

YOLOv12-Based PCB Defect Classification Post-Etching via SMOTE Data Balancing

Thomas Setiawan^{1*)}, Yohannes²⁾

¹⁾²⁾Program Studi Informatika, Fakultas Ilmu Komputer dan Rekayasa, Universitas Multi Data Palembang

^{*)}Correspondence author: thomassetiawan13@mhs.mdp.ac.id, Palembang, Indonesia

DOI: <https://doi.org/10.37012/jtik.v12i2.4029>

Abstract

Printed Circuit Boards (PCBs) are critical components in electronic devices, requiring high precision during manufacturing to ensure optimal circuit functionality. The etching process in PCB fabrication is prone to copper track defects, particularly in liquid transfer techniques, which are susceptible to poor ink adhesion that leads to wrinkled, widened, or broken tracks. To support fast and accurate quality inspection, this study implements YOLOv12 to classify the condition of PCBs post-etching. The dataset consists of 650 PCB images with a resolution of 640×640 pixels (200 non-defective and 450 defective PCB images). This research evaluates the performance of four optimizers (Adam, AdamW, SGD, and RMSProp) and analyzes the impact of applying the Synthetic Minority Over-sampling Technique (SMOTE) to address class imbalance. Experimental results demonstrate that without SMOTE, RMSProp achieved the highest overall performance with an accuracy of 93.846% and an F1-Score of 93.635%. However, applying SMOTE significantly boosted the performance of the Adam optimizer, attaining the highest overall accuracy of 95.385% and an F1-Score of 95.415%.

Keywords: Classification, Etching, PCB Defects, SMOTE, YOLOv12.

Abstrak

Printed Circuit Board (PCB) merupakan komponen penting dalam perangkat elektronik yang menuntut tingkat presisi tinggi agar dapat berfungsi secara optimal. Proses etching pada pembuatan PCB rentan menimbulkan cacat jalur tembaga, terutama pada teknik liquid transfer yang berpotensi menyebabkan jalur berkerut, melebar, atau putus akibat penempelan tinta yang tidak sempurna. Untuk mendukung proses inspeksi kualitas secara cepat dan akurat, penelitian ini mengimplementasikan model YOLOv12 untuk mengklasifikasikan kondisi PCB pasca-etching. Dataset yang digunakan terdiri dari 650 citra PCB berukuran 640×640 piksel (200 citra PCB tidak cacat dan 450 citra PCB cacat). Penelitian ini mengevaluasi kinerja empat jenis optimizer (Adam, AdamW, SGD, dan RMSProp) serta menganalisis pengaruh penerapan Synthetic Minority Over-sampling Technique (SMOTE) dalam mengatasi ketidakseimbangan kelas. Hasil eksperimen menunjukkan bahwa tanpa SMOTE, RMSProp menjadi optimizer terbaik dengan akurasi 93,846% dan F1-Score 93,635%. Namun, penerapan SMOTE berhasil meningkatkan performa optimizer Adam secara signifikan hingga mencapai akurasi tertinggi 95,385% dan F1-Score 95,415%.

Kata Kunci: Cacat PCB, Etching, Klasifikasi, SMOTE, YOLOv12.

PENDAHULUAN

Printed Circuit Board (PCB) merupakan papan yang berfungsi menghubungkan komponen-komponen elektronik melalui jalur konduktif (track), pad, dan via yang dibuat dari lapisan tembaga dan dilaminasi pada bahan substrat isolator (Direktorat Jenderal Bea dan Cukai, 2020). Seiring dengan peran pentingnya dalam berbagai perangkat, pada tahun 2024 produksi global PCB mencapai lebih dari 68 miliar unit. Permintaan terbesar berasal dari elektronik konsumen (39,5%), terutama smartphone dengan lebih dari 14,2 miliar unit. Sektor medis menggunakan sekitar 7,3 miliar PCB, sementara militer dan kedirgantaraan berkontribusi 3,8 miliar unit. Secara keseluruhan, industri ini mencakup lebih dari 4.200 produsen di seluruh dunia, dengan 57% berbasis di Asia-Pasifik, khususnya Tiongkok, Korea Selatan, dan Jepang (Market Growth Reports, 2025). Oleh karena itu, produksi PCB yang akurat menjadi semakin krusial seiring dengan meningkatnya permintaan produk elektronik (P.S. & R. S., 2014).

