dengan konstanta dielektrik yang lebih tinggi, sehingga meningkatkan kemampuan deteksi dalam berbagai lingkungan biokimia. Memahami dinamika ini sangat penting untuk menyesuaikan BioFET agar dapat secara efektif mendeteksi biomolekul dengan muatan dan karakteristik dielektrik yang bervariasi.


Tabel 7.4 Variasi Vt dan SS pada Doping Asimetris yang Berbeda

				$K_{bio} = 5$		
Nilai Doping $N_{S-} \ N_{C-} \ N_{D-} \ (\text{cm}^{-3})$				ρ $-1 * 10^{11}\text{cm}^{-2}$	ρ 0	P $+1 * 10^{11}\text{cm}^{-2}$
D _{s3}	$5 * 10^{20} _1 * 10^{10} _1 * 10^{19}$		SS	84.7319	84.933	85.1551
			V _t	424.49	412.21	399.754
D _{s2}	$1 * 10^{20} _1 * 10^{10} _1 * 10^{19}$		SS	83.8564	84.015	84.1602
			V _t	427.493	415.15	402.624
D _{s1}	$5 * 10^{20} _1 * 10^{10} _1 * 10^{19}$	N_S	SS	82.593	82.705	82.8195
			V _t	429.305	416.51	402.73
D _{RD}	$1 * 10^{20} _1 * 10^{10} _1 * 10^{19}$	RD	SS	77.4668	77.612	77.7609




		N_D	V_t	430.309	416.8	402.911
D_{D1}	$1 * 10^{20}_1 * 10^{10}_1 * 10^{19}$		SS	83.1755	83.341	83.5154
			V_t	419.28	405.74	391.808
D_{D2}	$1 * 10^{20}_1 * 10^{10}_1 * 10^{19}$		SS	84.9219	85.126	85.3389
			V_t	416.489	402.94	388.99
D_{D3}	$1 * 10^{20}_1 * 10^{10}_1 * 10^{19}$		SS	86.6484	86.81	86.9765
			V_t	412.482	399.28	385.3
(Kasus i) N_D bervariasi (N_C & N_S konstan) SS: (mV/decade) ⁻¹				(Kasus ii) N_S bervariasi (N_C & N_D konstan) V_t : mV		

Gambar 7.9 mengilustrasikan perubahan rasio I_{ON}/I_{OFF} untuk hidroprotein pada berbagai tingkat doping. Sisipan memberikan perbandingan spesifik rasio I_{ON}/I_{OFF} pada tingkat doping rendah dan tinggi untuk berbagai biomolekul. Peningkatan doping sumber meningkatkan arus keadaan ON (I_{ON}) dan arus keadaan OFF (I_{OFF}). Peningkatan I_{ON} ini terutama berkontribusi pada rasio I_{ON}/I_{OFF} keseluruhan yang lebih tinggi. Namun, pada tingkat doping yang lebih tinggi, arus keadaan ON mulai menurun karena degradasi signifikan dalam mobilitas elektron.



Gambar 7.9 Rasio I_{ON}/I_{OFF} pada doping berbeda untuk hidroprotein.


Gambar 7.10 menggambarkan analisis sensitivitas tegangan ambang dan kemiringan subambang pada berbagai tingkat doping saluran. Peningkatan doping saluran menyebabkan sedikit peningkatan tegangan ambang karena dibutuhkan lebih banyak tegangan gerbang untuk mengosongkan saluran sepenuhnya. Peningkatan doping ini meningkatkan jumlah lubang yang harus dikosongkan sebelum elektron dapat mengalir dari sumber ke drain di bawah tegangan yang diterapkan.




Gambar 7.10 Sensitivitas tegangan ambang pada doping saluran yang berbeda untuk hidroprotein.

Namun, sensitivitas tegangan ambang, yang mencerminkan perubahan relatifnya, menurun dengan N_C yang lebih tinggi. Demikian pula, kemiringan subambang dan sensitivitasnya menurun dengan peningkatan doping saluran. Tingkat N_C yang tinggi mengurangi arus keadaan ON dan keadaan OFF, yang menyebabkan kemiringan yang lebih landai pada plot $I_{DS}-V_{GS}$ di wilayah subambang. Akibatnya, seiring meningkatnya N_C , baik kemiringan subambang maupun sensitivitasnya berkurang. Temuan ini menekankan peran penting doping saluran dan sifat dielektrik dalam menyeting kinerja biosensor. Dengan mengoptimalkan parameter ini, biosensor berbasis FET dapat mencapai kemampuan deteksi yang unggul, yang penting untuk berbagai aplikasi biomedis dan lingkungan.

Gambar 7.11 dan 7.12 menggambarkan bagaimana arus drain berubah dengan tegangan gerbang dan drain, masing-masing, di seluruh imobilisasi biomolekul netral yang berbeda. Sisipan pada gambar-gambar ini menunjukkan perubahan serupa untuk berbagai biomolekul bermuatan. Perbedaan relatif dalam arus drain dengan adanya biomolekul (dibandingkan dengan rongga kosong) meningkat seiring dengan meningkatnya K_{bio} karena peningkatan kopling antara saluran dan gerbang. Nilai K_{bio} yang lebih tinggi menyebabkan pengurangan arus drain yang lebih signifikan, menunjukkan perubahan yang lebih besar pada konstanta dielektrik yang lebih tinggi.




Gambar 7.11 Perubahan arus drain sebagai fungsi tegangan gerbang pada $V_{DS} = 0,5$ V untuk berbagai biomolekul netral. ([SISIPAN] Menunjukkan perubahan arus drain sebagai fungsi tegangan gerbang pada $V_{DS} = 0,5$ V untuk berbagai biomolekul bermuatan.)



Gambar 7.12 Perubahan arus drain sebagai fungsi tegangan drain pada $V_{GS} = 0,5$ V untuk berbagai biomolekul netral. ([SISIPAN] Menunjukkan perubahan arus drain sebagai fungsi tegangan drain pada $V_{GS} = 0,5$ V untuk berbagai biomolekul bermuatan.)


Biomolekul bermuatan negatif lebih meningkatkan kopling ini, menghasilkan peningkatan sensitivitas dibandingkan dengan biomolekul netral. Perlu dicatat, BioFET silindris menunjukkan sensitivitas yang lebih tinggi terhadap tegangan gerbang daripada tegangan drain dengan adanya biomolekul. Pengetahuan ini juga membuka jalan untuk menciptakan platform BioFET serbaguna yang mampu mendeteksi dan mengukur beragam biomolekul secara andal di berbagai spesies matriks biologis, memaksimalkan kinerja perangkat untuk deteksi biomarker spesifik.

Gambar 7.13 menggambarkan bagaimana sensitivitas tegangan ambang dan sensitivitas ayunan subambang bervariasi dengan bias drain pada tingkat doping tinggi, sementara sisipan menunjukkan sensitivitas ini pada tingkat doping rendah. Kedua sensitivitas meningkat seiring dengan meningkatnya jumlah pembawa muatan akibat tegangan drain yang tinggi. Peningkatan pembawa muatan ini menyebabkan perubahan yang lebih signifikan pada tegangan ambang dan kemiringan subambang ketika biomolekul hadir. Akibatnya, sensitivitas perangkat terhadap biomolekul tinggi pada tegangan drain yang lebih tinggi, karena medan listrik yang lebih kuat di sepanjang kanal.



Gambar 7.13 Sensitivitas tegangan ambang dan sensitivitas kemiringan subambang pada berbagai tegangan drain untuk berbagai biomolekul pada doping tinggi. ([SISIPAN] Menunjukkan sensitivitas tegangan ambang dan sensitivitas kemiringan subambang pada berbagai tegangan drain untuk berbagai biomolekul pada doping rendah.)


Namun, penting untuk dicatat bahwa tegangan drain tidak dapat ditingkatkan tanpa batas, karena tegangan drain yang terlalu tinggi pada perangkat kanal pendek dapat menyebabkan kerusakan permanen. Pengetahuan ini juga membuka jalan untuk menciptakan platform BioFET serbaguna yang mampu mengukur beragam biomolekul secara andal di berbagai matriks biologis, memaksimalkan kinerja perangkat untuk deteksi biomarker spesifik. Gambar 7.14 mengilustrasikan distribusi potensial di sepanjang kanal BioFET silindris untuk berbagai biomolekul netral, dengan sisipan yang menampilkan potensial minimum di sepanjang kanal pada berbagai tingkat doping simetris. Peningkatan kelengkungan potensial kanal dengan K_{bio} yang lebih tinggi menunjukkan bahwa biosensor lebih sensitif terhadap biomolekul dengan konstanta dielektrik yang lebih tinggi, mendukung hasil penelitian ini. Perubahan relatif yang lebih besar pada potensial kanal merupakan parameter kritis untuk mengevaluasi kinerja biosensing BioFET silindris.




Gambar 7.14 Potensial melintasi saluran dengan adanya berbagai biomolekul.

Perlu dicatat, peningkatan tegangan gerbang mengurangi kelengkungan potensial, sehingga potensial kanal diplot pada tegangan gerbang rendah 10 mV untuk menekankan efek biomolekul pada kelengkungan. Hasil ini menyoroti perlunya menyeimbangkan tegangan drain dan gerbang dengan cermat untuk mengoptimalkan kinerja sensor sambil menghindari kerusakan perangkat. Memahami perubahan distribusi potensial di sepanjang kanal lebih lanjut menggarisbawahi pentingnya sifat dielektrik dalam meningkatkan sensitivitas biosensor. Wawasan seperti itu sangat penting untuk merancang BioFET yang kuat dan sangat sensitif yang disesuaikan untuk aplikasi biomedis dan lingkungan tertentu.

Gambar 7.15 menunjukkan bagaimana suhu mempengaruhi sensitivitas tegangan ambang, dengan sisipan untuk berbagai biomolekul bermuatan. Peningkatan suhu meningkatkan pembangkitan pembawa muatan, menurunkan tegangan ambang dan meningkatkan perubahannya, sehingga meningkatkan sensitivitas terhadap biomolekul. Sangat penting bagi FET untuk memilih oksida gerbang yang tepat, seperti SiO₂ karena stabilitas dan kompatibilitasnya. Mengintegrasikan dielektrik high-K dengan SiO₂ mengurangi medan pinggiran tetapi mengorbankan sensitivitas dan menambah kompleksitas. Gambar 7.16 membandingkan sensitivitas pada BioFET silindris dengan dan tanpa oksida gerbang bertumpuk untuk berbagai biomolekul, menyoroti peningkatan sensitivitas versus kompleksitas fabrikasi.



Gambar 7.15 Variasi sensitivitas tegangan ambang pada suhu berbeda untuk hidroprotein.



Gambar 7.16 Sensitivitas tegangan ambang dengan dan tanpa susunan oksida gerbang untuk berbagai biomolekul netral.

Tabel 7.5 menyajikan dampak lokasi biomolekul pada berbagai faktor pengisian. Rongga di sekitar sumber dan drain dibagi menjadi empat bagian yang sama, memungkinkan berbagai biomolekul uji untuk diperiksa dalam berbagai kondisi. Kasus 5 memiliki faktor pengisian yang lebih besar daripada Kasus 4, namun Kasus 4 menunjukkan sensitivitas yang lebih tinggi. Tren ini juga diamati antara Kasus 3 dan Kasus 5, serta antara Kasus 10 dan Kasus 11, dan lain-lain.

Cavity on Both Sides Are Divided into Two-Equal Parts

Threshold Voltage Sensitivity (S_{vt} : mV)

Increasing K_{ox}

S. No.	Cavity toward the Source End	Oxide Layer	Cavity toward the Drain End	Fill-In Factor	Biomolecules									
					A	B	C	D	E	F				
1.				0.25	0.006	0.095	0.507	1.409	1.74	2.877				
2.				0.25	1.004	4.557	5.805	10.095	16.772	27.396				
3.				0.25	17.834	43.669	51.006	86.091	113.111	170.040				
4.				0.25	38.927	64.879	72.905	106.778	135.880	152.631				
5.				0.50	3.929	6.842	7.506	12.298	19.115	27.983				
6.				0.50	22.003	52.332	46.579	90.079	119.887	135.002				
7.				0.50	25.991	55.014	49.082	93.332	122.229	138.900				
8.				0.50	40.02	66.698	74.117	108.183	137.710	154.119				
9.				0.50	44.384	70.192	78.751	112.672	141.008	158.725				
10.				0.50	62.193	89.002	96.621	130.798	159.027	186.791				
11.				0.75	37.971	61.395	71.003	100.391	134.441	160.219				
12.				0.75	46.929	72.982	80.388	114.501	143.412	169.590				
13.				0.75	65.129	91.109	99.041	133.923	162.721	189.993				
14.				0.75	68.905	94.795	102.003	136.729	165.111	192.100				
A-Streptavidin					B-Protein					C-Biotin				
D-APTES					E-Hydroprotein					F-Keratin				
Presence of biomolecules Absence of biomolecules Oxide layer (SiO_2)														
$L_{on} = 14\text{nm}, L_{ox} = 14\text{nm}, L_{od} = 2\text{nm}$														
$N_b = 10^{19}/\text{cm}^2, N_p = 10^{19}/\text{cm}^2, N_n = 10^{19}/\text{cm}^2$														


Tabel 7.5 Pengaruh Faktor Pengisian dan Lokasi Biomolekul yang Berbeda pada S_{vt}

Biasanya, faktor pengisian yang lebih tinggi meningkatkan sensitivitas dengan mengimobilisasi sejumlah besar biomolekul di dalam rongga. Namun, lokasi spesifik biomolekul di dalam rongga yang terisi sebagian sangat memengaruhi sensitivitas. Kasus 4, misalnya, meskipun memiliki faktor pengisian yang sama dengan Kasus 1, menunjukkan sensitivitas yang lebih tinggi karena biomolekul terletak lebih dekat ke sumber. Kedekatan ini




meningkatkan pengaruhnya pada bukit potensial di persimpangan sumber-saluran, sehingga memengaruhi tegangan ambang secara lebih signifikan.

Akibatnya, sensitivitas dimaksimalkan ketika biomolekul diposisikan lebih dekat ke sumber. Tren sensitivitas serupa diamati dalam perbandingan antara Kasus 5 dan Kasus 10, Kasus 11 dan Kasus 14, dan skenario analog lainnya. Gambar 7.17 dan 7.18 menggambarkan analisis komparatif biosensor BioFET silindris dengan berbagai varian biosensor yang ada. Terlihat jelas dari angka-angka tersebut bahwa pergeseran tegangan ambang (sensitivitas) meningkat secara proporsional dengan pelebaran rongga, memungkinkan lebih banyak biomolekul untuk diimobilisasi di dalamnya.



Gambar 7.17 Bagan perbandingan yang menunjukkan pergeseran tegangan ambang untuk APTES pada ketebalan rongga yang berbeda.




Gambar 7.18 Bagan perbandingan yang menunjukkan pergeseran tegangan ambang untuk berbagai biomolekul.

Akibatnya, biosensor menunjukkan perubahan tegangan ambang yang lebih nyata dengan dimensi rongga yang lebih besar. Gambar 7.18 secara khusus membandingkan



sensitivitas biosensor kami dengan varian BioFET terkemuka di berbagai biomolekul. Sisipan tersebut memberikan representasi visual dari perbandingan sensitivitas tegangan ambang antara struktur yang diusulkan dan empat varian lainnya. Perbandingan ini menggarisbawahi bahwa biosensor kami menawarkan sensitivitas yang lebih unggul terhadap biomolekul dibandingkan dengan sebagian besar alternatif yang ada. Gambar 7.19 menunjukkan plot produk frekuensi transkonduktansi gain (GTFP) untuk perangkat yang diusulkan pada $N_S = N_D = 10^{19}/\text{cm}^3$ dan $N_C = 10^{10}/\text{cm}^3$.



Gambar 7.19 Plot produk frekuensi transkonduktansi gain.

Pembelajaran Mesin Dalam Meningkatkan Kinerja Biofet

Pembelajaran mesin telah secara signifikan meningkatkan kemampuan BioFET, dengan meningkatkan sensitivitas dan spesifisitasnya. BioFET adalah sensor bio-kimia canggih yang beroperasi berdasarkan prinsip yang mirip dengan transistor efek medan. Integrasi ini memungkinkan investigasi waktu nyata, yang membantu mengidentifikasi molekul biologis seperti protein, DNA, dan patogen. Melatih model ML pada kumpulan data yang besar memungkinkan deteksi perubahan halus dalam respons sensor, yang mengarah pada deteksi yang lebih efektif dan tingkat deteksi palsu yang lebih rendah. Oleh karena itu, aplikasi ML canggih pada BioFET untuk diagnostik medis, pemantauan lingkungan, dan bioteknologi menunjukkan platform alat yang ditingkatkan yang dapat mewujudkan deteksi cepat dan akurat dari banyak analit biologis.

Memungkinkan modifikasi dan penyesuaian BioFET untuk aplikasi spesifik, menggunakan pembelajaran mesin yang dikombinasikan dengan BioFET, menawarkan manfaat desain yang signifikan dalam pengembangan biosensor. Peneliti dapat menggunakan algoritma canggih untuk memodelkan berbagai kondisi dan geometri untuk menargetkan desain sensor optimal sebelum dibuat.

Hal ini mempercepat proses pengembangan sekaligus mengurangi metode coba-coba yang mahal. Selain itu, dengan menggunakan data historis, pembelajaran mesin dapat menyempurnakan parameter sensor agar menjadi lebih presisi dari waktu ke waktu, sehingga



ketika target biologis baru muncul, sensor beradaptasi dengan perubahan zaman. Data yang dihasilkan BioFET biasanya kompleks dengan banyak dimensi, yang membuat pembelajaran mesin sangat diperlukan dalam menafsirkan data tersebut.

Masuknya data yang dihasilkan sensor ini dapat sulit ditangani menggunakan metode analisis data tradisional. Di sisi lain, model ML, seperti jaringan saraf, mesin vektor pendukung (SVM), dan pohon keputusan, sangat baik untuk mengidentifikasi korelasi ini dalam kumpulan data besar. Pendekatan ini mengungkapkan detail yang lebih rinci tentang bagaimana respons sensor berhubungan dengan interaksi biologis permukaan sensor untuk hasil yang lebih akurat dan dapat direproduksi. Contohnya dapat ditemukan dalam diagnostik medis, di mana BioFET dengan pembelajaran mesin dapat membedakan antara keadaan normal dan penyakit, yang mengarah pada identifikasi tahap awal penyakit dan strategi perawatan yang lebih personal.


Dalam perluasan ke analisis statis, pembelajaran mesin juga memunculkan ide-ide pemantauan waktu nyata dan sistem umpan balik. Kondisi ini dapat berubah dengan cepat dalam lingkungan dinamis tertentu seperti diagnostik medis *in vivo* atau pemantauan lingkungan. Skenario ini membutuhkan pemrosesan data waktu nyata dan respons yang cepat. Model ML terus belajar dan menyesuaikan diri dengan aliran data baru, yang sangat cocok untuk analisis cepat dan pengambilan tindakan secara waktu nyata.

Sifat waktu nyata BioFET memastikan tingkat akurasi dan keandalan yang sama, mirip dengan instrumen meja berbasis vakum, dan kinerja yang andal dalam lingkungan dinamis, yang akan sangat berharga dalam situasi klinis dan lapangan. Perangkat diagnostik kecil dan ramah pengguna juga berkembang dengan integrasi pembelajaran mesin dan nanoteknologi. Menempatkan algoritma berkinerja tinggi dalam perangkat genggam kecil memungkinkan kita melakukan biosensing molekuler dalam pengaturan laboratorium non-tradisional. BioFET portabel semacam itu memiliki aplikasi berharga dalam pengujian di tempat perawatan, pemantauan kesehatan jarak jauh, dan diagnostik lapangan cepat, yang akan secara signifikan memfasilitasi jangkauan dan kenyamanan bioteknologi.

Praktik pembelajaran mesin yang mendasari perangkat ini telah memungkinkan akses global ke hasil berkualitas laboratorium secara langsung dan mungkin akan meningkatkan kemampuan unggulan yang dapat merevolusi praktik perawatan kesehatan di seluruh dunia. Terakhir, pembelajaran mesin memiliki banyak hal untuk diimplementasikan dalam BioFET untuk membuatnya lebih fungsional, sensitif, dan cerdas. Integrasi ini mendukung analisis data tingkat lanjut, pemodelan prediktif, pemantauan waktu nyata, dan pembuatan alat diagnostik portabel. Dengan munculnya teknologi dan penelitian baru, integrasi erat antara pembelajaran mesin dan BioFET akan terus mendorong algoritma di bidang diagnostik biosensing.

