

# Kualitas Dataset dan Strategi YOLO untuk Deteksi Cacat Jahitan Berukuran Kecil: Tinjauan Literatur Sistematis menuju Inspeksi Bordir *Real-Time*

Eko Ari Wibowo<sup>1</sup>, Widyastuti<sup>2</sup>, Lazuardi Fatahillah Hamdi<sup>3</sup>, Eka Samsul Ma'arif<sup>4</sup>

<sup>1,2</sup> Prodi Teknik Industri, Fakultas Sains dan Humaniora, Universitas Muhammadiyah Gombong  
Jl. Yos Sudarso No. 461, Kebumen, Jawa Tengah, 54412

Email: [ekoariwibowo@unimugo.ac.id](mailto:ekoariwibowo@unimugo.ac.id), [widyastuti@unimugo.ac.id](mailto:widyastuti@unimugo.ac.id)

<sup>3</sup> Prodi Teknologi Informasi, Fakultas Sains dan Humaniora, Universitas Muhammadiyah Gombong  
Jl. Yos Sudarso No. 461, Kebumen, Jawa Tengah, 54412

Email: [lazuardi@unimugo.ac.id](mailto:lazuardi@unimugo.ac.id)

<sup>4</sup> Prodi Teknik Elektro, Fakultas Teknik, Universitas Muhammadiyah Jakarta  
Jl. Cempaka Putih Tengah No. 27, Jakarta Pusat, DKI Jakarta, 10510, Indonesia

Email: [eka.samsul@umj.ac.id](mailto:eka.samsul@umj.ac.id)

## ABSTRAK

Inspeksi cacat bordir berbasis *computer vision* memerlukan dataset yang konsisten dan model yang mampu mendeteksi pola kecil, tipis, memanjang, serta berkontras rendah. Penelitian ini menyintesis praktik kualitas dataset dan strategi *You Only Look Once* (YOLO) untuk deteksi cacat tekstil sebagai dasar pengembangan inspeksi bordir *real-time*. Tinjauan dilakukan berdasarkan *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) 2020. Pencarian Scopus menghasilkan 284 dokumen dan menyisakan 82 dokumen setelah penyaringan tahun, jenis dokumen, bahasa, dan akses terbuka. Sebanyak 61 artikel dinilai berdasarkan naskah lengkap, dan 34 studi primer disertakan dalam sintesis, sedangkan sumber lain yang relevan digunakan sebagai bukti pendukung. Data diekstraksi berdasarkan sumber dataset, akuisisi, anotasi, pembagian data, augmentasi, arsitektur YOLO, strategi *small-object detection*, dan kinerja komputasi. Hasil menunjukkan dominasi pendekatan *model-centric* berupa *attention mechanism*, *multi-scale feature fusion*, *lightweight architecture*, *loss function optimization*, operator konvolusi khusus, dan *small-object detection head*. Sebaliknya, definisi operasional kelas, pedoman anotasi *bounding box*, *quality control* label, metadata akuisisi, dan pencegahan *data leakage* masih terbatas. Kerangka terintegrasi diusulkan untuk menghubungkan definisi cacat, akuisisi, kurasi, anotasi, pengembangan YOLO, serta validasi akurasi, kecepatan, dan *robustness* sebagai landasan penelitian cacat bordir pada Usaha Mikro, Kecil, dan Menengah (UMKM).

**Kata kunci:** anotasi dataset; cacat jahitan; inspeksi bordir; kualitas dataset; *small-object detection*; YOLO.

## ABSTRACT

*Computer vision-based embroidery defect inspection requires a consistent dataset and a model capable of detecting small, thin, elongated, and low-contrast patterns. This study synthesizes dataset quality practices and You Only Look Once (YOLO) strategies for textile defect detection as a foundation for developing real-time embroidery inspection. The review was conducted based on the Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA) 2020. The Scopus search identified 284 documents and retained 82 documents after filtering by publication year, document type, language, and open-access status. A total of 61 articles were assessed based on full-text review, and 34 primary studies were included in the synthesis, while other relevant sources were used as supporting evidence. Data were extracted based on dataset sources, image acquisition, annotation, data partitioning, augmentation, YOLO architecture, small-object detection strategies, and computational performance. The results show that the reviewed studies were dominated by model-centric approaches, including attention mechanism, multi-scale feature fusion, lightweight architecture, loss function optimization, specialized convolution operators, and small-object detection head. In contrast, operational class definitions, bounding box annotation guidelines, label quality control, acquisition metadata, and data leakage prevention remain limited. An integrated framework is proposed to connect defect definition, acquisition, curation, annotation, YOLO development, and accuracy, speed, and robustness validation as a foundation for embroidery defect research in Micro, Small, and Medium Enterprises (MSMEs).*

**Keywords:** dataset annotation; dataset quality; embroidery inspection; *small-object detection*; stitch defect; YOLO.

## Pendahuluan

Inspeksi cacat tekstil berbasis *Artificial Intelligence* (AI) dan *computer vision* berkembang sebagai respons terhadap keterbatasan inspeksi manual yang subjektif dan lambat. Namun, pada konteks bordir, persoalan utama tidak hanya terletak pada akurasi model, tetapi juga pada konsistensi dataset, definisi kelas cacat, kualitas anotasi, dan kesiapan sistem real-time di lingkungan produksi [1], [2], [3].

Cacat tekstil sering berukuran kecil, berkontras rendah, atau memiliki rasio aspek ekstrem. *Priori Anchor Convolutional Neural Network* (PRAN-Net) menggunakan *Feature Pyramid Network* (FPN) dan *anchor* berbasis *ground truth bounding box* untuk mempertahankan detail cacat kecil [4]. Jaringan CNN multiskala juga mampu mencapai lebih dari 29 *frames per second* (FPS) sekaligus menangani cacat berukuran kecil [5]. Pendekatan segmentasi berbasis *Generative Adversarial Network* (GAN) menegaskan bahwa cacat kecil dan lemah memerlukan rekonstruksi, penguatan, dan model ringan [6]. Sementara itu, fusi multispektral, adaptasi terhadap pencahayaan, dan penggabungan CNN-*Mamba* memperlihatkan pentingnya *robustness* pada kondisi produksi, jumlah label terbatas, serta kemampuan mempertahankan fitur frekuensi tinggi [7], [8], [9].

*You Only Look Once* (YOLO) banyak digunakan karena melakukan klasifikasi dan lokalisasi dalam satu tahap sehingga sesuai untuk inspeksi *real-time*. Namun, performa arsitektur tidak dapat dipisahkan dari kualitas data. Pada bordir, benang normal dan benang cacat berada pada struktur visual yang sama. Sehingga, kesalahan definisi kelas atau anotasi dapat menghasilkan *bounding box* yang terlalu longgar, label hilang, kelas tumpang tindih, dan distribusi data yang tidak representatif.

Sejumlah studi telah memberi perhatian pada aspek dataset. Carrilho et al. mengembangkan dataset industri dengan keragaman warna, tekstur, dan jenis cacat [10]. Nasim et al. menggunakan citra yang diperoleh langsung dari proses manufaktur [11], sedangkan YMaskNet melibatkan ahli domain, penyeimbangan kelas, dan pembagian data latih-validasi-uji [12]. Studi *broken stitch* menunjukkan pentingnya definisi visual, cacat sintetis, variasi rotasi, dan uji pada perangkat komputasi murah [13]. Bukti tersebut relevan untuk merumuskan protokol dataset cacat bordir sebelum melakukan optimasi model. *Research gap* berdasarkan literatur yaitu belum terintegrasinya dua aspek penting, yaitu protokol kualitas dataset dan strategi YOLO untuk cacat jahitan berukuran sangat kecil, tipis, memanjang, serta berkontras rendah. Sebagian studi menekankan peningkatan arsitektur model, sedangkan aspek definisi kelas, pedoman *bounding box*, *quality control* label, metadata akuisisi, dan validasi lintas kondisi produksi belum dibahas sebagai alur yang utuh. Celah ini penting karena cacat bordir sering berada pada struktur visual yang mirip dengan benang normal, sehingga kesalahan anotasi dapat langsung menurunkan *precision*, *recall*, dan kemampuan generalisasi model.