Ada beberapa teknik yang umum dipakai dalam membuat jalur tembaga pada PCB untuk produksi dari rumah, yaitu engraving dan etching. Engraving dilakukan dengan menghilangkan bagian yang tidak diinginkan dengan penggilingan (Basniak & Catapan, 2012) atau laser (Alwaidh et al., 2014). Sedangkan etching dilakukan dengan melapisi bagian tertentu dengan tinta anti asam, lalu melarutkannya ke dalam cairan etsa. Hal ini menyebabkan bagian yang tidak dilapisi tinta terbuang setelah proses etching. Sebelum dilakukan etching, perlu dilakukan proses transfer layout. Transfer layout adalah proses pemindahan tinta atau cairan resist dari kertas ke permukaan PCB. Ada beberapa teknik dalam melakukan transfer layout, yaitu toner transfer, photoresist, dan liquid transfer.

Perbedaanya terletak pada cairan yang digunakan sebagai pelapis. Toner transfer menggunakan toner yang dicetak pada kertas glossy. Photoresist menggunakan cairan photoresist untuk menutupi bagian yang ingin dipertahankan. Liquid transfer menggunakan tinta yang digambar langsung pada PCB atau yang dicetak ke kertas. Teknik liquid transfer rentan menyebabkan kecacatan waktu proses etsa, tapi teknik ini paling mudah diaplikasikan dengan peralatan yang sering ditemukan (autan, PCB, kertas, printer laser, cairan etsa). Kecacatan yang terjadi berupa jalur tembaga yang berkerut, melebar, atau putus. Hal ini disebabkan oleh tinta yang tidak merekat sempurna karena permukaan PCB yang kotor atau teroksidasi. Selain itu, hal ini juga bisa disebabkan oleh tinta yang digunakan kurang kuat atau kurang tebal.

Untuk mengatasi permasalahan kecacatan tersebut, diperlukan sistem pendeteksi otomatis yang mampu mengidentifikasi cacat jalur tembaga pada PCB secara cepat dan akurat. Salah satu algoritma yang sering digunakan untuk klasifikasi gambar adalah YOLOv12. Algoritma ini dikembangkan oleh (Tian et al., 2025) dan rilis pada 20 Februari 2025. Menurut Sapkota et al. (2025), YOLOv12 menunjukkan definisi kontur objek yang lebih tajam dibandingkan versi YOLO sebelumnya. Hal ini membuat YOLOv12 potensial untuk digunakan dalam mengecek kecacatan jalur tembaga pada PCB.


Namun demikian, proses pelabelan citra cacat PCB pada umumnya menghasilkan distribusi kelas yang tidak seimbang (imbalanced dataset) karena jumlah citra PCB tidak cacat jauh lebih sedikit dibandingkan dengan citra PCB cacat. Ketidakseimbangan ini menyebabkan model machine learning cenderung lebih berpihak pada kelas mayoritas, sehingga menyebabkan kesalahan klasifikasi pada kelas minoritas dan menghasilkan kinerja klasifikasi yang buruk (Khan et al., 2024). Untuk mengatasi permasalahan tersebut, salah satu metode penyeimbangan data yang banyak digunakan adalah Synthetic Minority Over-sampling Technique (SMOTE). SMOTE bekerja dengan menambah jumlah sampel kelas minoritas melalui pembangkitan data sintetis (Chawla et al., 2002).

Selain permasalahan ketidakseimbangan data, efektivitas arsitektur YOLOv12 dalam mengenali kecacatan objek sangat bergantung pada pemilihan algoritma optimizer yang tepat. Pemilihan metode optimasi yang tepat serta pengaturan hiperparameter yang efektif memegang peranan krusial dalam menentukan kecepatan konvergensi pelatihan dan tingkat akurasi akhir model (Schmidt et al., 2021). Namun, setiap optimizer memiliki mekanisme pembaruan parameter yang berbeda.