Pengenalan pembelajaran mesin dalam pengembangan BioFET melibatkan penerapan beberapa pertimbangan dan teknik penting. Teknik-teknik ini mencakup aspek-aspek penting:

1. **Pra-pemrosesan Data:** Langkah pertama adalah mempersiapkan data mentah yang dikumpulkan oleh sensor perangkat keras untuk analisis. Ini mencakup pembersihan data, standarisasi, dan peningkatan akurasi data. Metode seperti deteksi outlier, pengurangan noise, dan normalisasi mempersiapkan data. Analisis komponen utama



- (PCA) adalah salah satu teknik pengurangan dimensi, yang seringkali mengarah pada pengurangan dimensi data sambil tetap mempertahankan informasi kunci.
2. **Ekstraksi Fitur:** Ini bertanggung jawab untuk mengubah data sensor yang belum diproses menjadi sesuatu yang dapat digunakan untuk dimasukkan ke dalam model ML. Misalnya, dalam aplikasi BioFET, fitur-fiturnya dapat berupa perubahan arus, tegangan, atau resistansi akibat interaksi biologis. Metode pemrosesan sinyal seperti transformasi Fourier dan transformasi wavelet mengekstrak fitur domain frekuensi dari sinyal sensor domain waktu. Jaringan saraf konvolusional (CNN) adalah contoh metode canggih untuk mengotomatisasi ekstraksi fitur kompleks dan sangat cocok untuk membedakan pola interaksi biologis yang rumit.
 3. **Memilih Model yang Tepat:** Analisis data yang akurat bergantung pada teknik ML yang digunakan. SVM, jaringan saraf (termasuk CNN dan jaringan saraf dalam atau DNN), random forest, dan K-nearest neighbors (KNN) adalah beberapa model yang dipilih dengan mempertimbangkan sifat data dan jenis analisis yang dibutuhkan. Sifat-sifat setiap jenis model membuatnya menguntungkan dalam menangani berbagai bentuk dan kompleksitas data BioFET.
 4. **Adaptasi secara Real-Time:** Dengan adaptasi real-time, model dapat diperbarui secara berkala ketika data baru tersedia untuk menjaga keakuratan model bahkan dengan perubahan lingkungan. Untuk tujuan ini, metode yang lebih canggih seperti online learning dan reinforcement learning, antara lain, digunakan. Dalam online learning, ketika data baru masuk, algoritma pembelajaran akan meningkatkan atau mengurangi parameter model Anda. Dengan demikian, jenis pembelajaran ini sangat tepat untuk aplikasi yang membutuhkan respons real-time yang tinggi. Penggunaan BioFET yang dikombinasikan dengan pembelajaran penguatan memungkinkan BioFET untuk mempelajari respons terbaik sesuai permintaan dari umpan balik waktu nyata, yang merupakan keharusan bagi setiap sensor yang dirancang untuk beroperasi di lingkungan biologis yang rumit dan mampu berinteraksi dengan beragam target dan kondisi.
 5. **Metode Ensemble:** Dalam ensembling, alih-alih membuat prediksi tunggal, beberapa model bekerja secara bersamaan, dan hasil yang diharapkan meningkatkan kinerja dan ketahanan secara umum. Kelompok pendekatan lain termasuk bagging, boosting, dan stacking, yang menggabungkan prediksi dan mengurangi efek overfitting yang dapat terjadi selama implementasi BioFET.
 6. **Transfer Learning:** Fine-tuning meningkatkan proses pembuatan model BioFET dengan menggunakan model yang telah dilatih sebelumnya dari tugas-tugas terkait, yang membantu meningkatkan akurasi prediksi prioritas ketika dataset kecil. Terlihat bahwa BioFET tidak hanya dapat membantu memajukan model berbasis fungsi tetapi juga membantu penyebaran yang lebih cepat dalam hal biosensing dan diagnostik.
 7. **Pemeliharaan dan Kalibrasi Prediktif:** Data yang dikumpulkan memungkinkan pemantauan otomatis untuk kondisi optimal, kalibrasi, dan jadwal servis perangkat BioFET menggunakan analisis data yang tersisa dari pembelajaran mesin. Model



analitik dikembangkan untuk memprediksi kebutuhan pemeliharaan dan frekuensi kalibrasi lainnya, memungkinkan kontrol yang tepat dan kinerja seumur hidup sensor. Model ML digunakan dalam pengembangan BioFET untuk meningkatkan sensitivitas, spesifisitas, dan fleksibilitas sensor. Sebelum menerapkan algoritma pemilihan model adaptif real-time yang akurat, dikombinasikan dengan ekstraksi fitur canggih, menggunakan teknik pra-pemrosesan yang ditingkatkan, metode ensemble, dan pembelajaran transfer aktual, untuk biosensing dan diagnostik sensor BioFET, sangat penting untuk memastikan keandalannya sebagai alat dalam aplikasi medis, lingkungan, dan bioteknologi.

Analisis Data Berdasarkan ML: Analisis berbasis PCA, analisis berbasis SVM, dan analisis berbasis jaringan saraf tiruan (ANN) adalah tiga pendekatan ML berbeda yang banyak digunakan di berbagai bidang, termasuk sensor BioFET.

1. **Analisis Berbasis PCA:** PCA adalah teknik statistik yang terutama digunakan untuk pengurangan dimensi dan ekstraksi fitur:
 - **Tujuan:** PCA mengidentifikasi pola atau komponen penting dalam data sensor yang kompleks dan berdimensi tinggi.
 - **Proses:** PCA mengubah variabel asli menjadi kumpulan komponen ortogonal yang lebih kecil (komponen utama) yang mempertahankan variabilitas yang ada dalam data.
 - **Aplikasi:** Dalam BioFET, PCA menyederhanakan respons sensor sambil mempertahankan informasi penting tentang interaksi biologis. PCA membantu memvisualisasikan pola data dan mengidentifikasi variabel berpengaruh/signifikan yang memengaruhi keluaran sensor.
2. **Analisis Berbasis SVM:** SVM adalah model yang kuat dan berpengaruh untuk klasifikasi dan regresi, yang merupakan jenis model pembelajaran terawasi:
 - **Tujuan:** Temuan menunjukkan bahwa SVM membantu mengklasifikasikan target biologis dari dataset sensor BioFET.
 - **Proses:** Mesin klasifikasi margin maksimum membatasi kelas terpisah dalam ruang berdimensi tinggi dengan membangun hyperplane optimal.
 - **Aplikasi:** Dalam BioFET, SVM dapat mengklasifikasikan respons sensor baik biomolekul maupun kondisi penyakit. Keuntungan menggunakan metode berbasis polinomial ketika berurusan dengan interaksi adalah bahwa metode ini tidak sensitif terhadap overfitting, baik dalam mengelola hubungan nonlinier, dan ideal ketika berurusan dengan interaksi biologis.
3. **Analisis Berbasis ANN:** ANN, termasuk DNN, adalah model matematika yang terinspirasi oleh jaringan saraf biologis; mereka unggul dalam mempelajari pola kompleks secara efisien.
 - **Tujuan:** ANN dapat mengenali pola dalam kumpulan data besar di mana polanya rumit.
 - **Proses:** Mereka terdiri dari beberapa tingkat neuron yang terhubung satu sama lain dan menghasilkan dimensi data hierarkis.



- **Aplikasi:** ANN dalam BioFET memproses informasi sensor untuk memprediksi interaksi dengan sistem biologis atau mengenali pola kompleks. CNN dalam ANN sangat cocok untuk menangani output sensor spasial, sementara jaringan saraf berulang (RNN) berkinerja baik dengan data yang lebih sekuensial, seperti respons deret waktu. Ini adalah kelas model yang membutuhkan daya komputasi yang besar tetapi dapat mencapai solusi yang sangat akurat dan adaptif untuk berbagai masalah.


PCA adalah solusi analitik yang berkaitan dengan pengurangan dimensi dan pemeriksaan utama dataset yang ada tanpa harus menggunakan data pelatihan atau pengujian. CNN dan RNN adalah jenis ANN yang digunakan untuk menangani pola yang rumit dan membutuhkan daya komputasi yang tinggi. Metode-metode ini bermanfaat dan dapat diintegrasikan ketika digunakan untuk menganalisis data dari BioFET.

PCA paling baik digunakan dalam implementasinya untuk menghilangkan noise dan mengembangkan fitur untuk dimasukkan ke dalam SVM atau ANN. SVM cenderung bekerja lebih baik dalam mengkategorikan dataset, sementara ANN membantu menyempurnakan atau menangani hubungan data yang kompleks.

Kesimpulannya, PCA, SVM, dan ANN memiliki kekuatan besar untuk analisis data array BioFET, dan setiap metode memiliki keunggulan tersendiri dalam hal pengurangan dimensi, klasifikasi, dan analisis pola. Metode-metode ini saling melengkapi dalam meningkatkan akurasi, kecepatan, dan analisis yang terkait dengan aplikasi BioFET di sektor biomedis dan bioteknologi.

Desain BioFET Berdasarkan ML: Baru-baru ini, desain sensor, khususnya BioFET, telah mendapat manfaat dari penggunaan algoritma ML dalam prosesnya. Aplikasi ini merevolusi pengembangan sensor dengan meningkatkan efisiensi operasional, meningkatkan material, mempersingkat waktu siklus desain, dan memilih reseptor yang sesuai.

1. **Meningkatkan Kinerja BioFET:** Pembelajaran mesin sangat penting dalam meningkatkan kinerja BioFET karena alasan berikut:
 - **Optimasi Parameter:** Pembelajaran mesin sangat penting untuk meningkatkan kinerja BioFET dengan mengoptimalkan berbagai parameter untuk sensitivitas, selektivitas, dan efisiensi keseluruhan yang lebih baik.
 - **Desain Material:** Aplikasi algoritma ML sangat penting dalam meningkatkan karakteristik material 2D yang digunakan secara tunggal dalam BioFET, termasuk dikalkogenida logam transisi semikonduktor (TMDC). ML terbukti meningkatkan keandalan dan kinerja sistem penginderaan dengan memprediksi parameter seperti celah pita dan memfasilitasi optimasi struktur cacat.
2. **Proses Desain yang Dipercepat:** Hal ini disebabkan oleh fitur-fitur utama ML—yaitu, kemampuan untuk mendukung desain dan pengembangan bioelektronik melalui peningkatan aplikasi untuk pembuatan prototipe cepat dan desain iteratif BioFET:
 - **Optimasi Heterostruktur:** Terdapat metode yang bermanfaat, seperti regresi proses Gaussian dan optimasi Bayesian, untuk memulai desain heterostruktur yang rumit dalam BioFET. Teknik-teknik ini mengantisipasi hal-hal seperti karakteristik listrik dan




optik dan membantu mengidentifikasi formula terbaik untuk material sensor guna meningkatkan fungsionalitas sensor.

- **Peningkatan FET Organik:** Algoritma pembelajaran lainnya, seperti random forest dan gradient boosting, secara signifikan meningkatkan aliran elektron dalam FET organik. Model ML menghubungkan sifat elektronik dengan kinerja sensor, sehingga meningkatkan peluang deteksi yang akurat dan bahkan tingkat sensitivitas.
3. **Pemilihan Reseptor Tingkat Lanjut:** Pembelajaran mesin mengubah pemilihan (lapisan bioreseptor) dan penyetelan reseptor untuk meningkatkan kemungkinan penginderaan BioFET.
 - **Rekayasa Reseptor:** Pendekatan berbasis ML memprediksi dan mengoptimalkan reseptor seperti enzim dan aptamer berdasarkan pola data. Metode ini melampaui pendekatan tradisional dengan mengidentifikasi reseptor baru dengan spesifisitas tinggi dan secara efisien mendeteksi molekul target.
 4. **Mengintegrasikan ML untuk Kemajuan BioFET:** Secara keseluruhan, penggabungan pembelajaran mesin ke dalam desain BioFET dianggap sebagai strategi revolusioner, memungkinkan pembuatan sensor dari elemen-elemen penting yang terdiri dari komponen yang berhubungan secara biologis dan elektronik dengan cara yang sangat akurat dan efisien dalam hal sensitivitas, spesifisitas, dan fleksibilitas. Metode pembelajaran mesin (ML) dalam mengoptimalkan parameter, konstruksi material, dan pembuatan prototipe cepat untuk pemilihan mikro-reseptor pada BioFET telah menempatkannya di pusat strategis diagnostik kesehatan, pemantauan lingkungan, pelacakan polusi, dan deteksi penyakit. Perkembangan ini dengan jelas menyoroti peran ML dalam pengembangan teknologi sensor dan kemampuan untuk memanfaatkannya guna memecahkan masalah yang menantang di berbagai bidang.

Sensitivitas BioFET

Doping secara signifikan memengaruhi sensitivitas BioFET, dengan persentase sensitivitas yang lebih tinggi diamati pada tingkat doping yang lebih rendah untuk tegangan ambang dan kemiringan subambang. Sensitivitas semakin meningkat dengan biomolekul konstanta dielektrik yang lebih tinggi, dan biomolekul bermuatan negatif menunjukkan peningkatan sensitivitas karena sifatnya (perilaku bermuatan negatif). Lokasi biomolekul di dalam rongga yang terisi sebagian, terutama di dekat sumber, secara signifikan memengaruhi sensitivitas tegangan ambang, mengalahkan efek faktor pengisian. Sensitivitas dievaluasi menggunakan berbagai metrik, termasuk tegangan ambang, kemiringan subambang, rasio I_{ON}/I_{OFF} , dan arus drain. Kebaruan karya ini terletak pada dua aspek utama: pertama, meningkatkan sensitivitas melalui pengoptimalan doping dan parameter lainnya, dan kedua, secara komprehensif mengeksplorasi rongga yang terisi sebagian pada faktor pengisian yang berbeda. Penggunaan berbagai biomolekul lebih lanjut memvalidasi temuan penelitian.

Pengoptimalan doping dan pengaturan bias sangat penting dalam fase pra-fabrikasi BioFET. Temuan ini menggarisbawahi kemandirian biosensor ini dalam mendeteksi biomolekul penting yang krusial untuk berbagai aplikasi biomedis dan klinis. Selain itu, biosensor ini menjanjikan deteksi cepat berbagai biomolekul penting medis lainnya, sehingga membantu



diagnosis dini penyakit akut dan kronis. Karya ini menunjukkan potensi BioFET sebagai sensor yang kuat dan sensitif, menyoroti penerapannya yang lebih luas dalam industri biomedis, yang memerlukan eksplorasi lebih lanjut.


BioFET yang diusulkan juga menawarkan alternatif yang hemat biaya dan aman untuk mendeteksi bahan kimia berbahaya dari jarak jauh, mengatasi potensi risiko kesehatan. Perangkat wearable berbasis BioFET berukuran nano sangat menjanjikan untuk mendeteksi gas atau radiasi berbahaya di lingkungan seperti ruang reaktif dan memantau kondisi kesehatan dalam pemeriksaan pribadi dan rutin untuk pasien atau individu lanjut usia. Selain itu, penelitian ini membahas peran penting dan meningkatnya kebutuhan untuk mengintegrasikan pembelajaran mesin ke dalam proses desain BioFET. Diskusi ini menyoroti bagaimana algoritma ML dapat meningkatkan sensitivitas, akurasi, dan kinerja keseluruhan BioFET dengan menganalisis interaksi biokimia yang kompleks dan mengoptimalkan parameter sensor.

7.4 KESIMPULAN

Bab ini menyelidiki analisis sensitivitas BioFET silindris, terutama berfokus pada pengaruh tingkat doping. Dengan mengeksplorasi berbagai biomolekul bermuatan dan netral, pembahasan ini meningkatkan realisme dan relevansi temuannya.

Hal ini menggarisbawahi bahwa sensitivitas tegangan ambang melampaui sensitivitas kemiringan subambang, dengan sensitivitas metrik pertama melebihi 400%, yang dapat dicapai melalui tingkat doping yang dioptimalkan secara cermat, menyoroti efikasi perangkat untuk aplikasi biosensing. Dalam kasus doping simetris untuk sumber dan drain, sensitivitas fraksional puncak untuk tegangan ambang dan kemiringan subambang masing-masing mencapai hingga 4,53 dan 0,44. Pembahasan ini menemukan bahwa sensitivitas persentase tinggi diperoleh pada tingkat doping rendah, dengan adanya pertukaran dengan konduktivitas. Penelitian ini juga mengkaji dampak faktor pengisian, mengungkapkan bahwa penempatan biomolekul yang tepat di dekat sumber secara signifikan memengaruhi sensitivitas lebih dari faktor pengisian itu sendiri.

Dengan mempertimbangkan V_t sebagai metrik penginderaan, sensitivitas persentase tinggi dicapai pada tingkat doping rendah, sementara sensitivitas perubahan relatif tinggi dicapai pada tingkat doping tinggi. Secara keseluruhan, pembahasan ini menekankan peran penting tingkat doping, kondisi bias, dan penempatan biomolekul dalam menentukan sensitivitas pada BioFET silindris. Pembahasan ini juga membahas peran pembelajaran mesin dalam meningkatkan kinerja dan desain BioFET melalui diskusi sinoptik.



BAB 8


SEMIKONDUKTOR EV & ENERGI TERBARUKAN

8.1 PENDAHULUAN

Bab ini membahas kemajuan dalam teknologi semikonduktor bertekanan dan penggunaannya pada kendaraan listrik dan hibrida (HEV/EV). Tinjauan tentang perangkat semikonduktor bertekanan otomotif terbaru disertakan, bersama dengan analisis teori dan kondisi terkini dari perangkat keras bertekanan yang dibutuhkan untuk EV dan HEV. Transistor bipolar gerbang terisolasi (IGBT) berbasis Si, transistor efek medan semikonduktor oksida logam (MOSFET) berbasis SiC, dioda freewheeling (FRD), dan dioda penghalang Schottky adalah beberapa inovasi terbaru di sektor semikonduktor otomotif. Desain tahan panas yang rendah, pengemasan tingkat tinggi, dan induktansi rendah dalam pengemasan kepadatan tinggi adalah tiga karakteristik yang mendefinisikan kemajuan dalam teknologi pengemasan semikonduktor otomotif.


Kita membahas semikonduktor terbaru dan berdaya tinggi untuk kendaraan listrik (EV) dan kendaraan hibrida (HEV), lingkungan yang menantang, dan perkembangan baru di bidang ini. Untuk perangkat Si, tantangan utamanya adalah kekuatan, ketebalan, kinerja, stabilitas, dan penggabungan; untuk perangkat SiC, tantangan utamanya adalah induktansi rendah dan suhu tinggi. Tren peningkatan jangka panjang dianalisis dari empat sudut pandang: penggabungan planar, inovasi dan material penggabungan baru, dan MOSFET SiC. Fitur-fitur seperti IGBT konduksi terbalik, saluran produsen tersembunyi, dan IGBT yang menakjubkan semuanya merupakan bagian dari IGBT berbasis Si generasi berikutnya untuk HEV/EV.

Pertumbuhan berkelanjutan membutuhkan pengembangan teknologi energi terbarukan yang terjangkau, tersedia secara luas, dan ramah lingkungan. Teknologi untuk konversi dan penyimpanan energi (foto)elektrokimia merupakan elemen penting. Oleh karena itu, untuk benar-benar mencapai penggunaan praktis teknologi energi (foto)elektrokimia, diperlukan desain, sintesis, dan modifikasi material katalitik nanostruktur yang realistis. Teknologi berkas ion adalah salah satu metode modifikasi fisik yang praktis dan serbaguna. Dengan mengendalikan energi, spesies, dan fluks ion yang diimplantasikan, dimungkinkan untuk memodifikasi permukaan, antarmuka, dan lapisan tipis dari berbagai jenis material katalitik. Pendekatan berkas ion memiliki beberapa manfaat, termasuk kompulsivitas doping elemen dan kontrolabilitas, presisi, dan reproduksibilitas yang tinggi. Kemajuan dan tren terkini dalam semikonduktor daya yang berorientasi HEV/EV digambarkan pada Gambar 8.1.



Gambar 8.1 Kemajuan dan tren terkini semikonduktor daya berorientasi HEV/EV: Sebuah tinjauan umum.

Data transaksi global dan ukuran pasar untuk konverter HEV/EV ditunjukkan pada Gambar 8.1. Empat peningkatan utama pada kerangka kerja digital daya kontemporer di mobil hibrida dan listrik adalah pengisi daya onboard, konverter DC untuk sumber daya daya bantu, konverter bantu DC di batang transmisi tegangan tinggi, dan komponen inverter untuk tekanan mesin. Menurut penelitian, industri ini akan tumbuh selama lima tahun ke depan dan melampaui sepuluh miliar dolar dengan konverter HEV/EV berdaya tinggi yang sejauh ini telah dibuat menggunakan berbagai jenis semikonduktor daya kontemporer, termasuk IGBT, transistor efek permukaan semikonduktor oksida logam (MOSFET), dan perangkat lubang pita lebar (WBG), termasuk perangkat silikon karbida (SiC) dan galium nitrida (GaN). Gambar 8.2 menunjukkan kemajuan dan tren terkini dalam HEV/EV.



Gambar 8.2 Perkembangan dan tren terkini pasar konverter HEV/EV: Gambaran umum.

Perjanjian dan skenario pasar perangkat tekanan yang diantisipasi untuk HEV/EV ditunjukkan pada Gambar 8.2. Dengan lebih dari 80% pasar modul listrik HEV/EV saat ini, telah



ditentukan bahwa IGBT adalah modul yang paling banyak digunakan dalam industri ini. Selain itu, modul SiC secara keseluruhan diprediksi hanya akan kalah tipis (sekitar 13%) selama periode lima tahun. Dalam kerangka elektronik daya, modul daya bisa menjadi elemen terlemah.


Menurut investigasi perusahaan yang menggunakan data dari lebih dari 80 perusahaan, aktivasi elemen suhu menyumbang 55% dari kegagalan sistem elektronik daya saat ini, dengan kegagalan modul daya menyumbang sekitar 42% di antaranya. Selain itu, untuk setiap derajat kenaikan suhu, tingkat kegagalan persimpangan meningkat sebesar 10°C. Mengenai semikonduktor daya dalam kerangka HEV/EV.

Tekanan kerja yang tidak dapat diprediksi dari era saat ini menciptakan persyaratan yang semakin ketat pada modul elektronik daya sistem kendaraan listrik karena kondisi cuaca dan jalan yang tidak dapat diprediksi. Pada titik ini, pengoperasian IGBT berbasis Si dan MOSFET penuh berbasis SiC pada suhu 175°C secara ekonomis layak. Suhu potensial tertinggi untuk penggunaan rekreasional lembaran SiC adalah 500°C, yang secara signifikan lebih tinggi daripada suhu maksimum untuk material Si modern. Namun, perangkat listrik SiC tampaknya lebih masuk akal untuk paket yang membutuhkan keandalan suhu tinggi dan iklim yang keras. Karena karakteristik suhu tinggi (>500°C), kecepatan elektron tinggi (321 cm/s), dan medan daya listrik tembus tinggi ($2,2 \times 10^6$ V/cm), perangkat berbasis SiC merupakan kandidat potensial untuk proyek konverter HEV/EV. Modul MOSFET berbasis SiC, sebagai perwakilan dalam perangkat WBG, secara bertahap mengubah nama domain utilitas konvensional yang berkaitan dengan MOSFET dan IGBT berbasis Si.

Meskipun demikian, dalam hal nilai material dan kemampuan penanganan yang canggih, semikonduktor SiC jelas tertinggal di belakang perangkat berbasis Si yang mutakhir. Namun, berakhirnya era SiC tidak dapat dijelaskan dengan baik oleh arsitektur kemasan lama yang diperkuat kawat. Berdasarkan gagasan ini, banyak teknologi baru telah muncul dalam upaya untuk mengatasi kesulitan ini dari perspektif penawaran kemasan modern dan mutakhir. Sebagai mesin penggerak penggunaan tenaga listrik, kendaraan listrik hibrida (HEV) dengan basis semikonduktor energi mengalami perubahan konstan dan berada pada titik balik dalam sejarahnya. Perubahan modul daya terbaru untuk pameran yang menarik perhatian publik merupakan konsekuensi dari terobosan dalam teknologi semikonduktor dan DB. Untuk menemukan peluang pengembangan baru bagi penelitian eksplorasi masa depan dan perusahaan HEV/EV, pembahasan ini meneliti perkembangan semikonduktor daya otomotif baru serta masalah dan metodologi dalam mengembangkan kerangka kerja elektronik yang lebih kuat di HEV/EV.