Konteks Usaha Mikro, Kecil, dan Menengah (UMKM) juga mensyaratkan teknologi yang tidak hanya akurat, tetapi ekonomis, mudah dioperasikan, dan aman. Prinsip tersebut telah diterapkan pada pengembangan sistem deteksi berbasis sensor optik berbiaya rendah [14]. Selain itu, rancangan alat sektor informal yang menekankan kebutuhan pengguna, keselamatan, dan efisiensi [15], [16]. Dengan demikian, kesiapan data, model, perangkat, dan konteks pengguna perlu dianalisis sebagai satu kesatuan.

Kontribusi praktis tinjauan ini diarahkan pada kebutuhan UMKM bordir, yaitu penyusunan protokol dataset yang mudah direplikasi, pemilihan strategi YOLO yang realistis untuk inspeksi *real-time*, peningkatan konsistensi identifikasi cacat, dan pengurangan ketergantungan pada inspeksi manual. Dengan demikian, hasil sintesis tidak hanya memetakan perkembangan metode, tetapi juga memberi dasar implementasi sistem inspeksi yang ekonomis dan operasional bagi produksi bordir skala kecil-menengah.

Tinjauan ini bertujuan menjawab tiga pertanyaan penelitian: (1) bagaimana karakteristik dataset serta praktik kurasi dan anotasinya; (2) strategi YOLO apa yang digunakan untuk mendeteksi cacat kecil, tipis, memanjang, dan berkontras rendah; serta (3) bagaimana akurasi, kecepatan, dan *robustness* sistem dievaluasi. Kontribusi akhirnya adalah kerangka kesiapan dataset dan model sebagai dasar formulasi protokol kurasi-anotasi dan perancangan inspeksi cacat bordir *real-time*.

## Metode Penelitian

### Strategi pencarian

Tinjauan literatur sistematis mengikuti panduan *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) 2020 [17]. Pendekatan berbasis pertanyaan penelitian, kriteria inklusi-eksklusi, dan sintesis terstruktur juga telah digunakan pada tinjauan teknologi sensor [18]. Pencarian dilakukan pada Scopus melalui bidang judul, abstrak, dan kata kunci menggunakan kata kunci: *TITLE-ABS-KEY* ("*fabric defect*" OR "*textile defect*" OR "*sewing defect*" OR "*stitch defect*" OR "*thread defect*" OR "*embroidery defect*") AND (*YOLO* OR "*You Only Look Once*") AND (*dataset* OR *annotation* OR *labeling* OR *curation* OR "*small object*" OR "*tiny defect*" OR "*real-time*").

Pencarian awal menghasilkan 284 dokumen. Filter tahun 2017-2026 tidak mengurangi jumlah dokumen karena tahun publikasi aktual yang tersedia adalah 2019-2026. Pembatasan menjadi artikel dan *conference*

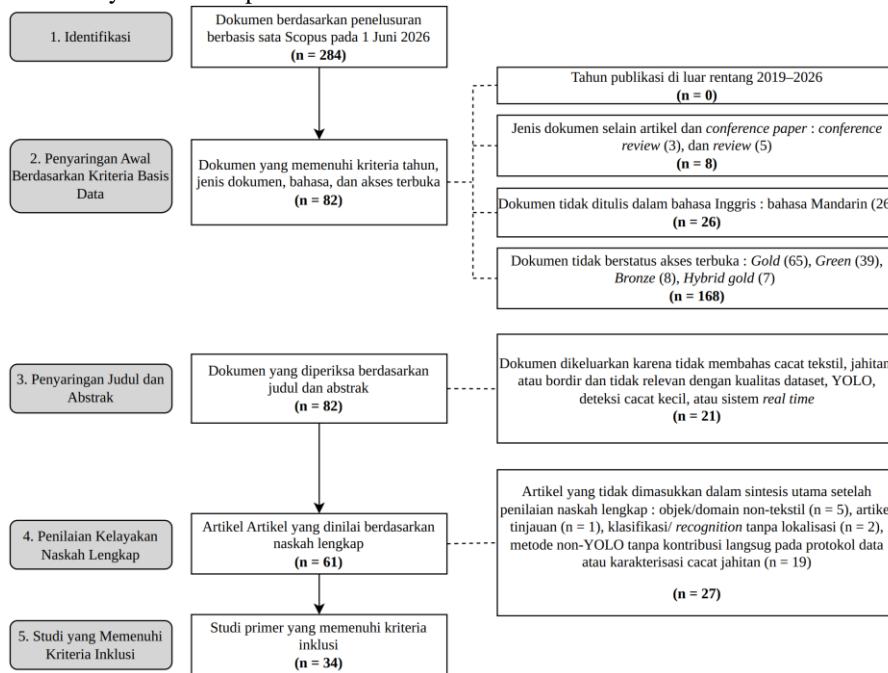
paper menyisakan 276 dokumen, bahasa Inggris menyisakan 250 dokumen, dan filter *all open access* menyisakan 82 dokumen.

**Kriteria seleksi dan ekstraksi data**

**Tabel 1.** Kriteria inklusi dan eksklusi

Kriteria	Penjelasan
Inklusi	Objek berupa cacat kain, tekstil, jahitan, atau bordir; YOLO sebagai metode utama; atau kontribusi langsung pada penggunaan dataset dan karakterisasi cacat jahitan.
Inklusi	Melaporkan sumber data, prosedur eksperimen, strategi anotasi/augmentasi, metrik deteksi, atau informasi kesiapan sistem <i>real-time</i> .
Inklusi	Artikel atau <i>conference paper</i> berbahasa Inggris, terbit 2017-2026, dan tersedia melalui filter <i>open access</i> .
Eksklusi	Artikel dengan objek kajian non-tekstil, seperti <i>mechanical thread defect</i> dan <i>cocoon defect</i> , dikeluarkan. Artikel tinjauan ( <i>review article</i> ) tidak dihitung sebagai studi primer, tetapi dapat digunakan sebagai sumber pendukung.
Eksklusi	Klasifikasi cacat tanpa lokalisasi, atau metode non-YOLO yang tidak memberi kontribusi langsung terhadap protokol data atau karakterisasi cacat jahitan.
Eksklusi	Data dan prosedur eksperimen tidak memadai untuk menjawab pertanyaan penelitian.

Sebanyak 82 dokumen disaring berdasarkan judul dan abstrak. Dua puluh satu dokumen dikeluarkan, sehingga 61 file naskah lengkap dikumpulkan. Dua puluh tujuh artikel tidak dimasukkan ke dalam sintesis primer, tetapi sumber yang masih relevan digunakan untuk memperkuat pendahuluan, perbandingan metode, dan pembahasan. Sebanyak 34 studi primer memenuhi kriteria akhir.