Optimizer Adam (Kingma & Ba, 2017) dan RMSProp (Hinton et al., 2012) menggunakan laju pembelajaran adaptif (adaptive learning rate), sedangkan SGD (Robbins & Monro, 1951) memperbarui parameter berdasarkan gradien yang dihitung dari setiap mini-batch data (Goodfellow et al., 2016). Pemilihan optimizer yang tidak tepat berpotensi menyebabkan model terjebak dalam local minima atau memerlukan waktu konvergensi yang jauh lebih lama (Ruder, 2017). Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengklasifikasikan cacat etching pada jalur PCB menggunakan model YOLOv12 dengan metode SMOTE pada berbagai optimizer.

METODE PENELITIAN

Dalam pelaksanaan penelitian ini, diterapkan perancangan metode terlebih dahulu untuk meminimalisir kesalahan dalam proses penelitian. Tahapan metodologi penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Metodologi

Tahap awal diawali dengan pengumpulan dataset yang terdiri dari 650 citra PCB berukuran 640×640 piksel pasca-proses etching menggunakan teknik liquid transfer. Citra tersebut terbagi menjadi kelas PCB tidak cacat sebanyak 200 citra (kelas minoritas) dan PCB cacat sebanyak 450 citra (kelas mayoritas) yang mencakup variasi cacat jalur tembaga berupa berkerut, melebar, atau putus. Contoh sampel visual dari kondisi PCB tidak cacat dan PCB cacat ditunjukkan pada Gambar 2. Dataset kemudian dibagi secara acak menggunakan proporsi 80% untuk data latih (training set) sebanyak 520 citra dan 20% untuk data uji (testing set) sebanyak 130 citra.



(a)



(b)

Gambar 2. Dataset PCB dengan post-etching (a) Cacat; (b) Tidak cacat

Pada tahap perancangan, disusun skenario eksperimen untuk mengevaluasi pengaruh penanganan ketidakseimbangan data dan variasi optimizer pada model YOLOv12 Nano Classification (yolo12n-cls). Penelitian ini membandingkan dua skenario pelatihan utama, yaitu Skenario 1 tanpa penerapan SMOTE dan Skenario 2 dengan penerapan SMOTE. Dalam setiap skenario, model dilatih menggunakan empat jenis optimizer (Adam, AdamW, SGD, dan RMSProp). Untuk memastikan perbandingan yang adil (fair comparison), seluruh pengujian dijalankan menggunakan konfigurasi hiperparameter yang diseragamkan, yaitu ukuran citra input sebesar 1500×1500 piksel, batch size sebesar 8, initial learning rate sebesar 0,01, momentum sebesar 0,937, weight decay sebesar 0,0005 serta durasi pelatihan selama 100 epoch. Proses pelatihan dieksekusi pada lingkungan multi-GPU dengan menetapkan nilai seed 42 untuk menjaga reproduksibilitas data eksperimen.

Tahap pengujian dilakukan untuk mengukur kinerja model pada testing set berdasarkan empat metrik klasifikasi utama, yaitu Accuracy, Precision, Recall, dan F1-Score, serta efisiensi waktu komputasi rata-rata per epoch (seconds/epoch). Formulasi metrik evaluasi yang digunakan didefinisikan persamaan 1 untuk akurasi, persamaan 2 untuk presisi, persamaan 3 untuk recall, dan persamaan 4 untuk f1-score.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Presisi = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1\ Score = \frac{2 \times Presisi \times Recall}{Presisi + Recall} \quad (4)$$

Variabel TP (True Positive) merepresentasikan citra PCB cacat yang terklasifikasi secara benar, TN (True Negative) merepresentasikan citra PCB tidak cacat yang terklasifikasi secara benar, FP (False Positive) merepresentasikan citra PCB tidak cacat yang salah terprediksi sebagai cacat, dan FN (False Negative) merepresentasikan citra PCB cacat yang tidak terdeteksi oleh model.


HASIL DAN PEMBAHASAN

Pengujian dilakukan untuk menganalisis pengaruh empat jenis optimizer (Adam, AdamW, SGD, dan RMSProp) terhadap kinerja arsitektur YOLOv12 dalam mengklasifikasikan cacat etching PCB, baik pada kondisi dataset asli maupun setelah diseimbangkan menggunakan Synthetic Minority Over-sampling Technique (SMOTE). Hasil komparasi lengkap antar-skenario disajikan pada Tabel 1, sedangkan hasil prediksi pada data uji ditampilkan melalui Confusion Matrix pada Gambar 3 dan Gambar 4.