Meningkatnya kesadaran akan pentingnya energi surya mutakhir telah mendorong penguatan penelitian di bidang pengumpulan energi matahari saat ini. Berbeda dengan silikon (Si), instrumen listrik menjadi bagian utama dari inovasi perangkat keras daya. Kinerja inverter fotovoltaik (PV), bagian penting dari sistem perdagangan energi bertenaga surya, bergantung pada desain cerdas perangkat keras tekanan mutakhir dan digambarkan pada Gambar 8.3, dengan pasar substrat silikon karbida dalam satuan dan dolar untuk inverter PV. Untuk memaksimalkan daya yang diekstrak dari pengisi daya berbasis sinar matahari, tegangan di

dalam kerangka konversi listrik harus dikendalikan dengan pemilihan perangkat semikonduktor kontemporer yang sesuai, sehingga membatasi jumlah komponen digital listrik saat ini. Kebutuhan untuk mengurangi massa dan ukuran sakelar secara keseluruhan telah mendorong terciptanya daya ekstrem terbaru pada Zeng dan rekan-rekan. Gambar 8.3 merangkum inverter PV di pasar substrat SiC.




Gambar 8.3 Inverter fotovoltaik di pasar substrat SiC dalam satuan unit.

Relevansi inovasi semikonduktor silikon karbida baru ditunjukkan oleh fungsi SiC mutakhir di hunian yang disebutkan di atas. Beberapa kendala inovasi saat ini adalah biaya sistem yang lebih tinggi, kebutuhan akan prosedur pengemasan suhu ekstrem, dan penemuan yang lebih baru. Investigasi selanjutnya akan berkonsentrasi pada teknik untuk mengurangi biaya produksi, menyelesaikan masalah pengemasan, dan mengatasi hambatan untuk meningkatkan keandalan dan daya tarik visual perangkat SiC modern. Fokus utama bab ini adalah proses pembuatan perangkat yang andal berdasarkan semikonduktor SiC dalam konteks transformasi energi PV.

Lebih lanjut, eksperimen dengan berbagai struktur inverter PV menunjukkan bahwa penggunaan perangkat semikonduktor energi SiC baru dalam kerangka energi PV dapat membantu menghilangkan beberapa masalah yang mungkin saat ini menghasilkan hambatan material untuk silikon modern. Perkembangan teknologi surya di masa depan telah memungkinkan untuk menghasilkan lebih banyak listrik yang dapat digunakan. Energi yang diekstrak dari matahari dan diubah menjadi energi termal atau listrik dikenal sebagai energi surya. Ini adalah sumber daya luar biasa yang tersedia secara luas di seluruh dunia.

Pembangkit energi surya skala aplikasi yang terutama berbasis sinar matahari (pembangkit yang menghasilkan sejumlah besar energi baru yang dapat langsung digunakan oleh matriks transmisi daya), pembangkit tenaga pusat (pembangkit tenaga yang terletak di dekat sumber PV untuk memanfaatkan energi terbarukan modern), dan pembangkit listrik jaringan distribusi adalah beberapa cara berbeda untuk membangun pembangkit tenaga surya. Energi sebesar 1.020 MW (1.020 MJ/s) berasal dari matahari, sedangkan 173.106 kW, atau 1.360 W/m², listrik mencapai bumi. Karena berbagai alasan modern, termasuk penyerapan, pantulan, lingkungan sekitar, disipasi, dan sebagainya, energi surya tidak



terdistribusi secara optimal. Gambar 8.1 menggambarkan jumlah energi surya modern yang dihasilkan oleh satuan luas di Amerika Serikat.

Dengan hasil yang tidak memadai (15%–17%), dunia tidak dapat sepenuhnya memanfaatkan sel surya berbasis silikon komersial saat ini untuk mengubah energi matahari menjadi energi listrik. Biaya pembelian properti yang menghadap matahari mungkin akan meningkat jika sel surya berbasis silikon digantikan dengan fotovoltaiik terkonsentrasi (CPV) atau teknologi multi-persimpangan. Akibatnya, penelitian ini efektif dalam meningkatkan kekuatan matahari secara finansial, menemukan metode untuk meningkatkan fungsionalitas ponsel pintar, dan menurunkan biaya pertemuan ultramodern. Kemajuan teknologi telah menunjukkan bahwa kompetensi seluler berorientasi surya kemungkinan akan meningkat di masa depan.

Pembahasan ini menunjukkan bahwa, dengan mempertimbangkan sifat material silikon modern, sel surya berbasis sinar matahari silikon memiliki efektivitas maksimum teoritis tidak lebih dari 31%–40%. Tetapi hanya sekitar 15%–30% dari anggota dewan yang baru diangkat telah mencapai puncak keahlian dalam tanggung jawab asosiasi mereka yang sebenarnya. Sinar matahari di peternakan tersebut memberi daya pada 5.236 panel CS6P-230P bertenaga surya Kanada yang dipasang di tanah. Demonstrasi keterbatasan 1,2 MW pada kluster fotovoltaiik berbasis sinar matahari dapat dilihat pada situs web Cary, North Carolina, pada Gambar 8.2.

Dengan efisiensi modul sebesar 14,3%, setiap papan memiliki 60 sel silikon polikristalin berbasis sinar matahari yang terletak di Gurun Mojave California kontemporer; pembangkit listrik tenaga surya Ivanpah adalah fasilitas energi surya terkonsentrasi (CSP) dengan kapasitas maksimum 377 MW. Diproyeksikan bahwa pembangkit yang beroperasi akan memiliki efisiensi sebesar 28,72%. Meskipun terdapat banyak pembangkit listrik tenaga surya di Amerika Serikat, hanya sekitar 30% yang benar-benar berfungsi.

Gambar 8.3 (Sumber: EIA MER, Juli 2014) menunjukkan peningkatan progresif dalam penggunaan energi tenaga surya antara tahun 1984 dan 2013. Saran-saran yang kuat dan kreatif didukung dalam upaya untuk memfasilitasi konversi energi surya terbaru menjadi energi listrik secara drastis. Selama era energi surya, banyak sistem dikembangkan untuk secara tepat menangkap semua energi surya yang dapat diberikan matahari. Berikut beberapa contoh dari dunia saat ini:

- Inisiatif yang menggunakan nanokristal berbasis timbal dan selenium terbaru
- Pengurangan biaya produksi
- Untuk membangun struktur sel, digunakan ruang-ruang kecil yang disebut nanorod
- Mencampur unsur-unsur pewarna ultra modern untuk menyimpan sinar matahari dan unsur-unsur titanium dioksida modern untuk mengurangi biaya listrik

Selain itu, untuk mencapai efisiensi dan keandalan tinggi dalam konstruksi inverter tenaga surya mutakhir, penelitian sedang dilakukan tentang penggunaan material semikonduktor. Dengan mempertimbangkan semua ini, perangkat tekanan baru dari para pemimpin industri telah menyebabkan munculnya perangkat semikonduktor. Perangkat ini memberi kita efisiensi yang luar biasa, kontrol yang sempurna, dan kemampuan untuk



mentransfer energi di berbagai proyek yang tidak biasa. Meskipun silikon memiliki sejarah penggunaan yang jauh lebih lama dalam perangkat tekanan, teknologi silikon karbida saat ini kembali populer dalam paket berkekuatan tinggi karena sifat materialnya yang modern dan luar biasa. Saat ini, perangkat silikon karbida sangat penting untuk pengembangan konverter tenaga surya ultramodern.


Kerangka kerja untuk transformasi daya PV terutama mempertimbangkan biaya, desain, dan pengoperasian inverter mutakhir. Untuk memenuhi persyaratan khusus, inverter modern harus dibuat di bidang dengan keandalan tinggi, efisiensi tinggi, komunikasi yang lebih baik, biaya lebih rendah, dan fleksibilitas. Untuk sistem perumahan, inverter fotovoltaik biasanya memiliki rentang daya 1–10 kW, sedangkan untuk struktur komersial, seringkali antara 100 dan 300 kW. Rentang saat ini untuk kerangka aplikasi adalah 10–500 kW; ini akan meningkat secara bertahap menjadi 2 MW dan akhirnya 20 MW. Untuk mengurangi biaya inverter PV yang paling canggih, desain saat ini bertujuan untuk meningkatkan energi spesifik (W/kg) dan kepadatan daya kuantitas (W/m^3).

8.2 ASPEK FINANSIAL DAN KEBERLANJUTAN SISTEM PANEL SURYA

Ukuran pembangkit PV dan biaya transportasinya bervariasi sesuai dengan tahap pasar. Atap komersial, atap perumahan, dan sistem PV skala aplikasi yang dipasang di tanah (satu hub dan hub terpasang) mencakup tiga sektor utama pasar PV. Kerangka pemasangan di lantai skala utilitas berbeda dari sektor lain dalam hal panjangnya, strategi pemasangan, jalur pemasaran, dan struktur biaya. Nilai umur PV, kemiringan atap, biaya pengecatan, perizinan tambahan, biaya pengiriman, biaya jaringan penyimpanan, tarif administrasi, biaya penyambungan gardu induk dan kerangka kerja, biaya perizinan dan penunjukan, biaya komunitas manufaktur, dan dipertimbangkan dalam analisis keuangan dari tatanan PV.

Variabel biaya dan opsi untuk pengurangan biaya ditunjukkan untuk biaya kerangka fotovoltaik (PV) skala utilitas, komersial, dan pribadi di Amerika Serikat. Biaya transportasi untuk hub kontinu, satu pivot, dan kerangka skala pribadi, bisnis, dan perangkat lunak ditunjukkan satu per satu. Nilai inverter paling sedikit bervariasi berdasarkan jenis institusi sesuai dengan alokasi harga. Akibatnya, setiap peningkatan yang dilakukan pada pengaturan inverter akan memfasilitasi pengurangan biaya untuk beberapa perusahaan. Untuk inverter bertenaga surya, perangkat SiC memiliki pasar yang substansial. Sejak tahun 2006, pasar substrat SiC untuk inverter fotovoltaik telah tumbuh pesat. Telah diamati bahwa SiC banyak digunakan di berbagai bidang komersial, termasuk transportasi, TI dan elektronik, bangunan, dan lain-lain.

Pada tahun 2025, diperkirakan total pasar untuk perangkat listrik yang sering digunakan untuk mengoperasikan mesin akan tumbuh menjadi Rp2,4 miliar. Perangkat SiC telah menarik minat dari berbagai bidang industri, termasuk rumah, TI dan gadget, komunikasi dan jaringan, dan transportasi. TV, tablet, dan telepon menyumbang 87% minat konsumen pada gadget digital. Lokasi pasar yang sebelumnya ditemukan menunjukkan distribusi yang konsisten.



Dari sudut pandang ekologis, penilaian siklus hidup (LCA) dari kerangka PV menjamin hobi kerangka kerja yang canggih. Biasanya, ini adalah kemampuan dan sumber daya yang bermanfaat dari kerangka PV. Bersama dengan deskripsi ruang lingkup, beberapa faktor yang memengaruhi analisis inventaris, penerjemahan, perhatian, dan penilaian diperhitungkan. Manfaat kuantitatif LCA memungkinkan evaluasi beberapa perubahan. Tahapan siklus hidup yang sesuai disertakan dalam evaluasi siklus hidup kerangka PV. Dalam penghapusan bahan mentah, bahan tanaman termasuk besi dan seng untuk fabrikasi sistem pemasangan, logam tembaga untuk koneksi, dan silika untuk kaca.

Wafer yang tidak diketahui dihilangkan dari wafer setebal 2 mm, sel (persimpangan p-n yang dibentuk oleh penyebaran dopan dan sirkuit bertenaga listrik yang dibuat dengan lem metalisasi sinter), dan modul (sel yang terhubung secara nyata dan elektronik dan dicirikan dengan bantuan kaca dan plastik) adalah beberapa langkah yang terlibat dalam produksi perangkat PV, menyatukan peralatan yang dibutuhkan untuk pengembangan. Ketika menyangkut peningkatan dan pembuatan ulang, untuk memelihara peralatan, modul PV, koneksi, dan daya disinkronkan, dan sistem pendukung dipasang. Kerangka PV dilepas, dibongkar, dan kemudian dipasang kembali menggunakan komponen dan material yang sesuai. Penilaian masa pakai objek kerangka PV merupakan tugas yang menantang.

Namun, harga bersyarat modul PV di masa depan telah diprediksi menggunakan uraian masa pakai: 30 tahun pengembangan modul yang sangat baik; inverter memiliki masa pakai 15 tahun untuk pembangkit listrik kecil atau sistem PV pribadi dan masa pakai 30 tahun dengan periode perubahan 10% yang bekerja seperti jam untuk pembangkit listrik besar. Masa pakai perangkat yang dipasang di atap atau dinding berkisar antara 30 hingga 60 tahun. Salah satu kendala yang direkomendasikan untuk menilai siklus hidup adalah daya. Tingkat emisi CO₂ merupakan indikator yang berguna untuk menilai kelayakan perangkat fotovoltaik dalam kasus perubahan iklim yang tidak normal. Oleh karena itu, satu faktor tambahan untuk evaluasi pelacakan kinerja peralatan (EPT) adalah waktu pengembalian CO₂.

8.3 SISTEM KONVERSI DAN OPTIMASI DAYA FOTOVOLTAIK

Peralatan listrik dan elektronik yang dibutuhkan untuk menangkap energi dan mengubahnya menjadi pasokan energi yang tidak terputus memiliki hambatan yang signifikan karena sifat intermiten dari sumber energi bersih, khususnya tenaga surya dan angin. Iklim lokal dan waktu dalam sehari, yang keduanya dapat diprediksi secara akurat, memengaruhi jumlah energi surya yang tersedia. Namun, ketidakkonsistenan dalam pembangkitan daya disebabkan oleh variasi radiasi matahari karena kabut, debu, atau tutupan awan. Konstruksi sistem fotovoltaik harus mampu beradaptasi dengan perubahan radiasi matahari sambil tetap menghasilkan listrik yang bersih dan stabil.

Perangkat keras daya diperlukan agar kerangka pengumpul energi surya berfungsi dengan baik. Dalam pengaturan perumahan, kerangka PV standar dapat bernilai hingga 5 kW, dan dalam pengaturan komersial, hingga megawatt (MW). Desain untuk transfer energi PV yang bloknnya dikonfigurasi ulang ditunjukkan pada. Konverter DC dan inverter DC-AC adalah dua bagian elektronik daya utama dari sistem surya. Konverter DC memiliki arsitektur MPPT



(Maximum Power Point Tracking) terintegrasi dan dirancang untuk berfungsi sebagai konverter daya, juga dikenal sebagai konverter maju. Dengan menggunakan sistem serba listrik, MPPT memodifikasi titik operasi pengisi daya surya untuk menghasilkan daya maksimum.

Tegangan arus searah (DC) diubah menjadi arus bolak-balik (AC) oleh komponen inverter, yang kemudian dapat digunakan untuk mengontrol area sekitarnya atau dikirim kembali ke jaringan. Tergantung pada aplikasinya, hasil inverter mungkin berupa satu tahap untuk pembangkit listrik pribadi atau tiga tahap untuk pembangkit listrik yang terhubung ke suatu sistem. Energi fotovoltaik dibagi menjadi beberapa kelompok berdasarkan seberapa efektifnya mereka mengontrol daya. Inverter mikro adalah inverter mandiri yang ditempatkan di bawah sinar matahari langsung dan dipasang pada satu papan. Terdapat kerangka kerja MPPT terintegrasi. Inverter string mendeteksi tegangan arus searah (DC) dari serangkaian pengisi daya surya yang terhubung.

Arsitektur MPPT inverter string melihat kelompok pengisi daya surya yang terhubung sebagai satu pengisi daya surya tunggal, berbeda dengan mikro-inverter, yang terfokus pada papan individual. Secara sederhana, inverter fokus adalah inverter string yang lebih panjang yang digunakan dalam aplikasi komersial dalam skala besar. Cakupan pembahasan ini tidak mencakup pemeriksaan komprehensif setiap model inverter PV. Bagaimana kerangka energi tenaga surya ditampilkan bergantung pada arsitektur kerangka perangkat daya yang dibutuhkan pada berbagai tahap transformasi energi. Untuk memberikan keuntungan 10% pada pengisi daya surya di atas kapasitas yang diharapkan untuk menahan periode radiasi matahari di inverter PV, peringkat daya pengisi daya surya harus diatur oleh inverter, seperti yang dijelaskan dalam.

Penggunaan daya yang berlebihan dapat membebani peralatan dan mengakibatkan masalah dengan keandalan jangka panjang. Untuk mengoptimalkan keluaran daya pengisi daya surya, sangat penting untuk meminimalkan kehilangan daya di dalam kerangka transformasi energi. Ini melibatkan pengenalan semikonduktor secara akurat dan penggunaan komponen listrik yang lebih sedikit sensitif terhadap daya. Radiasi matahari rata-rata yang diterima di distrik adalah faktor utama yang menentukan keberlanjutan ekonomi pengumpulan energi surya. Lokasi pembangkit listrik yang menghadap matahari haruslah lokasi dengan radiasi matahari harian yang cukup. Dengan menempatkan kerangka inverter dekat dengan pengisi daya surya, koneksi jarak jauh dihindari dan kehilangan daya DC dikurangi. Namun, hal ini mengorbankan suhu operasi lingkungan yang tinggi dari kerangka inverter PV, yang menurunkan kinerja dan akhirnya mengecewakan perangkat.

Kerangka pendingin yang besar dan rumit diperlukan agar inverter PV dapat beroperasi pada suhu yang aman, yang meningkatkan biaya kerangka tersebut. Inverter PV harus dapat beroperasi pada suhu yang sangat panas (50°C atau lebih tinggi) tanpa kehilangan daya keluaran, seperti yang dijelaskan dalam. Faktor penting lainnya dalam mengendalikan kelembapan relatif ruangan adalah suhu di mana perangkat keras daya berfungsi. Kelembapan udara merupakan faktor penting ketika ada perbedaan suhu antara perangkat dan udara sekitarnya.



Situasi terburuknya adalah komponen sensitif kelembapan yang menua yang memberi daya pada semikonduktor dapat mulai mengumpulkan tetesan air. Untuk mengurangi dampak lengketnya udara dan menghindari disfungsi sistem akibat kelembapan, yang diungkapkan dalam, strategi berikut diterapkan: Suhu heat sink diatur dengan manajemen konsumsi udara pendingin dalam pemanasan interior. Komponen daya seringkali didinginkan oleh fluida atau oleh heat sink di luar casing dalam casing tertutup dengan sirkulasi udara internal yang terpisah.

Perangkat Keras Daya Kerangka Energi Fotovoltaik

Produktivitas sel atau papan bertenaga surya merupakan elemen utama yang membatasi efektivitas total sistem energi bertenaga surya. Namun, gagasan tersebut akan menjadi kurang layak secara finansial jika inovasi sel berorientasi matahari yang lebih canggih digunakan, seperti sel surya multijunction. Hal itu akan membutuhkan biaya yang signifikan. Untuk efektivitas maksimum dalam situasi ini, pembaruan perangkat daya adalah tindakan yang direkomendasikan. Modul elektronik daya dari desain transisi energi PV menggunakan konverter energi PV dengan desain MPPT untuk mengekstrak daya terbesar dari pengisi daya bertenaga surya; ini menyebabkan keluaran tegangan DC yang tidak seragam. Untuk menjaga keluaran DC tetap konstan dalam rentang yang tepat, konverter pengangkat menyesuaikan tegangan, seperti yang dijelaskan dalam.

Cara kerja konverter pengangkat dapat diringkas sebagai berikut: Ketika sakelar berada pada posisi ON, energi dari sumber DC (V_{in}) disimpan dalam induktor (L_1). Selama sakelar mati, dioda satu sisi maju (D_1) mentransfer energi yang tersimpan dalam induktor ke beban dan kapasitor (C_1). Tegangan yang dihasilkan lebih tinggi daripada tegangan masukan sebagai akibat dari interaksi antara tegangan sumber DC dan tegangan di seluruh induktor ketika sakelar MATI. Fungsi inverter DC ke AC dapat diringkas dengan melihat perubahan semikonduktor daya Q_1 hingga Q_6 , yang diaktifkan untuk menghasilkan sinyal sinusoidal yang dikoreksi. Urutan pertukaran yang pasti tidak akan dibahas dalam bab ini. Sebagian besar kerangka kerja PV dirancang untuk beroperasi pada titik batas tegangan DC 1.000 V untuk mengurangi konduksi, seperti yang dijelaskan dalam.

Meskipun demikian, ada upaya yang sedang dilakukan untuk menaikkan ambang batas menjadi 1.500 V. Tetapi elektronik yang lebih tahan terhadap tegangan DC harus digunakan untuk mengkompensasi nasib buruk dan mempertahankan konduktivitas yang rendah pada tingkat tegangan impedansi tinggi. Meskipun perangkat bertenaga silikon mampu menangani aplikasi tegangan tinggi dan arus tinggi, keterbatasannya mengakibatkan perlunya sistem termal dan listrik yang rumit.

8.4 MASA DEPAN ELEKTRONIKA DAYA DALAM GENGAMAN TEKNOLOGI SiC

Silikon karbida (SiC) adalah campuran komponen silikon dan karbon IV. Di bidang penelitian material semikonduktor, SiC secara luas dikenal memiliki lubang pita yang lebih besar daripada silikon. Silikon karbida adalah material pilihan untuk perangkat semikonduktor yang terkait dengan aplikasi elektronik suhu tinggi dan daya tinggi karena memiliki lebih banyak fitur dengan silikon daripada silikon saja.



Setelah dianalisis, SiC ditemukan memiliki konduktivitas termal tiga kali lipat dari silikon, beberapa lubang pita, dan berbagai kekuatan medan listrik fundamental, seperti yang dijelaskan dalam. Dalam material dengan celah pita yang lebih besar, elektron biasanya membutuhkan energi lebih dari 2 eV untuk berpindah dari titik tertinggi pita valensi ke pita konduksi. Fokus transporter alami yang lebih rendah menyebabkan penurunan tegangan blokir tinggi, aktivitas suhu tinggi, dan arus bocor perangkat. Material celah pita lebar dapat bekerja di lingkungan yang rawan radiasi dengan kemasan perangkat yang kurang kompleks karena secara inheren lebih tahan terhadap partikel berenergi tinggi.