**Gambar 1.** Diagram Alir Proses Seleksi Artikel Berdasarkan PRISMA 2020

Ekstraksi dilakukan pada delapan elemen: objek dan kelas cacat; sumber serta ukuran dataset; kondisi akuisisi; anotasi dan pelabelan; pembagian data; augmentasi atau preprocessing; arsitektur serta strategi YOLO; dan metrik akurasi-komputasi. Sintesis dilakukan secara tematik. Satu studi dapat dikodekan ke lebih dari satu kategori strategi. Frekuensi strategi dihitung pada 32 studi berbasis YOLO, sedangkan dua studi non-YOLO dipertahankan karena memberikan bukti langsung mengenai pembangunan dataset industri dan karakter *broken stitch*.

Validitas ekstraksi data dijaga melalui pembacaan berulang terhadap judul, abstrak, dan naskah lengkap, kemudian setiap artikel dikodekan berdasarkan elemen yang sama. Ketidakesesuaian antara fokus artikel dan kriteria inklusi diantisipasi dengan penempatan artikel sebagai studi primer, sumber pendukung, atau artikel yang dikeluarkan. Potensi bias seleksi dikurangi dengan penggunaan kata kunci yang eksplisit, pencatatan alasan eksklusi, dan pemisahan antara studi YOLO utama dan studi non-YOLO yang hanya digunakan ketika

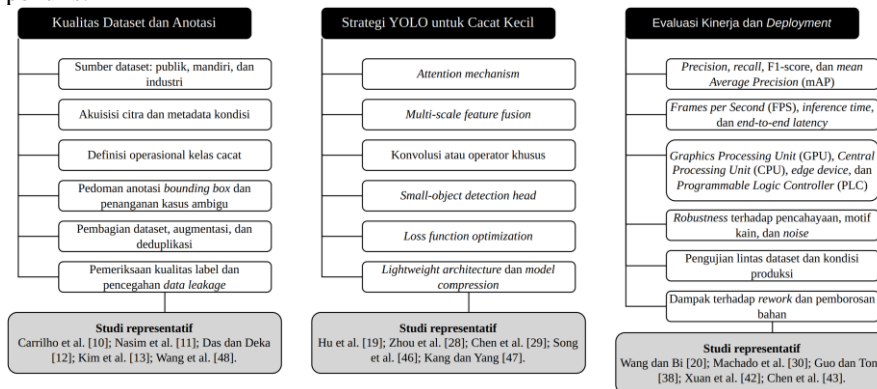
memberi kontribusi langsung terhadap dataset, anotasi, atau karakterisasi cacat jahitan. Meskipun demikian, penggunaan satu basis data dan filter *open access* tetap digunakan sebagai sumber bias cakupan.

## Hasil dan Pembahasan

### Klasifikasi fokus studi

Studi terpilih dapat dikelompokkan ke dalam tiga fokus yang saling berkaitan, yaitu kualitas dataset dan anotasi, strategi YOLO untuk mendeteksi cacat kecil, serta evaluasi kinerja dan *deployment system*. Pembagian ini menunjukkan bahwa kesiapan inspeksi bordir tidak cukup dinilai dari nilai akurasi model, tetapi harus ditelusuri sejak definisi kelas hingga validasi pada kondisi produksi.

Singkatan teknis yang digunakan selanjutnya meliputi *mean Average Precision (mAP)*, *frames per second (FPS)*, *Central Processing Unit (CPU)*, *Graphics Processing Unit (GPU)*, *Programmable Logic Controller (PLC)*, dan *quality control (QC)*. Modul utama mencakup *Contrast Limited Adaptive Histogram Equalization (CLAHE)*, *Adaptive Spatial Feature Fusion (ASFF)*, *Simple Parameter-Free Attention Module (SimAM)*, *Dilation-wise Residual (DWR)*, *Convolutional Block Attention Module (CBAM)*, *Large Separable Kernel Attention (LSKA)*, *Content-Aware ReAssembly of FEatures (CARAFE)*, *Multi-Proportion Spatial Attention Mechanism (MPAM)*, *Efficient Wise Intersection over Union (EWIoU)*, *Coordinate Attention (CA)*, *Squeeze-and-Excitation (SE)*, *Bidirectional Feature Pyramid Network (BiFPN)*, *Global Attention Mechanism (GAM)*, *Shuffle Attention (SA)*, *Polarized Self-Attention (PSA)*, *Small Object Detection Head (SOHead)*, dan *Information Gap Filling Strategy (IGFS)*. Nama varian model dan dataset lainnya dipertahankan sesuai penamaan asli penulis.



Gambar 2. Klasifikasi studi berdasarkan fokus kajian, topik utama, dan studi representatif

Tabel 2. Ringkasan studi primer

No.	Studi	Data/objek	Model/strategi	Kontribusi utama
1	Hu et al. (2025) [19]	Dataset mandiri; 6 kelas	YOLOv9s + dynamic snake convolution	Cacat halus/memanjang dan anotasi manual
2	Wang dan Bi (2026) [20]	Poliester industri; 2.512 citra	YOLO + PLC	Latensi end-to-end dan stabilitas 120 jam
3	Liu et al. (2022) [21]	Kain multikelas	YOLOv4 + SoftPool/CLAHE	Preprocessing dan akurasi-kecepatan
4	Luo et al. (2023) [22]	Tianchi	YOLO-SCD	Attention mechanism dan depthwise convolution
5	Wang et al. (2021) [23]	Industri; 3.946 citra	YOLOv5 + ASFF/Transformer	Mayoritas objek kecil; multi-scale feature fusion
6	Carrilho et al. (2024) [10]	Dataset industri beragam	Pembangunan dataset	Variasi kain, warna, cacat, dan benchmark
7	Ma et al. (2024) [24]	Industri + Tianchi	GSL-YOLOv8n	Ghost, SimAM, dan lightweight head
8	Sun et al. (2025) [25]	Seamless fabric; 4.184 citra	YOLOv8n + LSKA/CARAFE	Small-object layer dan kompleksitas rendah
9	Jin et al. (2025) [26]	TILDA + Tianchi	YOLOv8 + DySample/WIoU	Detail tepi dan sampel berkualitas rendah
10	Dharma et al. (2025) [27]	Tianchi; 22 kelas	Optimasi YOLOv8m	Augmentasi, threshold, loss, reproducibility