Tabel 1.

Hasil Skenario Pengujian

Skenario	Optimizer	Akurasi (%)	Presisi (%)	Recall (%)	F1 -Score (%)	Durasi per epoch (detik)
Skenario tanpa SMOTE	Adam	89,231	89,169	89,231	88,968	91,460
	AdamW	89,231	89,122	89,231	89,152	85,382
	SGD	92,308	92,246	92,308	92,251	90,310
	RMSProp	93,846	94,349	93,846	93,635	88,729
Skenario menggunakan SMOTE	Adam	95,385	95,496	95,385	95,415	100,435
	AdamW	90,769	91,855	90,769	90,243	100,832
	SGD	92,308	93,077	92,308	91,961	99,969
	RMSProp	92,308	92,246	92,308	92,251	98,695



Gambar 3. Confusion Matrix skenario tanpa SMOTE pada berbagai optimizer (a) Adam; (b) AdamW; (c) SGD; (d) RMSProp




Gambar 4. Confusion Matrix skenario menggunakan SMOTE pada berbagai optimizer (a) Adam; (b) AdamW; (c) SGD; (d) RMSProp

Pada skenario pertama tanpa penerapan SMOTE, dataset berada dalam kondisi tidak seimbang dengan dominasi kelas cacat dibandingkan kelas tidak cacat. Berdasarkan Tabel 1 dan Confusion Matrix pada Gambar 3, RMSProp mencatatkan kinerja terbaik dengan berhasil mengidentifikasi seluruh sampel cacat secara sempurna (45 dari 45 sampel terprediksi True Positive) tanpa adanya False Negative ($FN = 0$). Kinerja ini menghasilkan akurasi sebesar 93,846% dan F1-Score sebesar 93,635%. Keunggulan RMSProp pada data yang tidak seimbang didorong oleh mekanisme pembagian gradien dengan exponential moving average dari kuadrat gradien, yang secara adaptif menyesuaikan learning rate


individual agar parameter kelas minoritas tidak terabaikan. Sebaliknya, varian Adam (Adam dan AdamW) menghasilkan tingkat akurasi terendah pada skenario ini (89,231%) dengan angka kesalahan klasifikasi (False Positive) sebesar 4 hingga 5 sampel pada kelas tidak cacat.

Penerapan SMOTE pada skenario kedua (Gambar 4) terbukti memberikan dampak positif yang signifikan terhadap optimizer berbasis momentum adaptif, khususnya Adam. Confusion Matrix menunjukkan bahwa optimizer Adam mengalami penurunan False Positive secara drastis dari 5 sampel menjadi hanya 1 sampel, serta True Negative meningkat dari 15 menjadi 19 sampel. Hal ini mendongkrak kinerja Adam hingga mencapai akurasi tertinggi sebesar 95,385% dan F1-Score sebesar 95,415%. Distribusi data yang seimbang memungkinkan perhitungan moving average dari gradien dan kuadrat gradien pada Adam bekerja secara optimal tanpa terdistorsi oleh bias kelas mayoritas.

AdamW juga menunjukkan peningkatan sensitivitas pada kelas cacat ($TP = 45$, $FN = 0$), meskipun akumulasi kesalahan pada kelas tidak cacat ($FP = 6$) menjaga akurasi keseluruhannya berada di angka 90,769%. Di sisi lain, SGD menunjukkan tingkat ketahanan (robustness) yang sangat stabil dengan akurasi konsisten di angka 92,308% pada kedua skenario. Menariknya, RMSProp mengalami sedikit penurunan akurasi (-1,538% menjadi 92,308%) akibat munculnya 2 kesalahan prediksi pada kelas cacat ($FN = 2$), yang mengindikasikan bahwa data sintetis hasil pembentukan SMOTE berpotensi mengenalkan sedikit noise pada ruang fitur.