Perangkat daya perlu mampu mempertahankan keadaan blokir ON yang rendah sambil dengan cepat menghentikan tegangan berlebih. Kapasitas tegangan blokir perangkat daya bergantung pada tingkat doping dalam material semikonduktor. Secara khusus, untuk perangkat unipolar seperti semikonduktor medan oksida logam, menurunkan konsentrasi doping meningkatkan tegangan tembus dengan mengorbankan blokir keadaan ON dan, akibatnya, penurunan tegangan keadaan ON (MOSFET). Tegangan blokir yang terbatas pada perangkat daya unipolar silikon disebabkan oleh pertukaran antara blokir dalam keadaan ON dan tegangan penghambat. IGBT, atau transistor bipolar pintu masuk yang dilindungi silikon, dibedakan oleh resistansi keadaan ON yang rendah dan tegangan impedansi yang tinggi.

Namun, karena karakter bipolarnya, terdapat batas yang kaku untuk pengurangan pertukaran. Medan listrik fundamental, yang merupakan tempat dimulainya disintegrasi geser deras, adalah pertimbangan penting. Medan listrik fundamental SiC yang kuat dapat memungkinkan perangkat dengan daya tegangan penghambat tinggi dan resistansi ON-state rendah, seperti yang dijelaskan dalam. Mencapai kepadatan daya tinggi untuk kerangka perangkat daya menjadi kebutuhan perencanaan penting untuk sejumlah proyek. Namun, ada biaya yang terkait dengan itu: sistem manajemen panas yang rumit menghasilkan modul individual yang lebih mahal dan lebih besar.

Kemampuan suatu material untuk menghantarkan panas diukur dengan konduktivitas termalnya. Karena konduktivitas termalnya yang kuat, SiC merupakan material semikonduktor unik yang meningkatkan peningkatan intensitas menjauh dari persimpangan semikonduktor. Salah satu komponen penting yang memengaruhi arus perangkat dan kapasitas frekuensi pertukaran adalah kecepatan transfer muatan transporter. SiC memiliki kecepatan transfer muatan elektron yang tinggi, dua kali lebih cepat daripada silikon karena arus perangkatnya yang lebih tinggi, seperti yang dijelaskan dalam.

Potensi intrinsik pada 3 V untuk persimpangan PN silikon karbida, dibandingkan dengan 0,7 V untuk silikon, adalah salah satu kelemahan utama semikonduktor celah pita lebar. Pengaturan perangkat tingkat tinggi diharapkan dapat mengurangi potensi intrinsik yang tinggi dari perangkat daya SiC. Sifat-sifat utama material SiC yang berkaitan dengan silikon dan galium nitrida dijelaskan. Terlepas dari manfaat utama silikon karbida, beberapa hambatan masih menghalangi penggunaan luas perangkat SiC. Perangkat semikonduktor daya SiC masih belum umum diakses untuk penggunaan komersial karena peringkat tegangan dan arusnya.

Perangkat ini lebih mahal daripada perangkat silikon sejenisnya. SiC adalah material tahan panas, tetapi untuk memanfaatkan suhu tipikal semikonduktor, ia harus dikemas dengan



benar dengan perangkat suhu tinggi. Tujuan penelitian dan pengembangan perangkat SiC di masa depan adalah untuk menciptakan semikonduktor daya tegangan tinggi yang layak secara komersial. Salah satu elemen yang dapat menghasilkan harga yang lebih murah adalah peningkatan produksi wafer SiC. Perangkat dengan peringkat tegangan dan arus tinggi dapat mengurangi biaya pengaturan dan menawarkan solusi yang layak secara finansial untuk sistem tenaga surya dan angin multi-megawatt, seperti yang dijelaskan dalam.

Perangkat Daya Menggunakan Silikon Karbida

Dioda Schottky Penghalang Persimpangan (JBS)

Penyearah daya digunakan dalam berbagai aplikasi, mulai dari penyesuaian tegangan saluran sederhana untuk penggantian AC hingga konverter dan inverter DC yang rumit. Sebelum kemajuan dalam komposisi dan arsitektur semikonduktor, aplikasi elektronik daya didominasi oleh dioda PIN dan Schottky silikon. Untuk tujuan praktis, mereka tetap menjadi perangkat yang disukai. Dioda PIN adalah jenis komponen bipolar yang dibedakan oleh kerugian konduksi rendah dan tegangan pemblokiran tinggi, seperti yang dijelaskan dalam.

Modifikasi konduktivitas secara intrinsik bermanfaat bagi perangkat bipolar karena mengurangi masalah yang sering dikaitkan dengan perangkat tegangan pemblokiran tinggi saat berada dalam keadaan ON. Namun, pemulihan maju dan balik membatasi aktivitas pertukaran frekuensi tinggi, dan tegangan hidup yang tinggi (sekitar 3 V untuk perangkat SiC) memperburuk ketidaknyamanan keadaan ON. Karena dioda Schottky pada dasarnya adalah perangkat pengangkut parsial, dioda ini dapat berfungsi pada tingkat pengulangan tinggi dengan kesalahan yang dapat diabaikan; namun, pertukaran antara kapasitas tegangan pemblokiran dan penurunan tegangan keadaan ON membatasi jumlah dioda Schottky tegangan tinggi yang dapat diproduksi. Lebih lanjut, peningkatan suhu yang signifikan pada arus bocor dioda Schottky membatasi aktivitas suhu tinggi. Dioda JBS menggabungkan kapasitas tegangan penghambatan tinggi dari dioda PIN dengan penurunan tegangan keadaan ON yang rendah dan kapasitas pertukaran pengulangan tinggi dari dioda Schottky. Arsitektur segmen silang skematik dioda JBS didasarkan pada desain dioda PIN dan Schottky.

Mode konduksi maju, yang sebagian besar ditentukan oleh tingkat hambatan Schottky semikonduktor logam, menunjukkan kemajuan arus unipolar di atas saluran antara situs P yang diimplantasi. Fenomena ini dijelaskan oleh keberadaan sisipan Schottky dan P_x yang saling bertautan. Bencana ON-state yang rendah dan pertukaran rekurensi yang tinggi berasal dari penurunan tegangan ON-state yang tidak mencukupi yang disebabkan oleh transporter minoritas yang diinjeksikan tidak mencukupi, yang mencegah sakelar bipolar ON. Persimpangan P_A N menjadi satu sisi berlawanan selama penghambatan sakelar karena daerah konsumsi menyebar di atas jari-jari P⁺ dan melindungi persimpangan Schottky dari medan listrik yang kuat, mengurangi arus bocor, seperti yang dijelaskan dalam.

Vendor perangkat SiC komersial termasuk teknologi Infineon, STMicroelectronics, dan ROHM Semiconductor. Produk CREE memiliki perkiraan tegangan penghambatan berlawanan tertinggi (1.700 V) dari semua dioda JBS SiC yang tersedia secara komersial. Dioda ganda dengan arsitektur katoda tipikal memungkinkan dioda 1.200 V tersedia dalam bundel TO-247–



3 dengan tiga kaki, meskipun dioda 1.700 V hanya tersedia sebagai dioda tunggal dalam bundel TO-247–2. Dioda tersebut tersedia dari STMicroelectronics dalam paket DPAK tegangan tinggi.

Semikonduktor Dampak Medan (MOSFET)

Transporter komponen semikonduktor oksida logam yang lebih besar, yang sering disebut sebagai MOSFET daya, seringkali cocok untuk rangkaian tegangan rendah dan daya tinggi. MOSFET diaktifkan dengan menerapkan tegangan predisposisi yang sesuai ke terminal pintunya, yang diisolasi dari semikonduktor oleh kontak oksida. Arus yang melewati saluran permukaan dikendalikan oleh tegangan kemiringan lapisan pembalikan ultra tipis. MOSFET ideal untuk digunakan sebagai sakelar dalam rangkaian daya tinggi karena impedansi informasi yang sangat tinggi dan antarmuka oksida pada terminal input pintu. Untuk aplikasi mode sakelar dengan ketebalan tinggi, MOSFET adalah pilihan yang disukai karena tingkat penggantian pengulangannya yang tinggi, yang memungkinkan ukuran komponen yang mampu menghasilkan energi dikurangi, seperti yang dijelaskan dalam.

Terlepas dari keunggulan yang telah ditunjukkan sebelumnya, MOSFET bertenaga silikon terbatas dalam kemampuannya untuk memblokir tegangan karena adanya pertukaran antara tegangan penghambat dan hambatan keadaan ON ($R_{DS(on)}$). MOSFET silikon dengan harga yang wajar memiliki tegangan tembus yang hampir sama dengan 1.000 V. Namun demikian, ada beberapa kerugian utama dari tegangan tembus yang lebih tinggi, termasuk resistansi keadaan ON yang sangat tinggi yang membatasi arus saluran atau kapasitansi informasi yang tinggi, yang meningkatkan kerugian daya dan kebutuhan driver input. MOSFET daya silikon karbida menggabungkan kapasitas tegangan impedansi tinggi dari material SiC dengan keunggulan standar MOSFET. Dalam aplikasi tegangan tinggi, di mana IGBT silikon sekarang mendominasi, MOSFET daya SiC membedakan dirinya dari semikonduktor lain karena kemampuannya untuk memblokir tegangan tinggi sambil mempertahankan hambatan keadaan ON yang rendah.

MOSFET daya SiC kelas bisnis diproduksi oleh STMicroelectronics, ROHM Semiconductors, dan CREE; MOSFET daya komersial biasanya memiliki peringkat tegangan penghambat 1.200 V. Di antara MOSFET daya SiC yang dipasarkan, CREE menghasilkan tegangan penghambat terbesar sekitar 1.700 V yang dapat ditangani oleh satu perangkat, seperti yang dijelaskan dalam. Sebuah dioda penghambat Schottky SiC antiparalel (SBD) dan MOSFET ROHM (SCH2080KE) yang dikemas bersama dihubungkan untuk mencegah kecelakaan daya selama konduksi balik. Kecuali perangkat STMicroelectronics, yang disimpan dalam paket HiP247TM mereka sendiri untuk kinerja maksimum sambil mematuhi standar industri, tersedia dalam paket TO-247–3.

Semikonduktor Dampak Medan Persimpangan (JFET)

Seperti yang telah disebutkan sebelumnya, arus yang melewati kawat tipis langsung di dekat kontak semikonduktor oksida, seperti yang dijelaskan dalam, mewakili sistem konduksi dalam MOSFET. Hal ini menunjukkan bahwa arsitektur perangkat harus memiliki antarmuka semikonduktor oksida yang ditingkatkan. Dalam kasus SiC, keadaan permukaan yang terhubung karbon menyebabkan fleksibilitas elektron yang terbatas pada permukaan saluran dan ketebalan besar keadaan titik koneksi dalam lapisan oksida yang dihasilkan secara termal.



Alasan utama untuk investigasi mendalam SiC JFET adalah keandalan kinerja dan stabilitas SiC MOSFET pada titik koneksi semikonduktor oksida. JFET adalah pengangkut bagian yang lebih besar dengan sifat yang sebanding dengan MOSFET daya dalam hal pertukaran dan konduksi.


Rute konduksi kontinu dan mekanisme kontrol adalah di mana MOSFET dan JFET paling berbeda. Pada MOSFET, pengalihan aliran arus dapat diakses di permukaan perangkat, tetapi pada JFET, pengalihan tersebut dapat diakses melalui berat perangkat. Penerapan tegangan yang telah ditentukan sebelumnya pada antarmuka oksida membatasi arus kanal pada MOSFET, sedangkan sambungan P-N satu sisi yang menentang hal ini, membatasi arus kanal pada JFET. JFET SiC lebih dikenal karena ketahanannya terhadap perubahan suhu dan kondisi iklim operasional lainnya, karena tidak bergantung pada antarmuka semikonduktor oksida. Fakta bahwa perangkat JFET beroperasi dalam mode leading dengan tegangan pra-kondisi masuk nol adalah salah satu kelemahan utamanya, yang berarti bahwa perangkat tersebut sering dalam keadaan ON. Dua geografi struktur transistor efek medan sambungan daya (JFET) secara terpisah adalah vertikal (VV-JFET) dan vertikal horizontal (LV-JFET). Pendekatan aliran arus kanal-ke-sumber menentukan perbedaan utama antara kedua sistem tersebut.

Struktur JFET bukanlah subjek analisis rinci dalam karya ini. Infineon Advances AG dan Joined Silicon Carbide Integrated (USCi) menciptakan JFET daya SiC gabungan kelas bisnis, yang dinilai untuk tegangan hambatan 1.200 V. Perangkat dikemas dalam wadah TO-247-3 dan memiliki suhu kerja maksimum 175°C dalam teknologi Infineon 1.200 V SiC JFET. terdiri dari unit daya yang terbuat dari silikon karbida. Sistem pengumpulan energi surya skala besar membutuhkan daya lebih besar daripada yang dapat disediakan oleh perangkat daya SiC diskrit.


Modul daya menawarkan beberapa perangkat semikonduktor daya yang ditumpuk pada satu substrat, pembatasan fisik, interaksi listrik dan termal, dan keamanan. Bagian-bagian penyusun modul dapat disatukan dengan berbagai cara, mulai dari modul dioda daya tinggi sederhana hingga modul MOSFET/IGBT setengah dan penuh yang kompleks. Modul ini mampu mengintegrasikan banyak sirkuit kontrol, termasuk deteksi dan penutupan suhu, keamanan tegangan rendah, kelebihan dan kelebihan arus, dan penggerak pintu, berkat fleksibilitas modul daya. Salah satu contoh perangkat tersebut adalah modul daya cerdas (IPM). Semua modul SiC dan setengah-setengah (kombinasi perangkat silikon dan silikon karbida) ditawarkan untuk modul daya SiC perusahaan. Pemasok besar memasok beberapa modul daya SiC yang dijual secara komersial, seperti yang dijelaskan dalam.

8.5 KESIMPULAN

Karena sel surya seringkali kurang produktif dibandingkan sumber daya ramah lingkungan lainnya seperti angin, maka sulit untuk memanfaatkan energi surya secara tepat. Ketika faktor-faktor ini diperhitungkan, biaya penggunaan CPV atau sel surya multi-persimpangan dengan efisiensi yang relatif baik membatasi pilihan. Saat beroperasi pada efisiensi maksimum, arsitektur inverter PV seharusnya mampu mengurangi spekulasi modal. Fitur material SiC yang tak terduga, dibandingkan dengan silikon, telah memungkinkan kemajuan perangkat seperti MOS-FET, JFET, dan dioda.



Penyajian, analisis, dan perbandingan inverter PV berbasis SiC dengan inverter berbasis silikon menunjukkan bahwa yang pertama lebih efisien dan meningkatkan persentase kerangka yang terbuat dari silikon, yang menurunkan biaya inverter. Dalam kerangka berbasis SiC, pengurangan biaya material, terutama pengurangan ukuran bagian yang menarik secara signifikan, mengimbangi biaya perangkat yang tinggi. Serupa dengan ini, perkembangan dan komersialisasi perangkat daya SiC yang pesat telah menghasilkan penurunan biaya yang berkelanjutan. Meskipun SiC masih merupakan teknologi yang relatif baru, stabilitas perangkat daya dikonfirmasi oleh sejumlah besar data uji.



BAB 9

ANALISIS ML PADA TFET VERTIKAL TIGA LAPIS

9.1 PENDAHULUAN

Saat ini, konsumsi daya rendah dan arus bocor minimal merupakan persyaratan penting untuk perangkat elektronik yang sangat efisien. Untuk mengakomodasi kebutuhan yang muncul dari industri ini, penskalaan MOSFET telah mencapai rentang nanometer, yang membatasi pengurangan lebih lanjut dari tegangan suplai dan peralihan cepatnya, yang pada gilirannya meningkatkan efek kanal pendek.

Oleh karena itu, telah menjadi suatu kebutuhan untuk mengeksplorasi beberapa perangkat alternatif yang lebih baik yang dapat mengatasi keterbatasan MOSFET. Transistor efek medan terowongan (TFET) dengan efisiensi yang ditingkatkan, peralihan cepat, kompatibilitas perangkat keras, dan pengurangan efek kanal pendek menjadikannya alternatif yang lebih unggul daripada MOSFET. TFET bekerja berdasarkan fenomena band-to-band-tunneling (BTBT) alih-alih emisi termionik.

Namun, TFET memiliki beberapa parameter utama yang masih membutuhkan banyak perbaikan seperti IOFF, ION, kemiringan sub-threshold yang lebih curam, dan I_{amb} . Untuk mengatasi keterbatasan ini, berbagai teknik telah diadopsi oleh para peneliti di masa lalu, seperti perangkat TFET dengan bandgap rendah; rekayasa material baru dengan silikon-germanium, germanium, dan material bandgap rendah lainnya yang termasuk dalam kelompok III–V; rekayasa kantong spacer; rekayasa gerbang; dan rekayasa fungsi kerja. Untuk menekan perilaku ambipolar TFET, berbagai jenis perangkat telah direkomendasikan seperti perangkat oksida terpendam heterodielektrik gerbang ganda, perangkat gate-all-around (GAA) material ganda, perangkat struktur GAA logam rangkap tiga, perangkat berbasis tumpang tindih gerbang pada drain, dan perangkat berbasis kantong sumber yang didoping berat.

Pada bab ini, kita akan meninjau berbagai transistor efek medan vertikal gerbang logam rangkap tiga (TMG V-TFET) secara detail dalam hal kinerja dibandingkan dengan variasi panjang gerbang logam dan fungsi kerjanya. Bagian 9.2 membahas geometri perangkat TMG V-TFET, Bagian 9.3 berisi hasil dan diskusi tentang kinerjanya, Bagian 9.4 membahas TFET menggunakan pembelajaran mesin (ML), dan Bagian 9.5 menyimpulkan bab ini.


9.2 GEOMETRI PERANGKAT TRIPLE METAL GATE (TMG) V-TFET

Tmg V-Tfet Berbasis Gaa

Pada perangkat TMG V-TFET berbasis GAA ini, terdapat tiga lapisan gerbang logam—MG1, MG2, dan MG3—yang dirancang sedemikian rupa sehingga semua gerbang logam memiliki fungsi kerja yang berbeda: WF1, WF2, dan WF3. Pada perangkat ini, sumber dan drain masing-masing terbuat dari Ge dan Si yang didoping tinggi, dan karakteristik kinerjanya diselidiki melalui simulasi berbasis desain berbantuan komputer teknologi (TCAD) dengan berbagai model. Perangkat ini sebenarnya dirancang untuk mengatasi keterbatasan kinerja

TFET dan juga ambipolaritas perangkat TFET yang ada. Perangkat TMG V-TFET berbasis GAA sangat berguna dalam berbagai aplikasi masa depan yang membutuhkan konsumsi daya rendah dan arus bocor yang dapat diabaikan.

Gambar 9.1 menunjukkan berbagai tampilan TMG V-TFET yang memiliki tiga lapisan gerbang logam—MG1, MG2, dan MG3—dengan fungsi kerja yang berbeda (WF1, WF2, dan WF3, masing-masing). Spesifikasi desain penting yang dipertimbangkan dalam TMG V-TFET ini adalah panjang lapisan gerbang logam (L_1 , L_2 , dan L_3), panjang kanal (L_C), diameter wilayah kanal (N_S), diameter total nanowire (D_T), dan fungsi kerja semua lapisan gerbang logam (WF1, WF2, dan WF3). Pada Gambar 9.1c, diagram pita energi TMG V-TFET diberikan sehubungan dengan fungsi kerja yang berbeda yang didefinisikan untuk masing-masing lapisan gerbang logam.




Gambar 9.1 (a) Menggambarkan struktur perangkat 3D TMG V-TFET, (b) tampilan 2D, dan (c) menunjukkan diagram pita energi.

Tabel 9.1 mewakili semua spesifikasi desain penting yang dipertimbangkan dalam TMG V-TFET berbasis GAA ini.

Tabel 9.1 Spesifikasi Desain Penting TMG V-TFET Berbasis GAA


Parameter Desain	Nilai
Konsentrasi doping pada saluran keluar (drain) tipe-p	10^{20}cm^{-3}
Konsentrasi doping pada sumber (source) tipe-n	10^{20}cm^{-3}
Diameter kawat nano (<i>nanowire</i>) (D_T)	14 nm
Diameter wilayah saluran (N_S)	7 nm
Ketebalan ekuivalen oksida (T_{ox})	0,6 nm
Panjang Gerbang Logam 1 (L_1)	7 nm
Panjang Gerbang Logam 2 (L_2)	14 nm
Panjang Gerbang Logam 3 (L_3)	7 nm
Panjang saluran (L_C)	28 nm
Fungsi kerja gerbang logam 1	4,2 eV
Fungsi kerja gerbang logam 2	4,5 eV
Fungsi kerja gerbang logam 3	4,2 eV

Gambar 9.2 menyajikan kurva karakteristik transfer ($I_{DS}-V_{GS}$) untuk TMG V-TFET. Hasil simulasi memberikan I_{ON} kira-kira sama dengan $10^{-5} \mu\text{A}/\mu\text{m}$, nilai sub-threshold swing (SS) sebesar 8 mV/dekade, dan kemiringan sub-threshold rata-rata sekitar 43,5 mV/dekade. Perilaku kinerja TMG V-TFET bergantung pada pembawa muatan di permukaan kanal. Oleh karena itu, kelilingnya, yang diberikan oleh $2' \times \pi \times r_{\text{channel}}$, dapat dengan mudah menormalkan nilai I_{DS} . S, semua fungsi kerja gerbang logam dan panjangnya masing-masing ($L1$, $L2$, dan $L3$) pada TM V-TFET dianalisis. Hasil simulasi menunjukkan bahwa laju BTBT sumber-kanal terkait dengan parameter gerbang logam 1 dan gerbang logam 2, yang pada gilirannya memengaruhi kinerja perangkat. Tetapi laju penerowongan ini pada antarmukanya memengaruhi arus ambipolar dan juga gerbang logam 3 (MG3), yang juga memengaruhi ambipolaritas seperti parameter MG1/MG2.



Gambar 9.2 Karakteristik transfer ($I_{DS} - V_{GS}$) dari TMG V-TFET.