No.	Studi	Data/objek	Model/strategi	Kontribusi utama
11	Kim et al. (2022) [28]	Citra jahit normal/sintetis	CNN <i>feature map</i>	Definisi visual <i>broken stitch</i> dan perangkat murah
12	Zhou et al. (2025) [29]	Tianchi	DCFE-YOLO	<i>Dynamic snake convolution</i> dan <i>multi-scale feature fusion</i>
13	Chen et al. (2025) [30]	Dataset tekstil	YOLO-GCW	CBAM, WIoU, dan <i>Ghost</i> untuk <i>tiny defect</i>
14	Machado et al. (2025) [31]	Industri; dua kamera	YOLOv11 + Jetson	<i>Edge computing, logging, dan streaming</i>
15	Mao et al. (2025) [32]	Dataset kain	YOLOv8 + SimAM/DWR	<i>Small-target detection</i> dan <i>robustness</i>
16	Bao et al. (2025) [33]	Industri + TILDA + FDDS	FabricMamba-YOLOv8	Multiskala, <i>long-range</i> , dan efisiensi
17	Yu et al. (2024) [34]	Tianchi + ZJU-Leaper	FA-YOLO	<i>Detection head</i> tambahan, <i>attention mechanism</i> , dan ASFF
18	Huang et al. (2025) [35]	Tianchi + denim mandiri	FDDNet	Cacat halus/memanjang dan <i>global-local fusion</i>
19	Lv et al. (2024) [36]	Hiperspektral <i>nonwoven</i>	LL-YOLOv5	Cacat kecil dan benda asing sewarna
20	Ji dan Di (2024) [37]	ZJU-Leaper + Tianchi	YOLOv7 + MPAM	<i>Attention mechanism, memory fusion, dan EWIoU</i>
21	Xu et al. (2024) [38]	Cacat jahitan pakaian	YOLOv8-FPCA	<i>Broken thread, thread end, dan Focal Loss</i>
22	Nasim et al. (2024) [39]	Dataset manufaktur nyata	YOLOv8n	Kain polos/bermotif dan citra produksi
23	Guo dan Tong (2026) [40]	TILDA + DAGM	IR-YOLOv7-Tiny	HSV, DWT, interferensi, dan <i>deployment</i>
24	Jing et al. (2020) [41]	Dataset kain	<i>Improved YOLOv3</i>	<i>K-means anchor</i> dan skala deteksi
25	Kang (2024) [42]	Kain polos + bermotif	YOLOv5s ringan	CBAM, <i>feature enhancement</i> , dan 102 FPS
26	Jin dan Niu (2021) [43]	Tianchi + TILDA	YOLOv5 <i>teacher-student</i>	Keterbatasan sampel dan <i>knowledge distillation</i>
27	Xuan et al. (2026) [44]	Dataset kain	<i>Improved YOLOv9</i>	LSKA, BiFPN, Shape-IoU, dan 55,8 FPS
28	Chen et al. (2025) [45]	3 dataset tekstil	SDLS-YOLO	4,8 MB, 185 FPS, dan loss berbasis bentuk
29	Su et al. (2023) [46]	<i>Digital printing</i> mandiri	YOLOX ringan	SE <i>attention</i> dan cacat kecil
30	Lu et al. (2024) [47]	Dataset tekstil	YOLO-BGS	BiFPN, GAM/SA, dan pengurangan <i>waste</i>
31	Song et al. (2025) [48]	Tianchi; 4.774 citra	DA-YOLOv8s	DCNv2, PSA, SOHead, dan 257 FPS
32	Kang dan Yang (2026) [49]	Tianchi + ZJU-Leaper	FD-YOLO/YOLOv11n	<i>Cross-scale fusion</i> dan <i>lightweight head</i>
33	Wang et al. (2024) [50]	NEU-DET + kain mandiri	YOLO-DD	Transformer, IGFS, dan pencegahan data <i>leakage</i>
34	Das dan Deka (2025) [12]	YMask; 4.500 citra	YOLOv4-MobileNetV2-BiFPN	Ahli domain, kelas seimbang, dan <i>train-val-test split</i>

### Kualitas dataset, anotasi, dan kurasi

Dataset publik yang paling sering digunakan adalah Tianchi, TILDA, ZJU-Leaper, FDDS, dan DAGM. Penggunaan dataset publik memudahkan perbandingan, tetapi dapat mendorong optimasi berulang pada domain yang sama. Sebaliknya, dataset mandiri dan industri lebih dekat dengan kondisi implementasi, seperti citra produksi nyata [39], poliester industri [20], digital printing [46], jahitan pakaian [38], dan *handloom* [12].

Pelaporan data umumnya memuat jumlah citra, kelas, dan pembagian data, tetapi definisi operasional kelas dan aturan anotasi jarang dijelaskan secara rinci. Hu *et al.* menyebut anotasi manual berdasarkan standar tekstil [19], studi sistem *Programmable Logic Controller* (PLC) menggunakan label manual dan pembobotan kelas

[20], sedangkan YMaskNet melibatkan ahli domain [12]. Tidak ada studi primer yang melaporkan ukuran kesepakatan antar-*anotator*, sehingga pengaruh *noise* label terhadap performa model sulit diisolasi.

Augmentasi yang digunakan meliputi rotasi, *flipping*, *resizing*, blur, penyesuaian kecerahan-kontras, Mosaic, MixUp, dan cacat sintetis [12], [27], [28], [43], [50]. Augmentasi perlu dilakukan setelah pemisahan data. Dari korpus primer, hanya YOLO-DD yang secara eksplisit menyatakan pembagian dataset sebelum augmentasi untuk mencegah data leakage [50].

**Tabel 3.** Sintesis praktik kualitas dataset dan implikasinya untuk bordir

Aspek	Praktik dominan	Kesenjangan	Implikasi protokol bordir
Sumber data	Dataset publik dominan; dataset industri meningkat	Kondisi produksi tidak selalu terwakili	Gabungkan data terkontrol dan data UMKM
Definisi kelas	Nama kelas dilaporkan, batas visual jarang dijabarkan	Risiko tumpang tindih <i>broken stitch/over-thread</i>	Gunakan definisi operasional dan contoh batas kelas
Akuisisi dan metadata	Kamera/pencahayaan hanya dilaporkan sebagian studi	Sulit mereplikasi variasi domain	Catat kamera, jarak, sudut, lux, kain, dan benang
Anotasi	Mayoritas <i>bounding box</i> manual atau label bawaan dataset	Pedoman <i>bounding box</i> dan <i>occlusion</i> belum konsisten	Susun pedoman anotasi per kelas
Pemeriksaan label	Tidak ada pelaporan <i>inter-annotator agreement</i>	Noise label tidak terukur	Lakukan <i>dual review</i> dan audit label
Pembagian data	Rasio acak 8:2 atau 7:2:1 umum	Risiko sampel serupa masuk ke subset berbeda	<i>Split</i> berbasis <i>batch</i> atau produk
Augmentasi	Rotasi, flip, blur, <i>brightness</i> , Mosaic/MixUp	Citra hasil augmentasi dapat tidak realistis	Validasi terhadap morfologi cacat
Data leakage	Satu studi menjelaskan pencegahan eksplisit	Performa dapat terlalu optimistis	Lakukan <i>split dataset</i> sebelum augmentasi
Robustness	Uji lintas kondisi masih terbatas	<i>Generalization gap</i>	Uji motif, warna, cahaya, sudut kamera, dan perangkat

Sintesis pada Tabel 3 menunjukkan bahwa kualitas dataset berkaitan langsung dengan keandalan model deteksi. Untuk memperjelas implikasi tersebut, Tabel 4 menyajikan risiko kualitas data, dampaknya terhadap performa model, dan rekomendasi pengendaliannya.