Gambar 5. Grafik Kurva Pelatihan (Loss dan Accuracy) Model YOLOv12 pada Skenario Tanpa SMOTE untuk Optimizer (a) Adam; (b) AdamW; (c) SGD; (d) RMSProp



Gambar 6. Grafik Kurva Pelatihan (Loss dan Accuracy) Model YOLOv12 pada Skenario Menggunakan SMOTE untuk Optimizer (a) Adam; (b) AdamW; (c) SGD; (d) RMSProp

Dinamika konvergensi dan proses pembelajaran (learning behavior) keempat optimizer selama 100 epoch dapat diamati melalui perbandingan kurva pelatihan (loss dan metrics/accuracy_top1) pada Gambar 5 (tanpa SMOTE) dan Gambar 6 (menggunakan SMOTE):

Pada optimizer Adam, skenario tanpa SMOTE (Gambar 5) menunjukkan kurva metrics/accuracy_top1 yang mengalami fluktuasi cukup lebar dan relatif tertahan di kisaran 80%–88%. Namun, setelah penerapan SMOTE (Gambar 6), kurva akurasi Adam menunjukkan peningkatan progresif yang stabil dan konsisten melampaui rentang 90% hingga mendekati 95% di epoch akhir, disertai penurunan val/loss yang meluruh dengan cepat dan stabil tanpa lonjakan berlebih.

Sementara itu, pada AdamW, penerapan SMOTE mengubah performa penurunan train/loss menjadi sangat linier dan curam hingga mencapai rentang nilai terendah di akhir epoch (~0,20). Kurva metrics/accuracy_top1 pada Gambar 6 juga menunjukkan peningkatan tajam

sejak 25 epoch awal, meskipun sedikit penurunan konvergensi terjadi di epoch akhir akibat interaksi antara weight decay dan sampel sintetis tambahan.

Di sisi lain, kurva train/loss untuk SGD pada skenario SMOTE (Gambar 6) memperlihatkan penurunan yang sangat mulus dari 0,70 hingga mendekati 0,20. Peningkatan tren accuracy_top1 pada SGD juga berlangsung secara stabil tanpa fluktuasi drastis, yang menegaskan karakteristik kestabilan SGD ketika dihadapkan pada distribusi sampel data latih yang homogen.

Adapun pada RMSProp, kedua skenario (Gambar 5 & 6) secara konsisten menunjukkan pola val/loss yang sempat melonjak tinggi pada awal epoch sebelum akhirnya meluruh tajam mendekati nol. Kurva accuracy_top1 RMSProp memperlihatkan fluktuasi adaptif yang sangat intensif pada 40 epoch awal sebelum akhirnya terstabilkan dan terkonvergensi menuju puncak akurasi.

Dari perspektif efisiensi komputasi, durasi pelatihan rata-rata per epoch dipengaruhi secara langsung oleh penambahan jumlah sampel data akibat proses pembentukan data sintetis SMOTE. Penggunaan SMOTE menyebabkan peningkatan waktu pelatihan sebesar 8 hingga 15 detik per epoch di seluruh varian optimizer. Pada skenario tanpa SMOTE, AdamW mencatatkan waktu pelatihan tercepat sebesar 85,382 detik/epoch, sedangkan pada skenario dengan SMOTE, RMSProp menjadi optimizer paling efisien dengan durasi 98,695 detik/epoch. Secara keseluruhan, kombinasi YOLOv12 dengan optimizer Adam dan teknik SMOTE terbukti menjadi konfigurasi yang paling optimal untuk menghasilkan deteksi cacat PCB yang presisi dengan keseimbangan nilai Presisi (95,496%) dan Recall (95,385%) yang sangat baik.

KESIMPULAN DAN REKOMENDASI

Berdasarkan hasil pengujian dan analisis perbandingan optimizer (Adam, AdamW, SGD, dan RMSProp) pada model YOLOv12 untuk klasifikasi cacat etching PCB, dapat disimpulkan bahwa penerapan Synthetic Minority Over-sampling Technique (SMOTE) terbukti secara signifikan meningkatkan kinerja klasifikasi pada kondisi dataset yang tidak seimbang. Kombinasi YOLOv12 dengan optimizer Adam dan teknik SMOTE menghasilkan kinerja terbaik secara keseluruhan, dengan capaian akurasi sebesar 95.385%, presisi 95.496%, recall 95.385%, dan F1-Score 95.415%. Kenaikan performa terdistribusi paling tinggi pada optimizer Adam, yaitu sebesar +6.154% pada akurasi dibandingkan skenario