Pada Gambar 9.3a, nilai WF2 dan WF3 dijaga konstan pada 4,5 eV. Seiring meningkatnya WF1, probabilitas penerowongan berkurang, dan pada $V_{DS} = V_{GS}$ pada 0,5 V, I_{ON} juga menurun secara signifikan, karena ada peningkatan tegangan untuk mekanisme BTBT. Pada Gambar 9.3b, nilai WF1 dan WF3 dijaga konstan pada 4,2 eV.




Gambar 9.3 Karakteristik transfer ($I_{DS} - V_{GS}$) dari TMG V-TFET untuk WF1, WF2, dan WF3 yang berbeda.

Seiring meningkatnya WF2, arus keadaan OFF (I_{OFF}) berkurang karena penghalang potensial antara gerbang logam (MG1 dan MG2). Pada TMG V-TFET, arus keadaan ON (I_{ON}) tetap sama ketika WF2 naik dari 4,1 menjadi 4,5 eV. Namun, pada WF2 = 4,6 eV atau lebih besar, hanya elektron terowongan berenergi tinggi di wilayah kanal yang diizinkan mengalir melalui mekanisme BTBT. Hal ini menyimpulkan bahwa I_{ON} dan SS keduanya bergantung pada laju BTBT wilayah sumber dan wilayah kanal. Pada Gambar 9.3c, ketika WF1 berada pada 4,2 eV dan WF3 pada 4,5 eV, jelas bahwa dampak WF3 minimal terhadap kinerja. Seperti yang diamati dari hasil simulasi, untuk laju BTBT dan arus drain yang lebih besar, WF1 harus kurang dari 4,2 eV dan untuk arus keadaan OFF yang lebih rendah, WF2 harus kurang dari 4,6 eV.

Tmg V-TFET Berbasis Nanowire

Pada TMG V-TFET berbasis nanowire (NW) ini, dampak dari berbagai parameter DC, seperti memvariasikan nilai fungsi kerja gerbang logam yang berbeda dan mengubah panjang gerbang logam, dianalisis untuk membandingkan karakteristik transfer utama dan ayunan sub-ambang menggunakan hasil simulasi. Perangkat ini menunjukkan peningkatan yang lebih baik pada I_{ON} -nya dengan penurunan bertahap pada arus I_{OFF} . Perangkat ini juga memiliki kemiringan sub-ambang yang lebih baik bahkan pada tegangan ambang rendah.

Gambar 9.4 menunjukkan struktur perangkat TMG V-TFET berbasis NW dengan tampilan yang berbeda untuk pemahaman yang lebih baik, yang hampir identik dengan struktur TFET berbasis GAA sebelumnya dengan variasi tertentu dalam parameter desainnya. Parameter dan spesifikasi yang digunakan dalam perancangannya ada di Tabel 9.2.




Gambar 9.4 Struktur perangkat V-TFET TMG berbasis NW: (a) Struktur perangkat 3D dan (b) Struktur perangkat 2D.

Parameter Desain	Nilai
Konsentrasi doping, saluran tipe-p	10^{15}cm^{-3}
Konsentrasi doping, drain tipe-n	$5 \times 10^{18} \text{cm}^{-3}$
Konsentrasi doping, sumber (<i>source</i>) tipe-p	10^{20}cm^{-3}
Radius <i>nanowire</i>	5 nm
Panjang saluran	20 nm
Panjang gerbang logam 1 (L1)	7 nm
Ketebalan oksida	1,5 nm
Panjang gerbang logam 2 (L2)	6 nm
Panjang gerbang logam 3 (L3)	4 nm
Fungsi kerja gerbang logam 1	4,1 eV
Fungsi kerja gerbang logam 2	4,5 eV
Fungsi kerja gerbang logam 3	4,4 eV

Tabel 9.2 Parameter Desain Penting V-TFET TMG Berbasis NW


Panjang daerah sumber dianggap 10 nm, sama dengan daerah drain. Lapisan oksida adalah SiO_2 . Jari-jari nanowire adalah 5 nm. Simulator Silvaco Atlas telah digunakan untuk memeriksa sifat-sifat perangkat.

Gambar 9.5 mewakili diagram pita energi perangkat. Dari Gambar 9.5, jelas bahwa variasi panjang logam tidak menunjukkan dampak apa pun di sisi kanal, tetapi terlihat di daerah tengahnya. Celah pita energi ini minimum pada susunan keempat dengan rasio 8:4:8, dan maksimum pada susunan pertama dengan rasio 5:10:5, seperti yang ditunjukkan pada Gambar 9.5. Dengan penurunan panjang gerbang logam kedua (M2), celah energi juga menunjukkan penurunan bertahap pada levelnya, yang meningkatkan penerowongan melintasi struktur.



Gambar 9.5 Diagram pita energi V-TFET TMG berbasis NW.

Gambar 9.6 menunjukkan karakteristik I_D/V_{GS} dari V-TFET TMG berbasis NW. Kita amati bahwa nilai I_{ON} -nya adalah $2,8 \times 10^{-6}$ A/ μ m, arus I adalah $4,3 \times 10^{-20}$ A/ μ m, nilai I_{ON}/I_{OFF} -nya adalah $6,5 \times 10^{-13}$, dan nilai SS-nya adalah 6,59 mV/dekade pada V_T sebesar 0,172 V.



Gambar 9.6 Karakteristik transfer V-TFET TMG berbasis NW.

Triple Metal Gate Stacked V-Tfet


Pada triple metal gate stacked III–V vertical TFET (TM-GS-V-TFET), terdapat dua struktur yang perlu diperiksa. Salah satunya adalah Perangkat A, yang menggunakan kantong sumber. Yang lainnya adalah Perangkat B, yang menggunakan pendekatan ekstensi sumber baru.

TFET berbasis kantong sumber diperkenalkan karena peningkatan I_{ON} , pengurangan I_{OFF} , dan SS yang lebih curam dibandingkan dengan struktur TFET dasar. Namun, prosedur fabrikasinya cukup kompleks dibandingkan dengan yang konvensional. TFET tipe ekstensi



sumber meningkatkan medan listrik, yang mengurangi lebar penghalang penerowongan di sisi sumbernya, yang pada gilirannya meningkatkan laju penerowongan dan meningkatkan fungsi perangkat. Pada TM-GS-V-TFET berbasis sumber, terdapat kantong sumber yang sangat terdoping di dekat wilayah sumber, yang memodulasi penghalang penerowongan. Karena pengaturan ini, probabilitas penerowongan meningkat, yang pada gilirannya meningkatkan kinerjanya. Pada TFET berbasis perluasan sumber, perluasan wilayah sumber melampaui tepi gerbang untuk meningkatkan medan listriknya, yang mengurangi lebar penghalang penerowongan di dekat wilayah sumber. Karena pengaturan ini, laju penerowongan meningkat, dan fungsi perangkat meningkat. TFET berbasis perluasan sumber memiliki proses fabrikasi yang sederhana dan kemampuan yang baik untuk meningkatkan arus ION, mengurangi arus IOFF, dan nilai SS yang lebih baik.


Pada Gambar 9.7, skema penampang TM-GS-V-TFET dengan kantong sumber GaSb (Perangkat A) dan TM-GS-V-TFET dengan perluasan sumber (Perangkat B) ditunjukkan. Ketebalan dan panjang dipilih masing-masing 65 dan 30 nm. Berbagai spesifikasi perangkat TM-GS-V-TFET ada di Tabel 9.3.



Gambar 9.7 Skema (a) perangkat A-TM-GS-V-TFET dengan kantong sumber dan (b) perangkat B-TM-GS-V-TFET dengan ekstensi sumber.

Tabel 9.3 Spesifikasi Perangkat TM-GS-V-TFET


Parameter Desain	Simbol	Nilai
Konsentrasi Doping Saluran (tipe-p)	$N_{channel}$	$10^{16} cm^{-3}$
Konsentrasi Doping Drain (tipe-p)	N_{drain}	$510^{18} cm^{-3}$
Konsentrasi Doping Sumber (tipe-p)	N_{source}	$10^{20} cm^{-3}$
Ketebalan Wilayah Saluran	T_{ch}	10 nm
Ketebalan Dielektrik	T_{di}	1 nm
Panjang Gerbang Logam 1	L_1	8 nm



Panjang Gerbang Logam 2	L_2	8 nm
Panjang Gerbang Logam 3	L_3	4 nm
Panjang Saluran	L_c	20 nm
Fungsi Kerja Gerbang Logam 1	Φ_{m1}	4,2 eV
Fungsi Kerja Gerbang Logam 2	Φ_{m2}	4,6 eV
Fungsi Kerja Gerbang Logam 3	Φ_{m3}	4,2 eV

Diagram pita energi (Gambar 9.8) mengilustrasikan interaksi antara tingkat energi kedua wilayah dan keberadaan penghalang energi di dalam kanal. Selain itu, analisis ini dapat meningkatkan kualitas subambang. Mengubah parameter material dan tegangan gerbang memungkinkan karakteristik penerowongan untuk disesuaikan.

Seperti yang ditunjukkan pada Gambar 9.8a, pada Perangkat A, kantong GaSb yang diperkenalkan di wilayah sumbernya menciptakan penghalang energi tambahan untuk elektron di persimpangan wilayah sumber dan kanal dan memfasilitasi pergerakan elektron berenergi lebih tinggi di dekat wilayah paling atas pita valensi. Tingkat energi ini membuat elektron bertransisi ke kanal pita konduksi material InP dengan lengkungan yang lebih miring. Oleh karena itu, hal ini meningkatkan efisiensi TM-GS-V-TFET.




Gambar 9.8 Diagram pita energi: (a) TM-GS-V-TFET dengan kantong sumber (Perangkat A) dan (b) TM-GS-V-TFET dengan ekstensi sumber (Perangkat B).



Seperti yang ditunjukkan pada Gambar 9.8b, Perangkat B memiliki ekstensi sumber GaSb, yang menyebabkan terciptanya penghalang energi tambahan bagi elektron antara sambungan sumber dan kanal. Hal ini menyebabkan pemisahan elektron berdasarkan tingkat energinya, dan elektron yang memiliki tingkat energi lebih tinggi, dekat dengan wilayah atas pita valensi, memiliki kemungkinan lebih besar untuk melewati penghalang ini. Karena fenomena ini, arus keadaan ON dari TFET ini meningkat. Hal ini juga menghasilkan IOFF yang lebih rendah. SS-nya berpotensi jauh lebih curam dengan ekstensi sumber GaSb ini, yang menyebabkan pengurangan konsumsi daya dan peningkatan efisiensi bersama dengan tegangan gerbang yang lebih rendah.

Gambar 9.9 menunjukkan karakteristik transfer dari kedua struktur perangkat. Arus keadaan ON (I_{ON}) dari TM-GS-V-TEFT dengan kantong sumber (Perangkat A) dan dengan ekstensi sumber (Perangkat B) masing-masing adalah $26,82 \mu\text{A}/\mu\text{m}$ dan $234,03 \mu\text{A}/\mu\text{m}$. Perangkat B menunjukkan kinerja yang lebih baik dibandingkan dengan Perangkat A, karena menggunakan teknik ekstensi sumber, yang menyebabkan jarak penerowongan berkurang, sehingga meningkatkan kecepatan elektron. Dengan menerapkan nilai VGS positif, level Fermi di wilayah sumber mulai bergerak ke bawah. Setelah tingkat energi sumber GaSb mencapai besaran yang cukup, elektron memasuki saluran InP melalui penerowongan mekanika kuantum. Hal ini juga mengakibatkan pembatasan nilai SS, yang meningkatkan nilai I_{ON} Perangkat B. Nilai I_{OFF} untuk Perangkat A adalah $5,6 \times 10^{-14} \text{ A}/\mu\text{m}$ dan untuk Perangkat B adalah $1,52 \times 10^{-14} \text{ A}/\mu\text{m}$. Kantong sumber pada Perangkat A membantu dalam pengurangan I. Nilai SS untuk Perangkat A adalah $24,56 \text{ mV/dekade}$ dan untuk Perangkat B adalah $28,58 \text{ mV/dekade}$.



Gambar 9.9 Karakteristik transfer TM-GS-V-TFET dengan kantong sumber (Perangkat A) dan dengan ekstensi sumber (Perangkat B).

9.3 AI PADA STRUKTUR TFET

Pada bab ini, berbagai struktur TFET vertikal gerbang logam rangkap tiga dengan berbagai teknik seperti gate-all-around, nanowire, penyisipan source pocket, dan perluasan source region ditinjau dan dibandingkan dalam hal struktur perangkatnya; diagram pita energi;



kinerja fungsional parameter DC seperti I_{ON} , I_{OFF} , SS minimum, dan disipasi daya; dan berbagai variasi parameter perangkat seperti semua fungsi gerbang logam dan semua panjang gerbang logam. Perbandingan semua karakteristik kinerja beserta spesifikasi desain yang dipertimbangkan dari semua model TMG V-TFET yang dibahas dalam tinjauan ini terdapat pada Tabel 9.4.

Tabel 9.4 Data Perbandingan Karakteristik DC dari Berbagai TMG V-TFET

Jenis Perangkat (Device)	No. Ref	Tahun	SS (mV/dec)	I_{ON} (A/ μm)	I_{OFF} (A/ μm)	Rasio I_{ON}/I_{OFF}
TMG V-TFET berbasis GAA	[26]	2016	8,00	10^{-5}	10^{-13}	10^8
TMG V-TFET berbasis NW	[27]	2021	6,59	$2,8 \times 10^{-6}$	$0,4 \times 10^{-19}$	$6,5 \times 10^{13}$
TMG V-TFET berbasis <i>Source Pocket</i>	[28]	2024	24,56	2×10^{-5}	10^{-16}	2×10^{11}
TMG V-TFET berbasis <i>Source Extension</i>	[28]	2024	28,58	$2,3 \times 10^{-4}$	10^{-14}	$2,3 \times 10^{10}$

9.4 MENGENAL PERAN AI DALAM MEMPERCEPAT INOVASI TRANSISTOR

TFET dikembangkan dengan cepat menggunakan ML, terutama karena menyederhanakan prosedur desain, pemodelan, dan optimasi. Pembelajaran mesin (ML) membantu mengatasi kesulitan inheren dalam desain TFET, yang sangat terkenal karena fungsinya yang hemat energi berkat kemiringan subambang di bawah 60 mV/dekade. Kebutuhan akan simulasi berbasis fisika yang memakan waktu berkurang secara signifikan dengan menggunakan model prediktif yang secara akurat mensimulasikan perilaku TFET, seperti karakteristik arus-tegangan dan tegangan ambang, berkat teknik seperti jaringan saraf tiruan dan model regresi yang canggih. Selain itu, teknik optimasi seperti pembelajaran penguatan dan algoritma genetik sangat penting untuk mengoptimalkan kinerja TFET dan meningkatkan kecepatan switching serta efisiensi daya.

Lebih jauh lagi, kontrol adaptif yang meningkatkan hasil produksi dan keandalan perangkat dimungkinkan berkat bantuan ML dalam mengantisipasi cacat fabrikasi dan perubahan proses. Di luar pemodelan, ML memproses kumpulan data besar untuk menemukan desain yang mendorong batas efisiensi daya, yang mempercepat penemuan material baru dan struktur TFET mutakhir. Untuk pengembangan TFET dan penggabungannya ke dalam elektronik generasi berikutnya yang berdaya sangat rendah, ML sangat penting, karena memfasilitasi optimasi daya, deteksi kesalahan, dan manajemen energi tingkat sistem pada tingkat sirkuit.

9.5 KESIMPULAN

Pada bab ini, berbagai TMG V-TFET dengan susunan berbeda dalam hal kinerja dan karakteristik arusnya ditinjau berdasarkan hasil simulasi TCAD menggunakan berbagai teknik, termasuk konfigurasi struktur gate-all-around, konfigurasi nanowire, dan penyisipan konfigurasi source pocket dan source extension. Dalam pendekatan GAA, dampak modulasi berbagai parameter desain seperti panjang kanal, lapisan gerbang logam, dan fungsi kerja




semua lapisan gerbang logam pada kinerja perangkat juga dipelajari. Parameter desain TMG adalah ION hingga $10 \text{ A}/\mu\text{m}$, SS sekitar 8 mV/dekade , nilai kemiringan subambang yang lebih curam sekitar $43,5 \text{ mV/dekade}$ dan rasio ION/IOFF sekitar 10.

Pada TMG V-TFET berbasis NW, dengan pengurangan lebih lanjut pada panjang kanal, terdapat peningkatan yang lebih baik pada ION-nya, dengan penurunan bertahap pada arus IOFF. Ia juga memiliki kemiringan subambang yang lebih baik bahkan pada tegangan ambang rendah. Parameter desain TMG adalah ION hingga $2,8 \times 10^{-6} \text{ A}/\mu\text{m}$, SS sekitar $6,59 \text{ mV/dekade}$, dan rasio I/I sekitar $6,5 \times 10^{13}$. Pada TM-GS-V-TFET, terdapat dua pendekatan.

Pada pendekatan kantong sumber, probabilitas penerowongan dapat ditingkatkan hingga tingkat yang baik bersamaan dengan kinerja perangkat lainnya seperti ION yang lebih baik sekitar $2 \times 10 \text{ A}/\mu\text{m}$, I sekitar $10\text{-}16 \text{ A}/\mu\text{m}$, dan SS sekitar $24,56 \text{ mV/dekade}$. Pada pendekatan perluasan sumber, hal ini mengubah medan listrik perangkat dengan mengurangi lebar penerowongan sisi sumber, yang meningkatkan laju penerowongan. Oleh karena itu, hal ini juga meningkatkan perilaku ION dan SS. Struktur TMG mencapai ION sekitar $2,3 \times 10 \text{ A}/\mu\text{m}$, IOFF sekitar $10 \text{ A}/\mu\text{m}$, dan SS sekitar $28,58 \text{ mV/dekade}$.

Struktur ini juga menunjukkan karakteristik medan listrik yang baik dan sangat berguna dalam aplikasi efisiensi tinggi dan daya rendah yang sedang berkembang.



BAB 10

ANALISIS ML PADA NWFET MACARONI GE/SI UNTUK ANALOG/RF

10.1 PENDAHULUAN

Transistor efek medan (FET) mewakili kemajuan signifikan dalam bidang elektronik, yang mencakup berbagai jenis yang disesuaikan untuk berbagai aplikasi. Eksplorasi berkelanjutan mereka telah mendorong para peneliti untuk mengembangkan banyak struktur dengan variasi yang berbeda. Di antara ini, transistor efek medan semikonduktor oksida logam (MOSFET) menonjol, dan arsitektur silindris FET telah menarik perhatian khusus karena banyak keuntungannya.

Germanium, unsur golongan 14, dianggap sebagai salah satu alternatif yang paling menjanjikan untuk silikon. Energi celah pita sempitnya memberikan beberapa keuntungan ketika digunakan sebagai bahan sumber dalam perangkat elektronik. Misalnya, germanium dapat mencapai mobilitas pembawa muatan yang lebih tinggi, yang bermanfaat untuk transistor yang lebih cepat dan efisien. Meskipun beberapa peneliti telah mengeksplorasi penggunaan germanium dalam struktur FET, investigasi menyeluruh dan komprehensif tentang potensi dan keterbatasannya masih kurang dalam literatur saat ini. Kesenjangan ini menyoroti perlunya pembahasan yang lebih detail untuk sepenuhnya memahami dan memanfaatkan manfaat germanium dalam teknologi semikonduktor. Inilah kebaruan utama dari karya ini, di mana penggunaan germanium sebagai bahan sumber telah dipelajari secara komprehensif.

Pemilihan material oksida merupakan pertimbangan penting lainnya dalam desain FET. Sementara SiO_2 adalah material oksida gerbang konvensional yang memiliki kesederhanaan fabrikasi dan kontrol medan pinggir yang lebih baik, HfO_2 , di sisi lain, meningkatkan batas kerusakan oksida gerbang tetapi dengan masalah medan pinggir. Oleh karena itu, HfO_2 telah digunakan dalam susunan horizontal dengan SiO_2 untuk mengatasi keterbatasan masing-masing, dan sepenuhnya memanfaatkan manfaat masing-masing.

Geometri tubular dari struktur saluran makaroni telah menjadi desain yang menjanjikan untuk FET (Fluorescence Emission Transistor) baik dalam aplikasi analog maupun biosensing. Dalam sirkuit analog, konfigurasi gerbang melingkar menawarkan kontrol elektrostatik yang unggul terhadap saluran, meningkatkan ayunan subambang dan mengurangi efek saluran pendek. Hal ini menghasilkan linearitas yang lebih baik dan penguatan yang lebih tinggi, menjadikan FET ini ideal untuk aplikasi berdaya rendah dan frekuensi tinggi. Untuk biosensing, desain silinder berongga memberikan rasio permukaan terhadap volume yang besar, meningkatkan area sensitif untuk interaksi biomolekul. Hal ini, dikombinasikan dengan kemampuan untuk memfungsikan permukaan dalam dan luar, memungkinkan deteksi biomarker yang sangat sensitif dan selektif. Selain itu, struktur tubular membantu aliran analit melalui saluran, berpotensi meningkatkan waktu respons dan memungkinkan penginderaan waktu nyata.



FET nanowire dapat dimanfaatkan untuk sejumlah aplikasi analog, termasuk aplikasi nirkabel, aplikasi daya tinggi dan frekuensi radio (RF), dan aplikasi penginderaan. Oleh karena itu, bab ini mengeksplorasi modulasi FET nanowire berbasis kanal macaroni dengan antarmuka Ge/Si dalam meningkatkan kinerja transistor untuk berbagai aplikasi analog. Berbagai penulis telah melaporkan banyak struktur serta teknik rekayasa untuk meningkatkan kinerja FET. Lebih lanjut, pemanfaatan FET nanowire untuk aplikasi biomedis telah dilaporkan dan didemonstrasikan oleh berbagai penulis dalam beberapa dekade terakhir.

Salah satu keuntungan utama yang ditawarkan FET nanowire ini adalah penginderaan tanpa label, yang ekonomis dan kuat dibandingkan dengan penginderaan berlabel dengan kompromi dalam sensitivitas. Dengan kemajuan ilmiah dan teknologi, FET telah menemukan aplikasi dalam perangkat medis penting, seperti defibrillator, sistem pengiriman obat, deteksi biomolekul tanpa label, dosimetri in vivo, pemantauan penyakit kardiovaskular, alat bantu dengar, dan perangkat implan lainnya. Jadi tujuan sekunder bab ini adalah untuk menunjukkan penerapan perangkat yang diusulkan untuk aplikasi biomedis.