**Tabel 4.** Risiko kualitas data dan implikasinya terhadap performa model

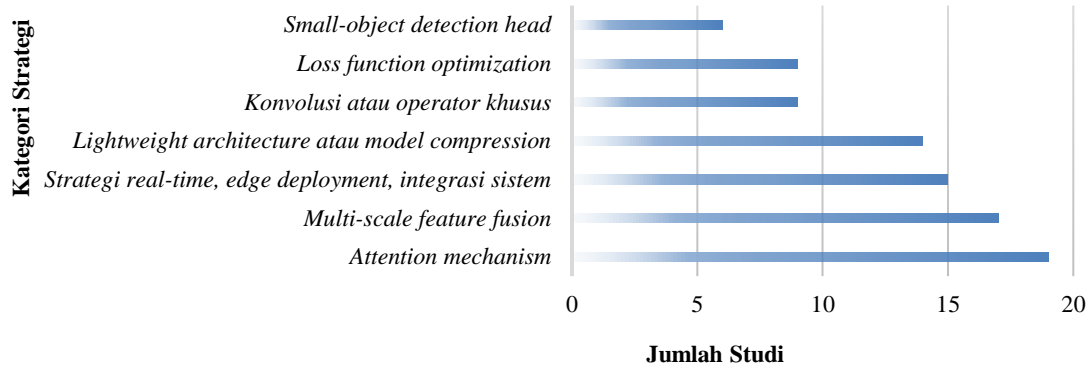
Risiko kualitas data	Implikasi terhadap performa model	Rekomendasi pengendalian
Definisi kelas cacat tidak operasional	Model sulit membedakan <i>broken stitch</i> , <i>over-thread</i> , dan variasi benang normal sehingga <i>false positive</i> dan <i>false negative</i> meningkat.	Susun definisi kelas, contoh visual, dan batas kasus ambigu sebelum anotasi.
Pedoman <i>bounding box</i> tidak konsisten	Ukuran dan posisi label tidak stabil, menyebabkan <i>localization error</i> dan penurunan mAP.	Gunakan pedoman <i>bounding box</i> per kelas serta audit label secara berkala.
Noise label dan label hilang	Model belajar dari target yang salah sehingga <i>recall</i> rendah pada cacat kecil dan tipis.	Terapkan <i>dual review</i> , <i>sampling audit</i> , dan revisi label pada citra bermasalah.
Data leakage akibat augmentasi sebelum <i>split</i>	Nilai akurasi, mAP, atau FPS readiness dapat terlalu optimistis dan tidak mencerminkan generalisasi.	Lakukan <i>split dataset</i> sebelum augmentasi dan pisahkan data berdasarkan <i>batch</i> atau produk.
Ketidakeimbangan kelas cacat	Kelas minoritas jarang terdeteksi, terutama cacat kecil yang jumlahnya terbatas.	Gunakan <i>class balancing</i> , augmentasi terkontrol, dan evaluasi per kelas.
Variasi akuisisi tidak terdokumentasi	Model sensitif terhadap perubahan pencahayaan, motif, sudut kamera, dan jenis kain.	Catat metadata akuisisi dan lakukan <i>robustness testing</i> pada variasi produksi.

### Strategi YOLO untuk mendeteksi cacat kecil dan memanjang

Sebagian besar studi masih berorientasi pada pengembangan model (*model-centric*). *Attention mechanism* mencakup SimAM, CBAM, CA, LSKA, SE, BRAttention, dan GAM. Mekanisme tersebut digunakan untuk menekan motif latar dan meningkatkan bobot fitur cacat.

*Multi-scale feature fusion* memanfaatkan FPN, PAN, BiFPN, dan ASFF. Untuk morfologi tipis dan memanjang, strategi yang paling relevan adalah *dynamic snake convolution*, *deformable convolution*, pemodelan global-lokal, dan jalur resolusi tinggi. *Small-object detection head* juga digunakan agar detail beberapa piksel tidak hilang akibat proses *downsampling*.

*Loss function optimization* mencakup *WIoU*, *Focal Loss*, *Shape-IoU*, dan *SDAF-IoU*. *Lightweight architecture* menggunakan *Ghost convolution*, *depthwise separable convolution*, *shared head*, dan *knowledge distillation*. Studi non-YOLO juga mendukung temuan tersebut: model RT-DETR-FFD menunjukkan bahwa *knowledge distillation* dapat mempertahankan 95,1% akurasi model guru dengan 26,1% parameternya [51], sedangkan segmentasi CNN-Mamba menekankan pentingnya keseimbangan fitur frekuensi rendah dan tinggi [9].



**Gambar 3.** Frekuensi kemunculan strategi pada 32 studi berbasis YOLO

*Attention mechanism* dan *multi-scale feature fusion* merupakan strategi yang paling sering dilaporkan. Namun, frekuensi tidak selalu identik dengan efektivitas pada bordir. Cacat jahitan memiliki bentuk yang sangat tipis dan dapat menyatu dengan benang normal. Sehingga, kombinasi operator peka bentuk, jalur resolusi tinggi, dan pedoman anotasi yang konsisten lebih penting daripada menambahkan banyak modul sekaligus.

Berdasarkan karakter cacat bordir, prioritas strategi tidak perlu dimulai dari model yang paling kompleks. Tahap pertama adalah membangun *baseline* YOLO ringan dengan *input* resolusi yang masih mampu mempertahankan detail benang. Tahap kedua adalah menambahkan jalur resolusi tinggi, *small-object detection head*, atau *multi-scale feature fusion* untuk menjaga fitur cacat kecil. Tahap ketiga adalah memilih *attention mechanism* seperti *dynamic/deformable convolution* hanya jika terbukti meningkatkan *recall* pada *broken stitch* dan *over-thread*. Tahap terakhir adalah *lightweight architecture*, *model compression*, dan *edge deployment* agar model tetap memenuhi kebutuhan *latency* pada produksi UMKM.

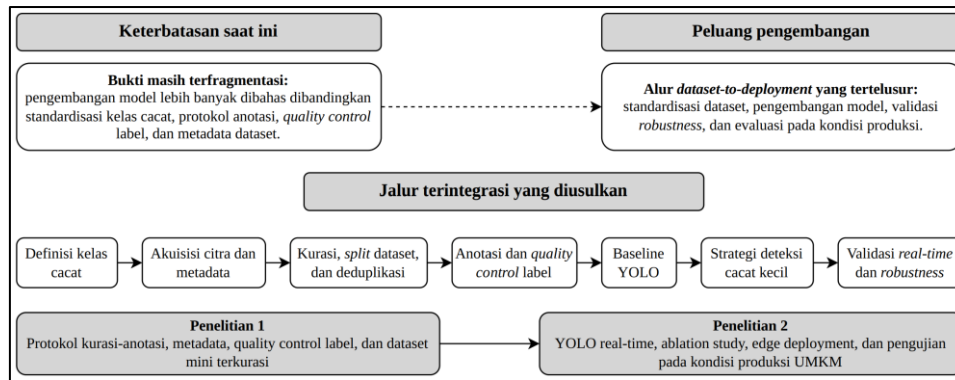
### **Evaluasi real-time performance dan robustness**

Nilai FPS antarstudi tidak dapat dibandingkan langsung karena perbedaan resolusi, perangkat, *batch*, dan tahapan yang diukur. Sistem PLC mengukur rata-rata pemrosesan sekitar 315 ms per *frame* pada *Central Processing Unit* (CPU) dan latensi penghentian *end-to-end* sekitar 420 ms selama 120 jam operasi [20]. Sistem YOLOv11 pada NVIDIA Jetson Orin Nano menambahkan multi-kamera, pencatatan hasil, *Message Queuing Telemetry Transport* (MQTT), dan *video streaming* [31]. Studi lain melaporkan 102 FPS [42], 185 FPS [45], dan 257,38 FPS [48]; angka tersebut harus dibaca bersama perangkat, resolusi, dan alur sistem. Agar evaluasi *real-time* lebih dapat dibandingkan, *benchmark* sebaiknya melaporkan minimal lima komponen: resolusi input, perangkat inferensi, *batch size*, waktu *preprocessing-inference-postprocessing*, dan *latency end-to-end* dari kamera hingga keputusan inspeksi. Selain FPS, pengujian perlu menyajikan *precision*, *recall*, mAP, ukuran model, konsumsi memori, dan skenario produksi yang digunakan. Untuk UMKM bordir, *benchmark* yang lebih relevan adalah pengujian pada beberapa motif kain, warna benang, intensitas cahaya, sudut kamera, serta kecepatan pergerakan material, bukan hanya pengujian pada data uji acak.