tanpa SMOTE. Di sisi lain, pada kondisi dataset asli tanpa penanganan imbalance, RMSProp mencatatkan ketahanan paling unggul dengan akurasi 93.846%. Dari sudut pandang efisiensi komputasi, penggunaan SMOTE meningkatkan durasi pelatihan rata-rata sebesar 8 hingga 15 detik/epoch, di mana RMSProp memberikan waktu pelatihan paling efisien pada skenario SMOTE dengan rata-rata 98.695 detik/epoch. Secara keseluruhan, integrasi SMOTE dan optimizer Adam terbukti paling efektif untuk meningkatkan presisi identifikasi cacat jalur PCB pada arsitektur YOLOv12. Untuk penelitian selanjutnya, disarankan melakukan penyesuaian hiperparameter (hyperparameter tuning) tingkat lanjut pada nilai weight decay AdamW dan learning rate RMSProp untuk mengeksplorasi potensi konvergensi yang lebih optimal.

REFERENSI

1. Alwaidh, A., Sharp, M., & French, P. (2014). Laser processing of rigid and flexible PCBs. *Optics and Lasers in Engineering*, 58, 109–113. <https://doi.org/10.1016/j.optlaseng.2014.02.006>
2. Basniak, R., & Catapan, M. F. (2012). Design of a PCB milling machine. *ABCM Symposium Series in Mechatronics*, 5, 1339–1348. https://abcm.org.br/symposium-series/SSM_Vol5/Section_VIII_Sensors_and_Actuators/10991.pdf
3. Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357. <https://doi.org/10.1613/jair.953>
4. Direktorat Jenderal Bea dan Cukai. (2020, August 28). *Official website Direktorat Jenderal Bea dan Cukai*. <https://www.beacukai.go.id/berita/mengenal-pcb-board.html>
5. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
6. Hinton, G., Srivastava, N., & Swersky, K. (2012). *Lecture 6.5—RMSProp: Divide the gradient by a running average of its recent magnitude* (pp. 26–31). Coursera: Neural Networks for Machine Learning.
7. Khan, A. A., Chaudhari, O., & Chandra, R. (2024). A review of ensemble learning and data augmentation models for class imbalanced problems: Combination, implementation and evaluation. *Expert Systems with Applications*, 244, 122778. <https://doi.org/10.1016/j.eswa.2023.122778>

-
8. Kingma, D. P., & Ba, J. (2017). *Adam: A method for stochastic optimization*. arXiv. <https://arxiv.org/abs/1412.6980>
 9. Market Growth Reports. (2025). *Printed circuit boards (PCBs) market size, share, growth, and industry analysis, by type (single-sided, double-sided, multi-layer), by application (consumer electronics, aerospace and defense, automotive, healthcare, others), regional insights and forecast to 2033*. <https://www.marketgrowthreports.com/market-reports/printed-circuit-boards-pcbs-market-110583>
 10. P. S., M., & R. S., N. (2014). PCB defect detection, classification and localization using mathematical morphology and image processing tools. *International Journal of Computer Applications*, 87(9), 40–45. <https://doi.org/10.5120/15240-3782>
 11. Robbins, H., & Monro, S. (1951). A stochastic approximation method. *The Annals of Mathematical Statistics*, 22(3), 400–407. <https://doi.org/10.1214/aoms/1177729586>
 12. Ruder, S. (2017). *An overview of gradient descent optimization algorithms*. arXiv. <https://arxiv.org/abs/1609.04747>
 13. Sapkota, R., Flores-Calero, M., Qureshi, R., Badgujar, C., Nepal, U., Poullose, A., Zeno, P., Vaddevolu, U. B. P., Khan, S., Shoman, M., Yan, H., & Karkee, M. (2025). YOLO advances to its genesis: A decadal and comprehensive review of the You Only Look Once (YOLO) series. *Artificial Intelligence Review*, 58(9), 274. <https://doi.org/10.1007/s10462-025-11253-3>
 14. Schmidt, R. M., Schneider, F., & Hennig, P. (2021). *Descending through a crowded valley: Benchmarking deep learning optimizers*. arXiv. <https://arxiv.org/abs/2007.01547>
 15. Tian, Y., Ye, Q., & Doermann, D. (2025). *YOLOv12: Attention-centric real-time object detectors*. arXiv. <https://arxiv.org/abs/2502.12524>