Goel et al. telah melaporkan FET nanotube tanpa sambungan untuk aplikasi kebisingan rendah. Goyal et al. telah melaporkan FET berbasis plasma muatan untuk aplikasi frekuensi tinggi. FET yang sama juga dapat dimodifikasi secara struktural untuk digunakan sebagai biosensor. Biosensor adalah alat yang dibuat untuk identifikasi biomolekul secara cepat. Dalam bioelektronik, biosensor berbasis FET telah meningkat popularitasnya karena sensitivitas dan skalabilitasnya yang luar biasa. Biosensor ini berfungsi dengan memanfaatkan karakteristik molekuler, seperti konstanta dielektrik dan kepadatan muatan, dari zat biokimia untuk deteksi tanpa label, memungkinkan pengenalan langsung biomolekul tanpa perlu entitas bertanda. Mekanisme deteksi utama dalam biosensor berbasis FET berpusat pada modulasi dielektrik parameter penginderaan. Penulis seperti Sharma et al. telah melaporkan banyak varian struktural FET yang dapat digunakan dalam aplikasi biosensing. Oleh karena itu, struktur yang diusulkan dalam karya ini telah didemonstrasikan untuk aplikasi analog dan biosensing.

FET adalah komponen fundamental dalam sirkuit analog, yang banyak digunakan dalam penguat, osilator, dan sistem sinyal campuran. Metode optimasi tradisional untuk meningkatkan kinerja MOSFET bergantung pada penyetelan empiris dan proses desain iteratif, yang dapat memakan waktu dan suboptimal. Kemajuan terbaru dalam pembelajaran mesin (ML) menghadirkan peluang yang menjanjikan untuk secara signifikan meningkatkan kinerja transistor dalam aplikasi analog. ML telah terbukti menjadi aset berharga dalam meningkatkan kinerja transistor di berbagai aplikasi. Dalam ranah optimasi perangkat semikonduktor, algoritma ML dapat memprediksi dan memperbaiki karakteristik transistor, meminimalkan kebutuhan akan penyesuaian eksperimental yang ekstensif dan mahal. Dalam desain sirkuit analog dan RF, metode ML membantu mengoptimalkan ukuran dan bias FET untuk meningkatkan linearitas, mengurangi kebisingan, dan meningkatkan efisiensi daya. Untuk aplikasi digital, ML digunakan untuk menyempurnakan parameter transistor guna mengurangi konsumsi daya dan meningkatkan kecepatan peralihan dalam rangkaian logika.

Dalam bidang sensor dan biosensor, algoritma ML secara signifikan meningkatkan pemrosesan sinyal dan pengenalan pola, meningkatkan sensitivitas dan selektivitas platform



penginderaan berbasis FET. Biosensor tradisional seringkali mengalami masalah terkait sensitivitas, spesifisitas, dan adaptabilitas. Algoritma ML mengatasi tantangan ini secara efektif, menghasilkan peningkatan substansial dalam kinerja biosensor. Sebagai cabang kecerdasan buatan, ML memungkinkan komputer untuk belajar dari data dan membuat prediksi atau keputusan yang tepat.

Dalam biosensing, algoritma ML memproses data kompleks dari biosensor, meningkatkan akurasi dan mengotomatiskan pengambilan keputusan. Dengan memanfaatkan ML, biosensor menjadi alat yang lebih ampuh untuk mendeteksi dan memantau penyakit, polutan, dan racun. Integrasi ML dengan teknologi FET memajukan kinerja perangkat, berkontribusi pada sistem elektronik yang lebih efisien dan mumpuni di berbagai aplikasi. Karya ini mengeksplorasi potensi ML dalam merevolusi desain dan optimasi FET. Diskusi berpusat pada dua aspek utama: memanfaatkan ML untuk analisis data dan menerapkan ML dalam desain perangkat.


Terakhir, makalah ini secara singkat membahas tantangan dan peluang untuk memajukan desain perangkat berbasis ML. ML memungkinkan perangkat untuk beradaptasi dengan kondisi lingkungan yang bervariasi dan mengoptimalkan kinerja melalui pembelajaran berkelanjutan, yang sangat penting untuk aplikasi dunia nyata, di mana faktor lingkungan dapat berfluktuasi dari waktu ke waktu. Biosensor berbasis ML juga menjanjikan integrasi dengan platform internet of things, memfasilitasi pemantauan jarak jauh dan transmisi data waktu nyata untuk meningkatkan kegunaan dan aksesibilitas. Oleh karena itu, tujuan sekunder dari karya ini adalah untuk menyajikan tinjauan sinoptik tentang pemanfaatan ML dalam meningkatkan kinerja perangkat yang diusulkan untuk berbagai aplikasi analog.

FET nanowire berbasis saluran macaroni dengan antarmuka Ge/Si berbasis dielektrik ganda (MC-DD-Ge/Si-INW-FET) telah dipilih dalam penelitian ini karena kemampuannya untuk secara efektif mengontrol aliran pembawa muatan dan mempertahankan integritas elektrostatik, karena desain gerbang di sekitarnya. Bagian pertama secara singkat meninjau literatur, mengidentifikasi kesenjangan penelitian, dan menguraikan ruang lingkup pembahasan saat ini. Bagian kedua menguraikan karakteristik struktural perangkat, pengaturan simulator, dan metodologi yang digunakan. Pada bagian ketiga, temuan penting dan grafik terkait dibahas, dengan fokus pada dampak terhadap kinerja analog. Terakhir, bagian keempat merangkum temuan utama, membahas potensi aplikasi, dan menggarisbawahi aspek inovatif dari penelitian saat ini.

10.2 ARSITEKTUR DAN SPESIFIKASI SENSOR NANOWIRE

Dalam karya ini, perangkat yang diusulkan, MC-DD-Ge/Si-INW-FET, memiliki struktur simetris yang dikenal sebagai kanal makaroni dengan FET nanowire berbasis dielektrik ganda Ge/Si, yang representasi 3D dan 2D-nya ditunjukkan pada Gambar 10.1. Ini mencakup konfigurasi dielektrik dua lapis dengan SiO_2 di dekat sumber dan HfO_2 di dekat drain. Struktur FET DDM-GAA terdiri dari dua dielektrik dengan panjang yang sama $L_1 = L_2$ (15 nm) dan ketebalan t_g (2 nm). Ketebalan lapisan dielektrik adalah t_{ox} (2 nm). Gambar 10.1a dan 10.1b mengilustrasikan skema 3D dan 2D dari MC-DD-Ge/Si-INW-FET. Perangkat ini memiliki radius

total R (15 nm), menggunakan germanium (Ge) untuk sumber dan silikon (Si) untuk kanal dan drain. Perangkat tipe-n ini memiliki konsentrasi doping ND sebesar $10^{19}/\text{cm}^3$ di tepi sumber dan drain. Molibdenum (Mo) berfungsi sebagai material gerbang, dan fungsi kerja gerbang dapat disesuaikan dengan memanipulasi implantasi nitrogen.



Gambar 10.1 (a) Representasi 3D dari MC-DD-Ge/Si-INW-FET dan (b) Representasi 2D dari MC-DD-Ge/Si-INW-FET.

Struktur kanal makaroni menggabungkan pengisi vakum/udara di tengahnya dengan ketebalan t_f (5 nm). Untuk mengurangi efek kanal pendek pada nanowire, opsi yang tersedia meliputi pengurangan ketebalan oksida gerbang atau penyesuaian ketebalan silikon dengan mengurangi jari-jari luar ($r_2 = t_{si}$) atau meningkatkan jari-jari dalam ($r_1 = t_f$). Struktur "makaroni" menjadi populer karena kemampuannya untuk menunjukkan "efek badan makaroni," yang mengurangi fluktuasi tegangan ambang. Oleh karena itu, disarankan untuk memprioritaskan rasio r_2/r_1 yang lebih rendah sambil memastikan nilai r_1 dan r_2 yang moderat untuk memastikan jumlah muatan bergerak yang memadai di dalam kanal.

Pada struktur makaroni yang diusulkan (MC-DD-Ge/Si-INW-FET), rasio r_2/r_1 ditetapkan pada 5 nm, yang tergolong rendah dan diharapkan dapat membantu meminimalkan fluktuasi tegangan ambang. Tabel 10.1 memberikan ringkasan parameter yang membandingkan FET gate-all-around konvensional (CGAA FET) dan MC-DD-Ge/Si-INW-FET. Kelemahan konfigurasi ini terletak pada proses fabrikasinya yang mahal dan rumit. Tantangannya meliputi pencapaian



dan pemeliharaan suhu yang tepat untuk dielektrik vakum, kesulitan dalam konsentrasi doping yang akurat, dan biaya tinggi peralatan fabrikasi yang dibutuhkan.

Tabel 10.1 Spesifikasi Parameter

Parameter	CGAA FET	MC-DD-Ge/Si-INW-FET
Doping saluran	$1 \times 10^{16}/cm^3$	$1 \times 10^{16}/cm^3$
Ketebalan Silikon (t_{si})	10 nm	10 nm
Panjang saluran (L_{ch})	30 nm	30 nm
Ketebalan oksida (t_{ox})	2 nm	2 nm
Fungsi kerja (ϕ_m)	4,88 eV	4,6 eV
Ketebalan gerbang (t_g)	2 nm	2 nm
Ketebalan pengisi (t_f)	5 nm	5 nm

Simulasi numerik dilakukan menggunakan simulator perangkat ATLAS 3D, yang menggabungkan berbagai model seperti SRH, CONMOB, FLDMOB, injeksi elektron panas (HEI), arus gerbang nonlokal Concannon (N.CONCAN), penyempitan bandgap (BBT.STD), dan model difusi drift. Sintaks model penerowongan pita-ke-pita (BTBT) BBT.STD secara khusus digunakan untuk menganalisis dan mengimplementasikan perangkat FET DDM-GAA yang kami usulkan secara akurat, dengan fokus pada karakteristik kebocoran drain yang diinduksi gerbang (GIDL) yang mirip dengan perangkat yang telah dibuat. Deskripsi rinci model-model ini dapat ditemukan pada Tabel 10.2. Masalah transportasi pembawa diselesaikan secara numerik menggunakan teknik Newton-Gummel.

Tabel 10.2 Model yang Digunakan dalam Simulasi

Model	Detail (Fungsi)
BBT.STD	Digunakan untuk menilai dampak dari penerowongan pembawa muatan (<i>charge carrier tunneling</i>).
FLDMOB	Digunakan untuk mengatasi dampak kejenuhan kecepatan (<i>velocity saturation</i>).
CONMOB	Digunakan untuk mempertimbangkan pengaruh mobilitas dan konsentrasi MOSFET.
HEI	Digunakan untuk memasukkan pembawa muatan penerowongan yang berkontribusi pada arus gerbang (<i>gate current</i>).
SRH	Digunakan untuk mengintegrasikan dampak rekombinasi pembawa muatan (<i>carrier recombination</i>).
Drift Diffusion	Memasukkan statistik Boltzmann dalam perhitungan aliran muatan.
N. CONCAN	Digunakan untuk menganalisis arus substrat.


10.3 BEDAH PERFORMA PERANGKAT MAKARONI UNTUK SINYAL ANALOG

MC-DD-GE/SI-INW-FET Untuk Aplikasi Analog

Gambar 10.2 mengilustrasikan variasi energi pita di sepanjang panjang kanal untuk MC-DD-Ge/Si-INW-FET dan CGAA FET pada tegangan drain yang berbeda ($V_{DS} = 0,0$ V dan 1,0 V, masing-masing). Dalam kasus MC-DD-Ge/Si-INW-FET, terdapat penurunan energi pita yang




terlihat jelas menuju ujung drain seperti yang digambarkan pada grafik. Penurunan energi pita ini dipengaruhi oleh dua faktor: pengisi yang bertindak sebagai dielektrik dan dielektrik high-k yang terletak di sisi drain, yang secara signifikan mengurangi penerowongan elektron dari pita valensi ke pita konduksi. Akibatnya, BTBT, yang melibatkan transisi elektron dari pita valensi ke pita konduksi, diminimalkan. Pada Gambar 10.2b, perubahan tajam pada energi pita dapat terlihat di sisi sumber karena adanya germanium sebagai sumber dan silikon sebagai kanal dan drain.




Gambar 10.2 Diagram pita energi untuk (a) CGAA FET dan (b) MC-DD-Ge/Si-INW-FET.

Gambar 10.3 menampilkan variasi arus GIDL (IDS) dengan tegangan gerbang untuk beberapa perangkat. GIDL, fenomena kebocoran subambang yang disebabkan oleh BTBT, terjadi ketika tegangan gerbang (VGS) menurun dan drain menjadi lebih bias positif. Elektron yang dipancarkan karena fenomena ini bergerak menuju ujung drain, membentuk arus GIDL. Gambar 10.3 secara jelas menunjukkan bahwa IDS menurun dari 10–9A menjadi 10–10A pada perangkat MC-DD-Ge/Si-INW-FET. Pengurangan arus kebocoran keadaan OFF ini terutama disebabkan oleh keberadaan pembawa panas di pengisi di sisi drain dan dielektrik high-k yang terletak di sana.




Gambar 10.3 Kebocoran keadaan mati di sepanjang kanal untuk berbagai perangkat.

Gambar 10.4 menampilkan karakteristik arus drain (I_{DS}) untuk berbagai perangkat pada tegangan gerbang (V_{GS}) yang berbeda. Grafik tersebut mengilustrasikan bahwa pada $V_{GS} = 1,0$ V, MC-DD-Ge/Si-INW-FET menunjukkan karakteristik I_{DS} yang superior dalam keadaan ON dibandingkan dengan desain lainnya. Peningkatan arus drain ini disebabkan oleh gerbang logam ganda dan dielektrik gerbang vakum yang digunakan pada perangkat MC-DD-Ge/Si-INW-FET.




Gambar 10.4 Variasi arus drain terhadap tegangan gerbang.

Gambar 10.5 mengilustrasikan rasio I_{ON}/I_{OFF} di berbagai tata letak perangkat. Rasio I_{ON}/I_{OFF} adalah metrik kinerja yang sangat penting, karena menentukan efisiensi perangkat untuk aplikasi digital. Untuk mencapai kinerja digital yang optimal, rasio arus dalam keadaan ON terhadap arus dalam keadaan OFF harus dimaksimalkan. Dapat diamati dari Gambar 10.5 bahwa MC-DD-Ge/Si-INW-FET menunjukkan rasio I_{ON}/I_{OFF} 28 kali lebih tinggi daripada CGAA FET. Rasio yang lebih tinggi pada MC-DD-Ge/Si-INW-FET ini disebabkan oleh arus keadaan ON yang superior dan arus keadaan OFF yang lebih rendah. Oleh karena itu, MC-DD-Ge/Si-INW-FET sangat cocok untuk aplikasi digital.



Gambar 10.5 Variasi I_{ON}/I_{OFF} pada berbagai perangkat.


Gambar 10.6 menyajikan kemiringan subambang (SS) untuk beberapa perangkat. Kemiringan subambang mencirikan kemampuan perangkat untuk bertransisi antara keadaan OFF dan ON. Idealnya, kemiringan ini harus 60 mV/dekade untuk kinerja optimal. Menurut Gambar 10.6, FET CGAA menunjukkan kemiringan subambang sebesar 77 mV/dekade, yang melebihi nilai ideal. Di sisi lain, FET MC-DD-Ge/Si-INW menunjukkan kemiringan subambang sebesar 65 mV/dekade, sedikit di atas nilai optimal tetapi lebih rendah dibandingkan dengan FET CGAA. Kehadiran dielektrik high-k di ujung drain dan pengisi pada FET MC-DD-Ge/Si-INW secara signifikan mengurangi efek ionisasi tumbukan, sehingga meningkatkan transisi dari keadaan OFF ke keadaan ON dan akibatnya menurunkan kemiringan subambang.



Gambar 10.6 Variasi kemiringan subambang pada berbagai perangkat.

Gambar 10.7 mengilustrasikan variasi arus drain yang bergantung pada tegangan gerbang, yang disebut "transkonduktansi." Ekspresi matematis untuk transkonduktansi didefinisikan oleh Persamaan 10.1. Hasilnya dibandingkan antara CGAA FET dan MC-DD-Ge/Si-INW-FET pada Gambar 10.7. Transkonduktansi sangat penting tidak hanya untuk aplikasi


analog/RF tetapi juga untuk menentukan titik bias optimal di mana frekuensi cutoff setiap perangkat diminimalkan. Peningkatan kemampuan derivasi arus dan arus drain yang lebih tinggi berkontribusi pada nilai transkonduktansi yang lebih tinggi pada MC-DD-Ge/Si-INW-FET.




Gambar 10.7 Variasi transkonduktansi pada berbagai perangkat.

$$g_m = \left. \frac{\partial I_{DS}}{\partial V_{GS}} \right|_{V_{DS}} \quad (10.1)$$

Gambar 10.8 menampilkan karakteristik keluaran (I_{DS} vs. V_{DS}) dari MC-DD-Ge/Si-INW-FET yang diukur pada $V_{GS} = 1,0$ V untuk semua perangkat. Dalam penelitian ini, karakteristik keluaran MC-DD-Ge/Si-INW-FET lebih unggul dibandingkan dengan topologi perangkat lainnya. Peningkatan ini disebabkan oleh keberadaan dielektrik high-k dan pengisi vakum di tengah perangkat, yang mengurangi efek elektron panas. Gambar 10.9 mengilustrasikan variasi konduktansi keluaran (g_d) dengan V_{DS} untuk CGAA FET dan MC-DD-Ge/Si-INW-FET pada $V_{GS} = 1,0$ V. Konduktansi keluaran (g_d) mewakili perubahan I_{DS} terhadap perubahan V_{DS} . Gambar tersebut menunjukkan bahwa MC-DD-Ge/Si-INW-FET menunjukkan profil yang lebih selaras dengan karakteristik optimal. MC-DD-Ge/Si-INW-FET memiliki konduktansi keluaran dan arus drain yang lebih tinggi karena adanya pengisi dan dielektrik high-k. Hal ini dapat dijelaskan secara matematis dalam Persamaan 10.2.



Gambar 10.8 Variasi kemiringan subambang pada berbagai perangkat.



Gambar 10.9 Variasi konduktansi keluaran pada berbagai perangkat.

$$g_m = \left. \frac{\partial I_{DS}}{\partial V_{DS}} \right|_{V_{DS}} \quad (10.2)$$

Pembelajaran Mesin Dalam Meningkatkan Kinerja Analog

FET merupakan elemen penting dalam rangkaian analog, yang menjalankan fungsi penting dalam penguat dan sistem sinyal campuran. Pendekatan konvensional untuk mengoptimalkan kinerja FET biasanya bergantung pada penyesuaian empiris dan metode desain iteratif, yang dapat memakan waktu dan suboptimal. Pengenalan teknik ML menawarkan peluang yang menjanjikan untuk secara substansial meningkatkan kinerja dan efisiensi FET dalam aplikasi analog. Bagian ini mengeksplorasi bagaimana ML dapat



meningkatkan kinerja FET dengan memajukan pemodelan perangkat, mengoptimalkan parameter dengan presisi, mendeteksi kesalahan secara efektif, dan meningkatkan keandalan.

Pembelajaran Mesin dalam Pemodelan Perangkat: ML sangat meningkatkan pemodelan perangkat dengan menawarkan prediksi yang tepat tentang perilaku MOSFET, yang sangat penting untuk mendesain rangkaian analog berkinerja tinggi. Tidak seperti model tradisional seperti SPICE, yang menggunakan persamaan yang disederhanakan, ML memanfaatkan kumpulan data yang luas untuk menangkap perilaku perangkat secara detail di berbagai kondisi. Proses dimulai dengan pengumpulan dan pra-pemrosesan data eksperimental dan simulasi, termasuk parameter seperti tegangan ambang, transkonduktansi, dan arus drain. Algoritma pembelajaran terawasi, seperti mesin vektor pendukung (SVM), pohon keputusan, dan jaringan saraf, dipilih berdasarkan kompleksitas data. Model-model ini dilatih dan divalidasi menggunakan teknik seperti validasi silang untuk memastikan efektivitasnya pada data baru, dengan kinerja dinilai menggunakan metrik seperti kesalahan kuadrat rata-rata (MSE) dan R-kuadrat (R^2). Pada akhirnya, model berbasis ML diintegrasikan ke dalam alat otomatisasi desain elektronik (EDA), memungkinkan para insinyur untuk secara akurat memprediksi metrik kinerja utama dan mencapai kontrol yang tepat atas karakteristik MOSFET.

Optimasi Parameter: Mencapai tujuan kinerja spesifik dalam desain MOSFET melalui optimasi parameter merupakan tantangan yang signifikan. Pendekatan konvensional seringkali bergantung pada simulasi ekstensif dan metode heuristik, yang dapat tidak efisien dan menghasilkan hasil yang kurang ideal. Teknik ML menawarkan alat yang ampuh untuk mengeksplorasi ruang parameter secara lebih efektif. Proses dimulai dengan menetapkan tujuan dan batasan, seperti penguatan, bandwidth, angka derau, dan konsumsi daya, sambil juga memperhitungkan keterbatasan manufaktur dan keandalan perangkat.

Algoritma optimasi seperti algoritma genetika (GA), optimasi swarm partikel (PSO), dan optimasi Bayesian secara otomatis mencari kombinasi parameter desain terbaik, termasuk panjang kanal, lebar, konsentrasi doping, dan ketebalan oksida. Algoritma ini secara iteratif menilai solusi potensial terhadap tujuan dan batasan yang ditentukan, menggunakan model ML untuk memprediksi kinerja dan mengurangi ketergantungan pada simulasi yang memakan waktu. Aplikasi praktis, seperti mendesain penguat derau rendah (LNA), telah menunjukkan bahwa optimasi berbasis ML dapat mencapai peningkatan kinerja, menawarkan karakteristik derau dan linearitas yang lebih baik dibandingkan dengan metode tradisional.