*Robustness* terhadap pencahayaan, motif, *noise*, dan domain baru lebih jarang diuji daripada akurasi pada pembagian data acak. IR-YOLOv7-Tiny menggabungkan ruang warna *Hue-Saturation-Value* (HSV) dan *Discrete Wavelet Transform* (DWT) untuk mengurangi gangguan pencahayaan dan interferensi [40]. FAD-enhanced tracking menguji *micro-defect* pada kondisi buruk dan kecepatan industri [7], sedangkan sistem robot kolaboratif menegaskan perlunya integrasi kamera, gerakan, sensor, dan keselamatan operator [52]. Segmentasi Deep-CRF dan MSC-DeepLabV3+ juga menunjukkan pentingnya akurasi *boundary* untuk cacat tipis dan struktur seam [53], [54].

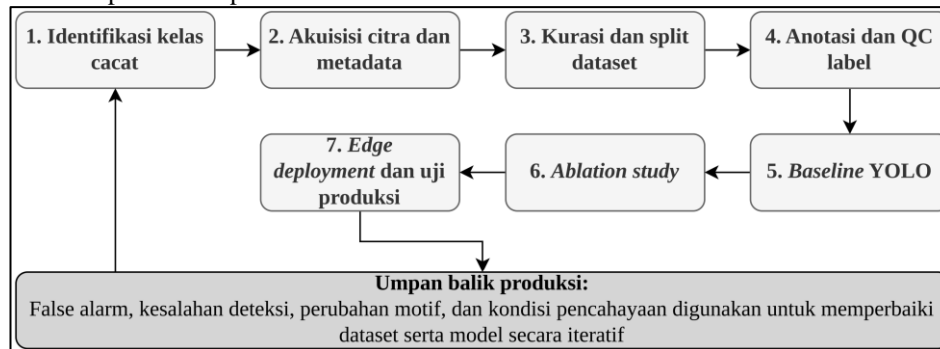
### **Kerangka kesiapan dataset dan model untuk inspeksi bordir**

Sintesis memperlihatkan bahwa standarisasi data perlu mendahului optimasi model. Tahap pertama adalah menetapkan definisi operasional *broken stitch* dan *over-thread*, termasuk batas objek, kasus parsial, dan kondisi ambigu. Tahap berikutnya mencakup akuisisi terkontrol, pencatatan metadata, kurasi, deduplikasi, pembagian berbasis *batch*, anotasi dengan pedoman *bounding box*, dan *quality control* label. Setelah itu, *baseline* YOLO dibangun sebelum melakukan *ablation study* terhadap *attention mechanism*, *multi-scale feature fusion*, operator khusus, dan *loss function*.



**Gambar 4.** Kerangka terintegrasi dari keterbatasan saat ini menuju inspeksi cacat bordir *real-time*

Kerangka tersebut menghubungkan dua penelitian lanjutan. Penelitian pertama menghasilkan protokol kurasi-anotasi, metadata, *quality control label*, dan dataset mini terkurasi. Penelitian kedua menggunakan dataset yang sama untuk membangun *baseline YOLO*, menguji strategi deteksi cacat kecil, melakukan *ablation study*, serta memvalidasi sistem pada variasi motif, warna kain, warna benang, intensitas cahaya, sudut kamera, kecepatan material, dan perangkat inferensi. Pemisahan ini mencegah hasil pengembangan arsitektur tertutup oleh masalah kualitas data dan meningkatkan keterlacakan hasil. Agar protokol lebih mudah diterapkan, Gambar 5 merangkum alur implementasi pada UMKM bordir.



**Gambar 5.** Alur implementasi protokol dataset dan YOLO pada UMKM bordir

Alur dimulai dari identifikasi jenis cacat yang sering muncul di lini produksi, akuisisi citra dengan metadata, kurasi dan split dataset, anotasi serta *quality control label*, pelatihan *baseline YOLO*, optimasi melalui *ablation study*, hingga *edge deployment*. Umpan balik dari produksi digunakan untuk memperbaiki dataset dan model secara iteratif.

### Keterbatasan

Tinjauan menggunakan satu basis data dan menerapkan filter *open access* pada tahap awal, sehingga artikel berbayar yang relevan dapat terlewat. Heterogenitas dataset, perangkat, resolusi, dan metrik menghalangi meta-analisis kuantitatif. Sebagian artikel tahun 2026 juga masih memiliki jejak sitasi terbatas. Oleh karena itu, hasil disajikan sebagai sintesis tematik dan pemetaan praktik, bukan peringkat absolut antar-model. Keterbatasan tersebut menunjukkan perlunya penelitian lanjutan yang menguji model lintas domain, lintas motif, dan lintas perangkat inferensi. Dataset bordir perlu divalidasi pada variasi warna kain, warna benang, kepadatan motif, pencahayaan, dan konfigurasi kamera yang berbeda. Selain itu, evaluasi pada perangkat *edge* perlu membandingkan akurasi, *latency end-to-end*, stabilitas operasi, dan biaya implementasi agar kesimpulan lebih relevan untuk UMKM.

### Simpulan

Literatur deteksi cacat tekstil bergerak menuju model YOLO yang lebih sensitif terhadap cacat kecil, lebih ringan, dan lebih siap digunakan secara *real-time*. Strategi dominan adalah *attention mechanism*, *multi-scale feature fusion*, *lightweight architecture*, operator konvolusi khusus, *loss function optimization*, dan *small-object detection head*. Strategi tersebut relevan untuk *broken stitch* dan *over-thread*, tetapi keberhasilannya bergantung pada kualitas dataset. Bukti yang tersedia menunjukkan bahwa definisi kelas, pedoman anotasi *bounding box*, metadata akuisisi, *quality control label*, pencegahan data *leakage*, dan *robustness testing* masih tertinggal dibandingkan modifikasi model. Penelitian bordir sebaiknya dimulai dari protokol data terstandar, dilanjutkan

dengan *baseline* YOLO, *ablation study*, serta pengujian *end-to-end* pada kondisi produksi UMKM. Kerangka yang diusulkan menjadi dasar langsung bagi formulasi protokol kurasi-anotasi dan perancangan sistem inspeksi *bordir real-time*. Secara praktis, sistem yang dikembangkan dari kerangka ini diharapkan dapat mempercepat inspeksi, meningkatkan konsistensi keputusan kualitas, dan mengurangi kesalahan manual dalam identifikasi cacat jahitan pada produksi bordir UMKM.