Deteksi Kesalahan dan Peningkatan Keandalan: Keandalan adalah faktor penting dalam kinerja MOSFET, khususnya dalam aplikasi analog di mana kegagalan perangkat dapat memiliki implikasi serius. ML dapat secara signifikan meningkatkan keandalan MOSFET dengan mendeteksi potensi kesalahan dan memprediksi bagaimana perangkat akan mengalami degradasi dari waktu ke waktu. Metode deteksi anomali, seperti autoencoder dan SVM satu kelas, dilatih pada data dari perangkat yang berfungsi untuk menetapkan apa yang merupakan operasi normal dan mengidentifikasi penyimpangan yang dapat menandakan kesalahan yang akan datang. Model pemeliharaan prediktif, yang menggunakan pendekatan seperti jaringan saraf berulang (RNN) dan jaringan memori jangka pendek panjang (LSTM), memperkirakan sisa




umur pakai (RUL) MOSFET berdasarkan penggunaan masa lalu dan kondisi stres. Model ML ini diintegrasikan ke dalam sistem pemantauan yang terus mengamati kinerja MOSFET secara real-time. Deteksi dini anomali melalui model ini memungkinkan pemeliharaan proaktif, sehingga meminimalkan risiko kegagalan serius. Pembahasan kasus, termasuk pada penguat daya (PA), telah menunjukkan bahwa deteksi kesalahan berbasis ML secara efektif melacak masalah kinerja yang disebabkan oleh stres termal dan penuaan, menghasilkan pemeliharaan tepat waktu dan umur perangkat yang lebih panjang.

Pembahasan Kasus dan Implementasi Praktis: Banyak pembahasan kasus menyoroti bagaimana ML dapat secara signifikan meningkatkan kinerja MOSFET dalam aplikasi analog. Sebagai contoh, jaringan saraf telah digunakan untuk memodelkan dan menyempurnakan LNA, yang menghasilkan peningkatan yang signifikan dalam kinerja noise dan linearitas. Demikian pula, metode optimasi berbasis ML telah memungkinkan terciptanya PA efisiensi tinggi dengan peningkatan gain dan konsumsi daya yang lebih rendah. ML juga telah diterapkan untuk meningkatkan penguat operasional, menghasilkan bandwidth, tegangan offset, dan efisiensi daya yang lebih baik. Dalam sistem sinyal campuran, teknik ML telah digunakan untuk secara efektif mengelola trade-off antara metrik kinerja analog dan digital, menghasilkan sistem yang lebih efisien dan andal.

ML telah secara signifikan memajukan optimasi dan keandalan MOSFET dalam aplikasi analog. Tidak seperti metode tradisional yang bergantung pada simulasi ekstensif dan pendekatan heuristik, ML menggunakan kumpulan data besar untuk membangun model yang sangat akurat dan prediktif.

Selain pemodelan, ML sangat penting untuk mengoptimalkan parameter perangkat dan meningkatkan keandalan. Algoritma optimasi seperti GA, PSO, dan optimasi Bayesian mengeksplorasi ruang parameter secara efisien, mengurangi kebutuhan akan simulasi yang panjang. ML juga memainkan peran kunci dalam peningkatan keandalan melalui algoritma deteksi anomali seperti autoencoder dan SVM satu kelas, yang mengidentifikasi penyimpangan dari kondisi operasi normal. Model pemeliharaan prediktif menggunakan RNN dan jaringan LSTM memperkirakan RUL MOSFET, memungkinkan pemeliharaan tepat waktu dan meminimalkan risiko kegagalan. Pembahasan kasus yang melibatkan LNA dan PA menunjukkan bahwa optimasi berbasis ML meningkatkan kinerja, meningkatkan pengurangan kebisingan, linearitas, efisiensi, dan masa pakai perangkat secara keseluruhan.

Demikian pula, algoritma ML telah mengoptimalkan penguat operasional (Op-Amp) untuk mencapai bandwidth, tegangan offset, dan efisiensi daya yang lebih baik. Dalam sistem sinyal campuran, ML membantu menyeimbangkan metrik kinerja analog dan digital, menghasilkan sistem yang lebih efisien dan andal. Contoh-contoh ini menunjukkan potensi transformatif ML dalam desain MOSFET, memberikan solusi yang kuat untuk tantangan kompleks dan mendorong kemajuan dalam kinerja sirkuit analog. Seiring kemajuan bidang ini, integrasi ML ke dalam proses desain MOSFET diperkirakan akan meningkat, yang mengarah pada inovasi dan peningkatan lebih lanjut dalam elektronika analog.




10.3.3 MC-DD-Ge/Si-INW-FET UNTUK APLIKASI BIOSENSING

FET merupakan pilihan tepat untuk mendesain biosensor dalam aplikasi biosensing yang cepat dan berbasis sensitivitas tinggi. MC-DD-Ge/Si-INW-FET diwujudkan sebagai biosensor dengan mengikis lapisan dielektrik dari sisi sumber dan drain. Rongga dua sisi yang dibuat dimanfaatkan untuk imobilisasi biomolekul. Gambar 10.10 menggambarkan tampilan 2D dari struktur perangkat biosensor berbasis MC-DD-Ge/Si-INW-FET (menunjukkan rongga). Nanokavitas dua sisi telah dibentuk dengan mengikis lapisan SiO₂ pada sisi sumber dan lapisan dielektrik HfO₂ pada sisi drain. Ketebalan nanokavitas (t_{cavity}) adalah 6 nm, dan panjang nanokavitas (L_{cavity}) masing-masing adalah 10 nm.


Dengan mengimobilisasi berbagai biomolekul di dalam rongga nano, biosensor ini bertujuan untuk mengkarakterisasi perilaku biomolekul tersebut dalam lingkungan biosensing. Biomolekul ini dapat diidentifikasi berdasarkan nilai konstanta dielektriknya: APTES ($K = 3,57$), hidroprotein ($K = 5$), keratin ($K = 8$), gelatin ($K = 12$), dan DNA yang dibedakan berdasarkan nilai kerapatan muatannya ($N_f = -1 \times 10^{11}/\text{cm}^2$, $N_f = -5 \times 10^{11}/\text{cm}^2$, $N_f = -1 \times 10^{12}/\text{cm}^2$) dan nilai konstanta dielektrik $K = 12$.

Ketika biomolekul yang berbeda diimobilisasi dalam biosensor berbasis FET, kapasitansi oksida gerbang perangkat berubah, memengaruhi profil potensial, distribusi medan listrik, dan I_D sebagai fungsi dari V_{GS} dan V_{DS} . Perubahan sifat listrik ini sering digunakan dalam mengidentifikasi biomolekul tertentu.



Gambar 10.10 Struktur dua dimensi MC-DD-Ge/Si-INW-FET sebagai biosensor.


Gambar 10.11 mengilustrasikan pergeseran potensial permukaan yang disebabkan oleh imobilisasi berbagai biomolekul netral dan biomolekul DNA dengan muatan negatif yang berbeda di dalam nanokavitas. Potensial permukaan turun dari APTES ke gelatin, seperti yang ditunjukkan pada Gambar 10.11a. Wilayah 1 di saluran di bawah nanokavitas sisi sumber menunjukkan perubahan potensial permukaan terbesar untuk berbagai biomolekul dibandingkan dengan tidak adanya biomolekul apa pun.



Gambar 10.11 Potensial permukaan di sepanjang saluran biosensor MC-DD-Ge/Si-INW-FET untuk (a) berbagai biomolekul netral dan (b) biomolekul DNA pada $K = 12$ dan muatan yang bervariasi.


Hal ini disebabkan oleh tegangan drain yang menurun secara monoton saat mendekati sumber. Biomolekul DNA bermuatan dengan potensial permukaan terendah di antara yang dipelajari memiliki kerapatan muatan $N_f = -1 \times 10^{12}/\text{cm}^2$, seperti yang ditunjukkan pada Gambar 10.11b. Untuk $N_f = -1 \times 10^{12}/\text{cm}^2$, kita mencapai perubahan potensial permukaan terbesar dan, dengan demikian, sensitivitas maksimal dari semua biomolekul DNA yang terperangkap di wilayah nanokavitas. Penurunan potensial dihasilkan dari peningkatan tegangan pita datar yang disebabkan oleh qN_f/C_{eff} . Akibatnya, ini berarti terjadi lebih banyak penipisan area kanal.

Perubahan medan listrik biosensor MC-DD-Ge/Si-INW-FET untuk biomolekul bermuatan dan netral ditunjukkan pada Gambar 10.12. Medan listrik untuk biomolekul dengan nilai konstanta dielektrik yang berbeda, dari APTES hingga gelatin, ditampilkan sepanjang panjang kanal pada Gambar 10.12a. Terlihat jelas bahwa medan listrik di sisi sumber meningkat seiring dengan peningkatan konstanta dielektrik.



Gambar 10.12b menunjukkan plot medan listrik biomolekul DNA bermuatan negatif dibandingkan dengan biomolekul netral pada konstanta dielektrik $K = 12$, beserta skenario tanpa biomolekul apa pun. Grafik tersebut secara jelas menunjukkan bahwa medan listrik bervariasi secara signifikan ketika biomolekul DNA hadir. Kekuatan medan listrik meningkat di dekat daerah sumber seiring dengan meningkatnya muatan negatif biomolekul DNA.

Namun, saat mendekati drain, medan listrik di dalam saluran secara bertahap menurun. Lebih lanjut, ketika muatan negatif DNA bertambah, Gambar 10.12b menunjukkan bahwa medan listrik berkurang hingga titik terendahnya di persimpangan saluran-drain. Pada dasarnya, perubahan karakteristik elektroda gerbang dan interaksinya dengan biomolekul DNA bertanggung jawab atas pergeseran medan listrik ini.




Gambar 10.12 Medan listrik biosensor MC-DD-Ge/Si-INW-FET untuk (a) berbagai biomolekul netral dan (b) biomolekul DNA pada $K = 12$ dan muatan yang bervariasi.

Karakteristik arus ON drain untuk mengimobilisasi beberapa biomolekul, termasuk gelatin, keratin, hidroprotein, dan APTES, ditunjukkan pada Gambar 10.13a, sedangkan arus drain pada skala logaritmik yang mewakili arus subambang $V_{GS} = 0,0$ V ditunjukkan pada Gambar 10.13b. Arus ON meningkat, dan arus subambang menurun seiring dengan meningkatnya nilai K dari berbagai biomolekul. Untuk mengidentifikasi biomolekul tertentu, perubahan arus ini merupakan parameter penginderaan yang penting.

Transkonduktansi (g_m) perangkat yang diusulkan diilustrasikan pada Gambar 10.13c setelah dimasukkannya beberapa biomolekul netral ke dalam wilayah nanokavitas. Transkonduktansi (g_m) adalah turunan orde pertama dari arus drain terhadap tegangan gerbang (V_{GS}). Gambar 10.13c menunjukkan bahwa perubahan transkonduktansi (g_m)


meningkat secara progresif ketika berbagai biomolekul dipertimbangkan, mulai dari APTES hingga gelatin. Dengan nilai puncak transkonduktansi (g_m) sebesar $1,67 \times 10^3 \mu\text{A/V}$, biomolekul gelatin memiliki nilai terbesar. Hasil ini menekankan bahwa ketika nilai konstanta dielektrik biomolekul meningkat, kapasitas perangkat untuk mengubah gangguan tegangan input kecil menjadi variasi arus yang sesuai akan dimaksimalkan.



Gambar 10.13 (a) Karakteristik I_D - V_{GS} dengan berbagai biomolekul dengan konstanta dielektrik yang berubah, (b) arus drain dalam skala logaritmik yang mewakili arus subambang pada $V_{GS} = 0,0$ V, dan (c) transkonduktansi untuk berbagai biomolekul.



Karakteristik arus drain untuk biomolekul DNA bermuatan ditampilkan pada Gambar 10.14, di mana Gambar 10.14a menunjukkan arus drain ON sedangkan Gambar 10.14b menampilkan arus OFF pada skala logaritmik. Ketika biomolekul bermuatan negatif, nilai arus drain ON dan OFF menurun. Penurunan arus drain yang terlihat diamati pada biosensor MC-DD-Ge/Si-INW-FET yang diusulkan. Dampak gerbang meningkat dengan diperkenalkannya protein bermuatan negatif yang lebih banyak, yang menyebabkan tingkat penipisan pembawa yang lebih tinggi dan, karenanya, jumlah arus OFF yang lebih rendah. Misalnya, dalam kasus $K = 12$ dan $N_f = -1 \times 10^{12}/\text{cm}^2$, arus OFF adalah $1,47 \times 10^{-14}$ A, sedangkan dalam kasus tanpa biomolekul, arusnya adalah $3,99 \times 10^{-11}$ A.




GAMBAR 10.14 (a) Karakteristik I_D - V_{GS} dari biosensor MC-DD-Ge/Si-INW-FET untuk biomolekul DNA bermuatan dan (b) arus drain dalam skala logaritmik untuk biomolekul DNA bermuatan.

Gambar 10.15 menunjukkan arus drain dalam kaitannya dengan tegangan drain ke source (VDS). Variasi arus drain untuk mengubah konstanta dielektrik biomolekul ditunjukkan pada Gambar 10.15a, dan variasi arus drain ON, $I_{DS}(\text{ON})$, untuk mengubah muatan negatif biomolekul DNA ditunjukkan pada Gambar 10.15b. Ketika konstanta dielektrik tetap konstan,



dan muatan negatif DNA meningkat, arus drain ON menunjukkan tren penurunan. Penurunan arus drain disebabkan oleh pergeseran ke bawah pada potensial permukaan ketika biomolekul bermuatan negatif diimobilisasi.



Gambar 10.15 Karakteristik I_D – V_{DS} dari biosensor MC-DD-Ge/Si-INW-FET untuk (a) biomolekul netral dan (b) biomolekul DNA bermuatan.


Komponen terpenting dalam desain sensor adalah sensitivitas. Strategi konvensional untuk menguji sensitivitas biosensor FET adalah dengan menganalisis perubahan proporsional pada parameter listrik terukur yang mencerminkan keberadaan biomolekul. Karakteristik listrik ini dapat mencakup arus I_{ON} dan V_{th} , di antara parameter lainnya. Definisi formal sensitivitas (SEP) dalam matematika adalah sebagai berikut:

$$S_{EP} = |EP_{No\ Biomolecul} - EP_{Biomolecules}| \quad (10.3)$$


Nilai parameter listrik sebelum terpapar biomolekul dilambangkan sebagai $EP_{No\ Biomolecul}$, dan nilai parameter listrik biosensor setelah biomolekul diimobilisasi adalah $EP_{Biomolecules}$.

Sensitivitas arus drain biomolekul netral pada MC-DD-Ge/Si-INW-FET ditunjukkan pada Gambar 10.16a. Persamaan 10.3 menghasilkan hasil berikut, yang ditunjukkan pada Gambar 10.16a: sensitivitas arus drain meningkat secara sistematis di seluruh nilai tegangan gerbang setelah penambahan biomolekul, dari APTES hingga gelatin. Pola ini menunjukkan bahwa biomolekul dengan konstanta dielektrik yang lebih tinggi lebih sensitif.

Untuk biomolekul DNA dengan konsentrasi muatan yang bervariasi, sensitivitas arus drain ditunjukkan pada Gambar 10.16b. Jika dibandingkan dengan biomolekul netral, biomolekul bermuatan negatif memiliki kapasitas pengikatan yang lebih tinggi. Akibatnya,



aliran pembawa muatan melintasi saluran diatur lebih ketat ketika terdapat biomolekul bermuatan negatif, yang meningkatkan sensitivitas arus drain.





Gambar 10.16 Sensitivitas arus drain untuk (a) berbagai biomolekul dan (b) biomolekul DNA dengan muatan negatif yang meningkat.

Untuk $K = 12$ dan konsentrasi muatan $N_f = -1 \times 10^{12}/\text{cm}^2$, sensitivitas arus drain adalah $455 \mu\text{A}$.

Pada biosensor berbasis FET, variasi tegangan ambang sangat penting untuk menilai sensitivitas perangkat. Ketika permitivitas biomolekul meningkat, khususnya dengan adanya biomolekul DNA netral dan bermuatan negatif pada $K = 8$, tegangan ambang meningkat, seperti yang diilustrasikan pada Gambar 10.17a dan 10.17b. Hal ini terjadi karena tegangan gerbang yang lebih tinggi diperlukan untuk sepenuhnya mengosongkan saluran ketika potensial permukaan saluran menurun dari ketiadaan biomolekul ke keberadaan biomolekul DNA netral dan bermuatan negatif. Akibatnya, hal ini menyebabkan peningkatan tegangan ambang. Kebutuhan akan tegangan gerbang yang lebih besar untuk mengosongkan saluran dengan adanya biomolekul menunjukkan bahwa potensial permukaan saluran sangat dipengaruhi oleh permitivitas dan muatan biomolekul.

Kapasitansi oksida gerbang meningkat seiring dengan meningkatnya konstanta dielektrik biomolekul, yang secara signifikan berkontribusi pada perubahan relatif tegangan ambang dan dengan demikian sensitivitas. Untuk biomolekul APTES dan keratin, sensitivitas V_{th} masing-masing adalah $45,8 \text{ mV}$ dan $75,4 \text{ mV}$.




E

Gambar 10.17 Tegangan ambang dan sensitivitas tegangan ambang untuk berbagai (a) biomolekul netral dan (b) biomolekul DNA bermuatan.

Sebaliknya, untuk biomolekul DNA dengan $N_f = -1 \times 10^{11}/\text{cm}^2$ dan $N_f = -1 \times 10^{12}/\text{cm}^2$, sensitivitas V_{th} masing-masing adalah 107,14 mV dan 249,50 mV, seperti yang digambarkan pada Gambar 10.17b. Peningkatan sensitivitas tegangan ambang dengan nilai K dan N_f yang lebih tinggi menunjukkan peningkatan respons biosensor terhadap variasi sifat biomolekul, sehingga membuatnya lebih efektif dalam mendeteksi interaksi biomolekul yang berbeda.

Gambar 10.18 menampilkan sensitivitas rasio I_{ON}/I_{OFF} untuk berbagai biomolekul. Rasio I_{ON}/I_{OFF} untuk beberapa biomolekul ditunjukkan pada sisipan Gambar 10.18. Kapasitansi oksida gerbang meningkat seiring dengan konstanta dielektrik biomolekul, memberikan gerbang lebih banyak kendali atas pembawa muatan dan meningkatkan arus ON. Arus subambang adalah istilah untuk arus yang ada bahkan sebelum mencapai tegangan ambang (V_{th}).





Gambar 10.18 Rasio I_{ON}/I_{OFF} dan sensitivitas I_{ON}/I_{OFF} dari biosensor FET DDM-GAA.

Arus OFF drain yang berkurang dihasilkan dari kanal yang sedikit terbalik lebih awal oleh kapasitansi oksida yang lebih tinggi. Konstanta dielektrik K dari biomolekul meningkat sebagai hasilnya, meningkatkan rasio I_{ON}/I_{OFF} . Karena fluktuasi nilainya yang lebih besar untuk perubahan kecil pada konstanta dielektrik, perlu disebutkan bahwa rasio I_{ON}/I_{OFF} juga dapat digunakan sebagai metrik untuk menilai sensitivitas biosensor. Persamaan 10.4 digunakan untuk menghitung sensitivitas rasio I_{ON}/I_{OFF} :

$$\frac{I_{ON}}{I_{OFF}} \text{ Sensitivity : } S_{I_{ON}/I_{OFF}} = \frac{\frac{I_{ON}}{I_{OFF}}}{\frac{I_{ON}}{I_{OFF}}|_{\text{No biomolecules}}} \quad | \text{With biomolecules} \quad (10.4)$$

Analisis sensitivitas komprehensif dilakukan untuk mengevaluasi kinerja biosensor DDM-GAA FET dibandingkan dengan biosensor FET lain dengan karakteristik struktural serupa. Pada Gambar 10.19, terlihat jelas bahwa biosensor yang diusulkan menunjukkan $S_{V_{th}}$ yang jauh lebih tinggi dibandingkan dengan beberapa biosensor terbaru, termasuk GaN-GME-DE-SNW-FET, GC-GAA-NWFET, DG-6H-SiC SB-FET, dan DM DPDG-TFET, untuk $N_f = -1E^{12}/\text{cm}^2$.





Gambar 10.19 Perbandingan ke-SV biosensor MC-DD-Ge/Si-INW-FET dengan biosensor FET yang baru-baru ini dipublikasikan.

Sensitivitas tinggi biosensor MC-DD-Ge/Si-INW-FET menyoroti potensinya untuk meningkatkan kemampuan deteksi dalam aplikasi biosensing, terutama untuk biomolekul DNA. Keunggulan saluran makaroni dan struktur dielektrik ganda menempatkan biosensor MC-DD-Ge/Si-INW-FET pada posisi yang kompetitif dan bermanfaat di sektor teknologi biosensing.

10.3.4 PEMBELAJARAN MESIN DALAM MENINGKATKAN KINERJA BIOSENSOR

ML telah secara signifikan meningkatkan biosensor berbasis FET dengan meningkatkan sensitivitas dan spesifisitasnya, sehingga lebih efektif dalam diagnostik medis, pemantauan lingkungan, dan bioteknologi. BioFET, sensor biokimia canggih yang beroperasi seperti FET, kini mendapat manfaat dari deteksi molekul secara real-time seperti protein, DNA, dan patogen.

Melatih model ML pada dataset besar memungkinkan deteksi akurat dengan tingkat positif palsu yang lebih rendah. Integrasi ini memungkinkan para peneliti untuk memodelkan desain sensor optimal sebelum fabrikasi, mempercepat pengembangan dan mengurangi biaya. ML menyempurnakan parameter sensor dari waktu ke waktu, menyesuaikan dengan target biologis baru dan menganalisis data kompleks dengan model seperti jaringan saraf. Hal ini menghasilkan respons sensor yang lebih presisi, yang sangat penting untuk deteksi dini penyakit dan pengobatan yang dipersonalisasi.

Selain itu, ML memungkinkan pemantauan waktu nyata dan sistem umpan balik, yang sangat penting untuk lingkungan dinamis seperti diagnostik *in vivo* dan pemantauan lingkungan. BioFET portabel yang menggabungkan algoritma ML memfasilitasi biosensing molekuler di luar laboratorium konvensional, meningkatkan pengujian di tempat perawatan, pemantauan kesehatan jarak jauh, dan diagnostik lapangan yang cepat. Inovasi ini siap untuk mengubah perawatan kesehatan dengan membuat BioFET lebih fungsional, sensitif, dan cerdas melalui analisis data tingkat lanjut, pemodelan prediktif, dan pemantauan waktu nyata.

Mengintegrasikan ML ke dalam pengembangan BioFET melibatkan beberapa teknik dan pertimbangan penting. Pertama, pra-pemrosesan data mempersiapkan data sensor mentah untuk analisis dengan membersihkan, menstandarisasi, dan meningkatkan akurasi melalui metode seperti deteksi outlier, pengurangan noise, dan normalisasi. Teknik pengurangan dimensi, seperti analisis komponen utama (PCA) juga diterapkan. Kedua, ekstraksi fitur mengubah data mentah menjadi input yang dapat digunakan untuk model ML, dengan fitur-fitur seperti perubahan arus, tegangan, atau resistansi akibat interaksi biologis diekstrak menggunakan metode pemrosesan sinyal seperti transformasi Fourier dan wavelet. Jaringan saraf konvolusional (CNN) dapat mengotomatiskan ekstraksi fitur kompleks, mendeteksi pola rumit dalam interaksi biologis. Ketiga, memilih model ML yang tepat—seperti SVM, jaringan saraf, random forest, atau K-nearest neighbors—sangat penting untuk analisis yang akurat, berdasarkan tipe data dan persyaratan analisis. Keempat, adaptasi waktu nyata melibatkan pembaruan model secara berkala dengan data baru untuk mempertahankan



akurasi meskipun terjadi perubahan lingkungan, menggunakan teknik seperti pembelajaran online dan pembelajaran penguatan. Kelima, metode ensemble meningkatkan kinerja dan ketahanan dengan menggabungkan prediksi dari beberapa model melalui strategi seperti bagging, boosting, dan stacking. Keenam, transfer learning meningkatkan akurasi model dan mempercepat penerapan dengan memanfaatkan model yang telah dilatih sebelumnya dari tugas-tugas terkait, yang sangat bermanfaat untuk dataset kecil. Terakhir, pemeliharaan dan kalibrasi prediktif menggunakan ML untuk mengotomatiskan pemantauan, mengoptimalkan kondisi, dan menjadwalkan servis untuk perangkat BioFET, memastikan kontrol yang tepat dan umur panjang. Secara keseluruhan, ML meningkatkan sensitivitas, spesifisitas, dan fleksibilitas BioFET, menjadikannya alat yang berharga untuk aplikasi medis, lingkungan, dan bioteknologi melalui pra-pemrosesan tingkat lanjut, ekstraksi fitur, metode ensemble, transfer learning, dan pemilihan model adaptif secara real-time.

Analisis Data Berbasis ML: Dalam analisis data, PCA, SVM, dan jaringan saraf tiruan (ANN) adalah tiga metode ML terkemuka yang diterapkan pada data sensor BioFET. PCA adalah teknik yang digunakan untuk mengurangi dimensi dan mengekstrak fitur-fitur utama dari data sensor yang kompleks dan berdimensi tinggi, mengubahnya menjadi komponen utama yang menangkap variabilitas penting. Proses ini menyederhanakan data sambil mempertahankan detail penting tentang interaksi biologis. Model SVM efektif untuk tugas klasifikasi dan regresi.


Model ini menciptakan hyperplane optimal untuk mengklasifikasikan target biologis dalam data sensor dan mengelola hubungan nonlinier tanpa overfitting. ANN, termasuk CNN dan RNN, mahir dalam mengidentifikasi pola kompleks dalam dataset besar, menganalisis data sensor untuk memprediksi interaksi dan mendeteksi pola dalam sistem biologis.

Teknik-teknik ini bekerja bersama, dengan PCA menyaring noise dan menciptakan fitur untuk analisis SVM atau ANN, SVM mengklasifikasikan dataset, dan ANN menyempurnakan hubungan data yang rumit. Bersama-sama, metode-metode ini meningkatkan akurasi, kecepatan, dan kedalaman aplikasi BioFET di bidang biomedis dan bioteknologi.

Desain BioFET Berdasarkan ML: Baru-baru ini, desain sensor, terutama BioFET, telah sangat ditingkatkan dengan penerapan algoritma ML. Kemajuan ini telah mengubah pengembangan sensor dengan meningkatkan efisiensi operasional, meningkatkan material, mengurangi waktu siklus desain, dan meningkatkan pemilihan reseptor. ML secara signifikan meningkatkan kinerja BioFET dengan mengoptimalkan parameter untuk sensitivitas, selektivitas, dan efisiensi yang lebih besar, serta menyempurnakan sifat material 2D seperti semikonduktor dikalkogenida logam transisi (TMDC), memprediksi celah pita, dan mengoptimalkan struktur cacat.

Teknik seperti regresi proses Gaussian dan optimasi Bayesian mempercepat proses desain untuk heterostruktur, sementara random forest dan gradient boosting meningkatkan aliran elektron dalam FET organik. Selain itu, ML merevolusi pemilihan reseptor dengan memprediksi dan mengoptimalkan reseptor seperti enzim dan aptamer, yang mengarah pada penemuan reseptor baru dengan spesifisitas dan efisiensi deteksi yang tinggi.

Menggabungkan ML ke dalam desain BioFET merupakan pendekatan inovatif, yang memfasilitasi pembuatan sensor yang tepat dan efisien dengan sensitivitas, spesifisitas, dan




fleksibilitas yang lebih baik. Hal ini menempatkan ML sebagai elemen penting dalam memajukan diagnostik kesehatan, pemantauan lingkungan, dan deteksi penyakit, menyoroti peran pentingnya dalam mengembangkan teknologi sensor dan mengatasi tantangan kompleks di berbagai bidang.

10.4 KESIMPULAN

Pembahasan ini mengeksplorasi analisis sensitivitas saluran makaroni yang terintegrasi dengan FET nanowire Ge/Si dielektrik ganda, mengevaluasi kinerjanya dalam berbagai aplikasi analog. Tes simulasi komprehensif dilakukan untuk menilai kinerja analog perangkat, menganalisis berbagai parameter dan karakteristik. Temuan ini menyoroti peningkatan signifikan berkat kanal macaroni, sumber germanium, dan susunan gerbang horizontal, yang meningkatkan kinerja perangkat dibandingkan dengan model tradisional.

Rasio I_{ON}/I_{OFF} telah meningkat sekitar 28 kali, yang sangat penting untuk aplikasi digital, sementara transkonduktansi telah meningkat sekitar 44 kali, bermanfaat untuk amplifikasi. Selain itu, perangkat ini telah digunakan sebagai biosensor, menunjukkan sensitivitas tinggi terhadap berbagai biomolekul. Dengan memeriksa biomolekul bermuatan dan netral, penelitian ini meningkatkan penerapan dan akurasi hasilnya. Biosensor menunjukkan sensitivitas tegangan sekitar 75,4 mV untuk $K_{bio} = 8$. Lebih lanjut, peran ML dalam mengoptimalkan kinerja dan desain perangkat dieksplorasi melalui diskusi terperinci.



DAFTAR PUSTAKA

- Ahmad, F. (2022). PENGEMBANGAN ALAT PERAGA KONVERSI PANAS KE LISTRIK UNTUK MENSTIMULUS KETERAMPILAN BERPIKIR KREATIF.
- Akhsan, H., Ariska, M., Lekati, N. K., Firmansyah, Z. A., & Veronika, A. (2025). De Broglie Waves In Electron Microscopy: Contributions To Atomic-Scale Visualization And Material Characterization—A Prisma Based Review. *Jurnal Fisika: Fisika Sains Dan Aplikasinya*, 10(2), 40-47.
- Ali, S., & Basri, H. (2022). Analisa Panel Surya Pada Sistem Pengisian Mobil Listrik 3500 Watt. *Mekanik: Jurnal Ilmiah Bidang Teknik Mesin*, 15(1), 67-74.
- Andi, F. F. R., & Rachmat, P. (2022). Rancang Bangun Prototipe Alat Pembersih Panel Panel Surya Otomatis (Doctoral Dissertation, Politeknik Negeri Ujung Pandang).
- Anugrah, M. R., Prayitno, T. B., & Suhendar, H. (2025, January). Performance Comparison Of Random Forest Regressor And Xgboost Regressor Algorithms In Predicting The Band Gap Of Silicon Semiconductor Materials: Perbandingan Performa Algoritma Random Forest Regressor Dan Xgboost Regressor Dalam Prediksi Band Gap Material Semikonduktor Silikon. In *Joint Prosiding Ips Dan Seminar Nasional Fisika (Vol. 13)*.
- Arham, M., Hamka, A., BJ, M. F., Nasir, A. M. S., Tawakkal, M., Mislahuddin, M., & Syahril, S. (2024). TEKNOLOGI DAN INOVASI DALAM PENDIDIKAN TEKNIK MESIN TREN DAN APLIKASI TERBARU.
- Auliani, Q., Aditya, R., Saputra, M. D., Firdaus, M. A., Pahlevi, B. R., & Aribowo, D. (2024). Simulasi Sensor Parkir Berbasis Mikrokontroler Arduino Uno Dengan Sensor HC-SR04 Menggunakan Website Wokwi. *Jurnal Teknik Mesin, Industri, Elektro Dan Informatika*, 3(4), 259-273.
- Choir, R. A., Sudarti, S., & Yushardi, Y. (2024). Analisis Pemahaman Mahasiswa Pendidikan Fisika Tentang Mekanisme Pembangkit Listrik Tenaga Surya. *Jurnal Mekanova: Mekanikal, Inovasi Dan Teknologi*, 9(2), 200-207.
- Dafa, A. H. (2025). DESAIN KOMPOSISI OPTIMAL MATERIAL SEMIKONDUKTOR ALUMINIUM GALIUM ARSENIDA (Alxga1-Xas) MENGGUNAKAN KECERDASAN BUATAN (Doctoral Dissertation, Universitas Nasional).
- Darmawan, A., Winarta, A., & Baliarta, I. (2023). Uji Kinerja Cooler Box Thermoelectric Menggunakan Pcm-Heatsink Pada Sisi Panas (Doctoral Dissertation, Politeknik Negeri Bali).
- Fadhilah, R., & Irawan, D. (2023). Kimia Material Pengembangan Material Berbasis Selulosa Kulit Pisang. CV. Bintang Semesta Media.



- Gunawan, L. A., Agung, A. I., Widyartono, M., & Haryudo, S. I. (2021). Rancang Bangun Pembangkit Listrik Tenaga Surya Portable. *Jurnal Teknik Elektro*, 10(1), 65-71.
- Hesti, W. H. (2024). Rancang Bangun Mesin Cnc Laser 4 Axis Menggunakan Motor Stepper Tipe Nema 23 Terintegrasi Mach3 Usb Untuk Aplikasi Mesin Cutting Otomatis (Doctoral Dissertation, Universitas Lampung).
- Ismail, Z. (2024). Uji Fungsi Mesin Metal Thermal Evaporator Physical Vapour Deposition (PVD) Untuk Efektifitas Lapisan Film Tipis Aluminium (Al) Pada Substrat Kaca (Doctoral Dissertation, Politeknik Manufaktur Bandung).
- JUNAEDI, J. (2024). ANALISA PENGARUH VARIASI SUHU DAN RANGKAIAN LISTRIK PADA TERMOELEKTRIK GENERATOR MODULE SP 1848-27145 TERHADAP ENERGI LISTRIK YANG DIHASILKAN DAN EFISIENSI TERMOELEKTRIK GENERATOR (Doctoral Dissertation, FAKULTAS TEKNIK, UNIVERSITAS ISLAM SUMATERA UTARA).
- Magfira, D. B., Yudianto, F., Wulan, T. D., Herlambang, T., Budiarti, R. P. N., & Siswanti, A. T. R. (2024). Perancangan Iot Sederhana Untuk Sistem Pendeteksi Kemurnian Kopi Bubuk. *Jurnal Tecnoscienza*, 9(1), 86-96.
- Mulyawan, R. G., Rivai, M., & Isnaeni, I. (2021). Perancangan Sistem Pump-Probe Spectroscopy Sebagai Metode Dalam Analisis Dinamika Elektron Pada Larutan. *Jurnal Sains Dan Seni ITS*, 10(1), 488432.
- Mustakim, S., Kom, M., Suparman, A., Si, S., Kom, M., Haryanta, J. T., ... & Alvianus Dengan, S. T. (2025). PERKEMBANGAN TEKNOLOGI KOMPUTER. CV Rey Media Grafika.
- Nashihin, H., Baroroh, A., & Ali, A. (2020). Implikasi Hukum Teknologi Informasi Dalam Perkembangan Teknologi Pendidikan Islam (Telaah Atas Hukum Moore, Hukum Metcalfe, Dan Hukum Coase). *At Turots: Jurnal Pendidikan Islam*, 136-147.
- Nasution, A. H., & Ginting, A. (2025). Tinjauan Penggerudian Laser: Kemajuan, Teknik Optimasi, Dan Aplikasi. *Jurnal Rekayasa Material, Manufaktur Dan Energi*, 8(2), 384-394.
- Nugraha, R. A., Utomo, B. S., Larasati, P. D., & Wibisono, R. D. (2025, August). PERANAN ENERGI BERKELANJUTAN PADA PENDIDIKAN SAINS: STUDI KASUS EVALUASI KINERJA PLTS. In *Proceeding Seminar Nasional IPA* (Pp. 460-469).
- Nulhakim, L., Syafrizal, S., Subekti, M. I., Tauvana, A. I., Widodo, W., & Yusuf, M. (2024). RANCANG BANGUN MODUL MESIN KONVERSI ENERGI BERTINGKAT: RANCANG BANGUN MODUL MESIN KONVERSI ENERGI BERTINGKAT. *Machine: Jurnal Teknik Mesin*, 10(1), 1-5.
- Nurba, D. (2025). MATERIAL KONVERSI ENERGI EDISI PERTAMA. Diswandi Nurba.
- Nurba, D., & Syah, H. (2026). MATERIAL KONVERSI ENERGI EDISI KE-2. Diswandi Nurba.



- Nurmayanti, Y., Rukmana, M. D., Cengristitama, C., Amir, A. A., Nafillah, K., Sari, M. W., ... & Yusri, A. (2024). Kimia Material. Yayasan Tri Edukasi Ilmiah.
- Octowinandi, V. (2022). Pengukuran Hasil Dari Mesin Laser Engraving Pada Material Akrilik Dan Pvc. JOURNAL OF APPLIED SCIENCES, ELECTRICAL ENGINEERING AND COMPUTER TECHNOLOGY (ASEECT), 3(01), 34-48.
- Pramono, A., & Arsana, I. M. (2023). Pengembangan Video Pembelajaran Materi “Wire And Tube Heat Exchanger” Untuk Mahasiswa Teknik Mesin Universitas Negeri Surabaya. Jurnal Pendidikan Teknik Mesin, 12(2), 47-52.
- Purwiyanti, S., Fitriawan, H., Komarudin, M., & Alam, S. (2025). Analisis Tingkat Pemahaman Mahasiswa Teknik Elektro Terhadap Materi Semikonduktor Untuk Memenuhi Kebutuhan Industri: Studi Kasus Di Universitas Lampung. PARAMETER: Jurnal Pendidikan Universitas Negeri Jakarta, 37(2), 155-169.
- Putra, A. G., Muda, I., Pawawoi, P., Ikaningsih, M. A., Prajitno, D. H., Martijanti, M., ... & Chandrasari, A. Z. (2025). Pengantar Material Teknik. Yayasan Tri Edukasi Ilmiah.
- Rahmadani, R. (2025). Prediksi Hasil Arus Keluar Pada Pembangkit Listrik Tenaga Surya Menggunakan Edge Impulse= Prediction Of Output Current Results In Solar Power Plants Using Edge Impulse (Doctoral Dissertation, Universitas Hasanuddin).
- Rahman, N. R., Sya’roni, I., Subiantoro, I., & Prasetyono, A. D. (2023). Analisis Respon Mahasiswa Pada Pembelajaran Fisika Material Tetang Lapisan Tipis Menggunakan Media Praktikum Spin Coating Berbasis Mikrokontroler Dan Iot. PENDIDIKAN MENUJU ERA SOCIETY 5.0, 40.
- Rahman, N. R., Sya’roni, I., Subiantoro, I., & Prasetyono, A. D. (2023). Analisis Respon Mahasiswa Pada Pembelajaran Fisika Material Tetang Lapisan Tipis Menggunakan Media Praktikum Spin Coating Berbasis Mikrokontroler Dan Iot. PENDIDIKAN MENUJU ERA SOCIETY 5.0, 40.
- Ramadhan, M. J., Santiyadnya, N., & Pracasitaram, I. G. M. S. B. (2022). Media Pembelajaran Nodemcu8266 Menggunakan Iot Pada Mata Kuliah Sistem Kendali Berbasis Komputer Di Prodi S1 Pendidikan Teknik Elektro Undiksha. Jurnal Pendidikan Teknik Elektro Undiksha, 11(2), 82-92.
- Ramadhana, D. R. (2024). Rancang Bangun Modul Robotika Sebagai Media Pembelajaran Pada Mata Kuliah Kecerdasan Buatan Dan Robotika Menggunakan Mikrokontroler ESP32= Design And Development Of Robotics Module As A Learning Media For Artificial Intelligence And Robotics Courses Using ESP32 Microcontroller (Doctoral Dissertation, Universitas Hasanuddin).



- Rusdi, M., Rahmawaty, R., Pulungan, M. A., Azis, A., Irawan, S., & Othman, Z. (2024). Analisis Variasi Suhu Terhadap Variasi Cahaya Pada Rancang Bangun Solar Test Simulator Menggunakan Peltier. *Jurnal Rekayasa Material, Manufaktur Dan Energi*, 7(1), 106-112.
- Sapulette, R. (2025). Sosialisasi Pemamfaatan Energi Surya Sebagai Pembangkit Listrik Tenaga Surya (PLts) Pada Siswa Smp Kokoda Utara. *Solideo Jurnal Pengabdian Masyarakat*, 3(3), 146-155.
- SETIAWAN, D. (2024). ANALISA JUMLAH PELTIER TYPE TEC1-12706 SR PADA TERMOELEKTRIK GENERATOR TERHADAP TEGANGAN, ARUS, DAYA LISTRIK DAN EFESIENSI TERMOELEKTRI (Doctoral Dissertation, FAKULTAS TEKNIK, UNIVERSITAS ISLAM SUMATERA UTARA).
- Siagian, P. (2022). Pengembangan Panel Surya 120 Wp Dengan Solar Tracker Double Axis Sebagai Bahan Pembelajaran Mahasiswa Di Program Studi Teknik Mesin UHN. *Sprocket Journal Of Mechanical Engineering*, 3(2), 115-128.
- Siregar, Z. H., Mubarak, A. A., Djuli, Y. S., Irwan, H., Bora, M. A., Merjani, A., ... & Edi, F. (2025). *Pengantar Teknik Mesin Dan Industri*.
- Sitompul, S., Ibrahim, H., Pratama, A. B., & Hasan, F. F. (2024). Analisis Pengaruh Energi Matahari Terhadap Tegangan Keluar Solar Cell Pada Rancang Bangun Solar Tracking Berbasis Microcontroler. *SINERGI POLMED: Jurnal Ilmiah Teknik Mesin*, 5(2), 113-120.
- Suartana, I. P. E., & Widyanto, D. (2023). Estimasi Kecepatan Reaksi Elektrolisis Berdasarkan Energi Listrik Dari Sumber Energi Terbarukan Dengan Estimator Extreme Learning Machine. *Informatik: Jurnal Ilmu Komputer*, 19(3), 177-188.
- Syaefudin, E. A., Kholil, A., Wulandari, D. A., Avianti, R. A., & Walujo, D. (2022, December). Penerapan Pembangkit Listrik Tenaga Surya (PLts) Sebagai Media Pembelajaran Di Smpn 3 Terisi Indramayu. In *Prosiding Seminar Nasional Pengabdian Kepada Masyarakat* (Vol. 3, Pp. SNPPM2022ST-246).
- Taufiq, A. J., Wibowo, T. N., Endratno, H., Tamam, M. T., Pratama, B. H., & Mashobih, F. F. (2025). Pelatihan Alat Peraga Pelajaran IPA Untuk Guru SD Muhammadiyah Purwokerto: Training On Science Teaching Aids For Teachers Muhammadiyah Elementary School Purwokerto. *Jurnal Pengabdian Teknik Dan Sains (JPTS)*, 5(2), 83-91.
- Wadjdi, F. (2026). *Rangkaian Listrik Arus Searah Berbasis Qr. Feniks Muda Sejahtera*.

Machine Learning (ML) untuk Material Semikonduktor

Dr. Ir. Agus Wibowo, M.Kom, M.Si, MM.

BIO DATA PENULIS



Penulis memiliki berbagai disiplin ilmu yang diperoleh dari Universitas Diponegoro (UNDIP) Semarang. dan dari Universitas Kristen Satya Wacana (UKSW) Salatiga. Disiplin ilmu itu antara lain teknik elektro, komputer, manajemen, ilmu sosiologi dan ilmu hukum. Penulis memiliki pengalaman kerja pada industri elektronik dan sertifikasi keahlian dalam bidang Jaringan

Internet, Telekomunikasi, Artificial Intelligence, Internet Of Things (IoT), Augmented Reality (AR), Technopreneurship, Internet Marketing dan bidang pengolahan dan analisa data (komputer statistik), Ilmu Perpajakan.

Penulis adalah pendiri dari Universitas Sains dan Teknologi Komputer (Universitas STEKOM) dan juga seorang dosen yang memiliki Jabatan Fungsional Akademik Lektor Kepala (Associate Professor) yang telah menghasilkan puluhan Buku Ajar ber ISBN, HAKI dari beberapa karya cipta dan Hak Paten pada produk IPTEK. Sejak tahun 2023 penulis tercatat sebagai Dosen luar biasa di Fakultas Ekonomi & Bisnis (FEB) Universitas Diponegoro Semarang. Penulis juga terlibat dalam berbagai organisasi profesi dan industri yang terkait dengan dunia usaha dan industri, khususnya dalam pengembangan sumber daya manusia yang unggul untuk memenuhi kebutuhan dunia kerja secara nyata.



YAYASAN PRIMA AGUS TEKNIK

PENERBIT :

YAYASAN PRIMA AGUS TEKNIK
Jl. Majapahit No. 605 Semarang
Telp. (024) 6723456. Fax. 024-6710144
Email : penerbit_ypat@stekom.ac.id

ISBN 978-634-7695-04-8 (PDF)



9

786347

695048