### Daftar Pustaka

- [1] P. Guo, Y. Liu, Y. Wu, R. H. Gong, and Y. Li, "Intelligent Quality Control of Surface Defects in Fabrics: A Comprehensive Research Progress," *IEEE Access*, vol. 12, pp. 63777–63808, 2024, doi: 10.1109/ACCESS.2024.3396053.
- [2] M. S and A. P.u, "Comparative Analysis of Suitability of Deep Learning Models in Quality Assurance of Fabrics," *International Research Journal of Multidisciplinary Technovation*, pp. 41–57, Jul. 2025, doi: 10.54392/irjmt2544.
- [3] H. Lin, D. Cai, Z. Xu, J. Wu, L. Sun, and H. Jia, "Fabric4show: real-time vision system for fabric defect detection and post-processing," *Vis. Intell.*, vol. 2, no. 1, p. 13, Jun. 2024, doi: 10.1007/s44267-024-00047-w.
- [4] P. Peng, Y. Wang, C. Hao, Z. Zhu, T. Liu, and W. Zhou, "Automatic Fabric Defect Detection Method Using PRAN-Net," *Applied Sciences*, vol. 10, no. 23, Nov. 2020, doi: 10.3390/app10238434.
- [5] S. Zhao, L. Yin, J. Zhang, J. Wang, and R. Zhong, "Real-time fabric defect detection based on multi-scale convolutional neural network," *IET Collaborative Intelligent Manufacturing*, vol. 2, no. 4, pp. 189–196, 2020, doi: 10.1049/iet-cim.2020.0062.
- [6] B. Li, Y. Zou, R. Zhu, W. Yao, J. Wang, and S. Wan, "Fabric Defect Segmentation System Based on a Lightweight GAN for Industrial Internet of Things," *Wireless Communications and Mobile Computing*, vol. 2022, no. 1, p. 9680519, 2022, doi: 10.1155/2022/9680519.
- [7] D. Jokić, "FAD-Enhanced Visual Tracking for Textile Defect Detection: A Multispectral Feature Fusion Approach," *Textile & Leather Review*, vol. 9, pp. 587–615, Mar. 2026, doi: 10.31881/TLR.2026.587.
- [8] W. Wu, Z. Zhang, Z. Xiang, and M. Qian, "Texture-Adaptive Fabric Defect Detection via Dynamic Subspace Feature Extraction and Luminance Reconstruction," *Algorithms*, vol. 18, no. 10, Oct. 2025, doi: 10.3390/a18100638.
- [9] M. Li, P. Ye, Z. Li, S. Cui, P. Zhu, and J. Liu, "An efficient CNN-Mamba hybrid network for fabric defect segmentation," *Results in Engineering*, vol. 28, p. 107493, Dec. 2025, doi: 10.1016/j.rineng.2025.107493.
- [10] R. Carrilho, K. A. Hambarde, and H. Proença, "A Novel Dataset for Fabric Defect Detection: Bridging Gaps in Anomaly Detection," *Applied Sciences*, vol. 14, no. 12, Jun. 2024, doi: 10.3390/app14125298.
- [11] M. Nasim, R. Mumtaz, M. Ahmad, and A. Ali, "Fabric Defect Detection in Real World Manufacturing Using Deep Learning," *Information*, vol. 15, no. 8, Aug. 2024, doi: 10.3390/info15080476.
- [12] A. Das and A. Deka, "YMaskNet: A Deep Learning Based Handloom Fabric Defect Detection Technique," *J. Eur. Syst. Autom.*, vol. 58, no. 10, pp. 2079–2088, 2025, doi: 10.18280/jesa.581008.
- [13] H. Kim, W.-K. Jung, Y.-C. Park, J.-W. Lee, and S.-H. Ahn, "Broken stitch detection method for sewing operation using CNN feature map and image-processing techniques," *Expert Systems with Applications*, vol. 188, p. 116014, Feb. 2022, doi: 10.1016/j.eswa.2021.116014.
- [14] E. A. Wibowo, Widyastuti, and L. F. Hamdi, "Desain Sistem Pendeteksi Nominal dan Keaslian Uang untuk Tunanetra Berbasis Sensor Optik-UV dengan Pendekatan Value Engineering," *Jurnal Teknologi dan Manajemen Industri Terapan*, vol. 4, no. 4, pp. 2102–2112, Dec. 2025, doi: 10.55826/jtmit.v4i4.1321.
- [15] W. Widyastuti, E. A. Wibowo, A. Dicasani, and E. Ernawati, "kansei wire stripper untuk pemilahan sampah kabel di sektor informal," *Jurnal Teknik Industri Terintegrasi (JUTIN)*, vol. 8, no. 1, pp. 585–591, Jan. 2025, doi: 10.31004/jutin.v8i1.39943.
- [16] E. A. Wibowo, M. N. W. Hidayah, G. M. Munandar, R. Ardiyansah, and N. F. Rahmawati, "Desain inovatif alat pemotong ring AMDK gelas plastik: Meningkatkan efisiensi dan keamanan proses daur ulang di sektor informal dengan pendekatan value engineering," *Jurnal Teknik Industri Terintegrasi (JUTIN)*, vol. 8, no. 1, pp. 807–813, Jan. 2025, doi: 10.31004/jutin.v8i1.40635.
- [17] M. J. Page *et al.*, "The PRISMA 2020 statement: an updated guideline for reporting systematic reviews," Mar. 2021, doi: 10.1136/bmj.n71.
- [18] E. A. Wibowo, W. Widyastuti, L. F. Hamdi, G. T. Chanafi, W. A. Fadhi, and I. Betanursanti, "Potensi Sensor Optik dan UV Untuk Deteksi Mata Uang: Tinjauan Pustaka," *Jurnal Inovasi Teknik Industri*, vol. 4, no. 1, pp. 124–135, Jun. 2025, doi: 10.26753/jitin.v4i1.1707.
- [19] Y. Hu *et al.*, "A novel deep learning network for fabric defect detection based on the improved YOLOv9s model," in *Third International Conference on Electrical, Electronics, and Information Engineering (EEIE 2024)*, SPIE, Jan. 2025, p. 432. doi: 10.1117/12.3057265.

- [20] X. Wang and Y. Bi, "A Real-Time Textile Defect Inspection System for Industrial Polyester Reinforcement Layers Based on YOLO and PLC-Driven Closed-Loop Control," *IEEE Access*, vol. 14, pp. 33873–33889, 2026, doi: 10.1109/ACCESS.2026.3669364.
- [21] Q. Liu, C. Wang, Y. Li, M. Gao, and J. Li, "A Fabric Defect Detection Method Based on Deep Learning," *IEEE Access*, vol. 10, pp. 4284–4296, 2022, doi: 10.1109/ACCESS.2021.3140118.
- [22] X. Luo, Q. Ni, R. Tao, and Y. Shi, "A Lightweight Detector Based on Attention Mechanism for Fabric Defect Detection," *IEEE Access*, vol. 11, pp. 33554–33569, 2023, doi: 10.1109/ACCESS.2023.3264262.
- [23] Y. Wang, Z. Hao, F. Zuo, and S. Pan, "A Fabric Defect Detection System Based Improved YOLOv5 Detector," *J. Phys.: Conf. Ser.*, vol. 2010, no. 1, p. 012191, Sep. 2021, doi: 10.1088/1742-6596/2010/1/012191.
- [24] S. Ma, Y. Liu, and Y. Zhang, "Fabric Defect Detection Based on Improved Lightweight YOLOv8n," *Applied Sciences*, vol. 14, no. 17, Sep. 2024, doi: 10.3390/app14178000.
- [25] Q. Sun, B. Noche, Z. Xie, and B. Huang, "Research on Seamless Fabric Defect Detection Based on Improved YOLOv8n," *Applied Sciences*, vol. 15, no. 5, Mar. 2025, doi: 10.3390/app15052728.
- [26] Y. Jin *et al.*, "A Real-Time Fabric Defect Detection Method Based on Improved YOLOv8," *Applied Sciences*, vol. 15, no. 6, Mar. 2025, doi: 10.3390/app15063228.
- [27] F. P. Dharma, M. L. Singgih, and D. D. Prastyo, "Beyond architecture: Hyperparameter optimization for YOLOv8m in multi-class textile defect detection," *Results in Engineering*, vol. 28, p. 108356, Dec. 2025, doi: 10.1016/j.rineng.2025.108356.
- [28] H. Kim, W.-K. Jung, Y.-C. Park, J.-W. Lee, and S.-H. Ahn, "Broken stitch detection method for sewing operation using CNN feature map and image-processing techniques," *Expert Systems with Applications*, vol. 188, p. 116014, Feb. 2022, doi: 10.1016/j.eswa.2021.116014.
- [29] G. Zhou, S. Yan, X. Yan, and C. Zhu, "Sensing application of double rectangular root and ring nanocavities in MIM waveguides," in *Fifth International Conference on Mechanical Engineering, Intelligent Manufacturing, and Mechatronics (MEIMM 2024)*, SPIE, Dec. 2024, pp. 62–68. doi: 10.1117/12.3057366.
- [30] J. Chen, Y. Xiao, W. Li, B. Wang, and G. Wang, "Research on Textile Tiny Defective Targets Detection Method Based on YOLO-GCW," *Electronics*, vol. 14, no. 3, Jan. 2025, doi: 10.3390/electronics14030480.
- [31] R. Machado, L. A. M. Barros, V. Vieira, F. D. da Silva, H. Costa, and V. Carvalho, "Textile Defect Detection Using Artificial Intelligence and Computer Vision—A Preliminary Deep Learning Approach," *Electronics*, vol. 14, no. 18, Sep. 2025, doi: 10.3390/electronics14183692.
- [32] Y. Mao, G. Wang, Y. Ma, and X. Gui, "Enhancing Fabric Defect Detection With Attention Mechanisms and Optimized YOLOv8 Framework," *IEEE Access*, vol. 13, pp. 96767–96781, 2025, doi: 10.1109/ACCESS.2025.3570455.
- [33] N. Bao, J. Lin, Y. Fan, R. Bao, and A. Simeone, "FabricMamba: A fabric surface defect detection system based on large kernel attention and visual state space," *Engineering Applications of Artificial Intelligence*, vol. 162, p. 112558, Dec. 2025, doi: 10.1016/j.engappai.2025.112558.
- [34] K. Yu *et al.*, "Fa-Yolo: A High-Precision and Efficient Method for Fabric Defect Detection in Textile Industry," Nov. 09, 2022, *Social Science Research Network, Rochester, NY*: 4272230. doi: 10.2139/ssrn.4272230.
- [35] Z. Huang, J. Wang, C. Li, and M. Yu, "FDDNet: Fabric defect detection with spatial depth-transforming convolution and multiscale dilated self-attention fusion module," *Journal of Engineered Fibers and Fabrics*, vol. 20, p. 15589250251394004, Jun. 2025, doi: 10.1177/15589250251394004.
- [36] H. Lv, H. Zhang, M. Wang, J. Xu, X. Li, and C. Liu, "Hyperspectral Imaging Based Nonwoven Fabric Defect Detection Method Using LL-YOLOv5," *IEEE Access*, vol. 12, pp. 41988–41998, 2024, doi: 10.1109/ACCESS.2024.3378739.
- [37] Y. Ji and L. Di, "Textile defect detection based on multi-proportion spatial attention mechanism and channel memory feature fusion network," *IET Image Processing*, vol. 18, no. 2, pp. 412–427, 2024, doi: 10.1049/ipr2.12957.
- [38] Z. Xu, Y. Bao, and B. Tian, "Improved YOLOv8 garment sewing defect detection method based on attention mechanism," *Journal of Measurements in Engineering*, vol. 12, no. 4, pp. 706–721, Dec. 2024, doi: 10.21595/jme.2024.24283.
- [39] M. Nasim, R. Mumtaz, M. Ahmad, and A. Ali, "Fabric Defect Detection in Real World Manufacturing Using Deep Learning," *Information*, vol. 15, no. 8, Aug. 2024, doi: 10.3390/info15080476.
- [40] S. Guo and S. Tong, "IR-YOLOv7-Tiny: A Lightweight and Robust Framework for Fabric-Defect Detection," *Sensors*, vol. 26, no. 4, Feb. 2026, doi: 10.3390/s26041094.
- [41] J. Jing, D. Zhuo, H. Zhang, Y. Liang, and M. Zheng, "Fabric defect detection using the improved YOLOv3 model," *Journal of Engineered Fibers and Fabrics*, vol. 15, p. 1558925020908268, Jan. 2020, doi: 10.1177/1558925020908268.

- [42] X. Kang, "Research on fabric defect detection method based on lightweight network," *Journal of Engineered Fibers and Fabrics*, vol. 19, p. 15589250241232153, Apr. 2024, doi: 10.1177/15589250241232153.
- [43] R. Jin and Q. Niu, "Automatic Fabric Defect Detection Based on an Improved YOLOv5," *Mathematical Problems in Engineering*, vol. 2021, no. 1, p. 7321394, 2021, doi: 10.1155/2021/7321394.
- [44] C. Xuan, W. Shi, L. Sun, J. Wu, Y. Zhang, and J. Tu, "Improved YOLOv9 with Dual Convolution and LSKA Attention for Robust Small Defect Detection in Textiles," *Processes*, vol. 14, no. 1, Jan. 2026, doi: 10.3390/pr14010149.
- [45] J. Chen *et al.*, "SDLS-YOLO: An ultra-lightweight real-time fabric defect detection algorithm based on multi-module coupling," *J. King Saud Univ. Comput. Inf. Sci.*, vol. 38, no. 1, p. 7, Dec. 2025, doi: 10.1007/s44443-025-00376-w.
- [46] Z. Su, H. Zhang, P. Li, H. Zhang, and Y. Lu, "A lightweight model for digital printing fabric defect detection based on YOLOX," *Journal of Engineered Fibers and Fabrics*, vol. 18, p. 15589250231208702, Jan. 2023, doi: 10.1177/15589250231208702.
- [47] G. Lu, T. Xiong, and G. Wu, "YOLO-BGS Optimizes Textile Production Processes: Enhancing YOLOv8n with Bi-Directional Feature Pyramid Network and Global and Shuffle Attention Mechanisms for Efficient Fabric Defect Detection," *Sustainability*, vol. 16, no. 18, Sep. 2024, doi: 10.3390/su16187922.
- [48] W. Song, D. Lang, J. Zhang, M. Zheng, and X. Li, "Textile Defect Detection Algorithm Based on the Improved YOLOv8," *IEEE Access*, vol. 13, pp. 11217–11231, 2025, doi: 10.1109/ACCESS.2025.3528771.
- [49] S. Kang and M. Yang, "FD-YOLO: An Attention-Augmented Lightweight Network for Real-Time Industrial Fabric Defect Detection," *CMC*, vol. 86, no. 2, pp. 1–23, 2025, doi: 10.32604/cmc.2025.071488.
- [50] J. Wang *et al.*, "YOLO-DD: Improved YOLOv5 for Defect Detection," *CMC*, vol. 78, no. 1, pp. 759–780, 2024, doi: 10.32604/cmc.2023.041600.
- [51] G. Liang, S. Yu, and S. Han, "RT-DETR-FFD: A Knowledge Distillation-Enhanced Lightweight Model for Printed Fabric Defect Detection," *Electronics*, vol. 14, no. 14, Jul. 2025, doi: 10.3390/electronics14142789.
- [52] S. A. Hassan, M. J. Beliatas, A. Radziwon, A. Menciassi, and C. M. Oddo, "Textile Fabric Defect Detection Using Enhanced Deep Convolutional Neural Network with Safe Human–Robot Collaborative Interaction," *Electronics*, vol. 13, no. 21, Nov. 2024, doi: 10.3390/electronics13214314.
- [53] D. Jokić, "Deep-Learning-Based Probabilistic Graphical Models for Automated Defect Detection in Smart Textile Manufacturing," *Textile & Leather Review*, vol. 8, pp. 925–939, Dec. 2025, doi: 10.31881/TLR.2025.925.
- [54] W. Shi, K. Lv, C. Xuan, and J. Wu, "MSC-DeepLabV3+: A Segmentation Model for Slender Fabric Roll Seam Detection," *CMC*, vol. 87, no. 2, 2026, doi: 10.32604/cmc.2025.075203.