

### Analisis Dinamika Fungsi Loss dalam Pelatihan Model Deteksi Objek Berbasis YOLO: Studi Konvergensi, Generalisasi, dan Anomali Data pada Log Pelatihan 100 Epoch

Akramunnisa<sup>1</sup>, Dianradika Prasti<sup>2</sup>, Muhammad Idham Rusdi<sup>3</sup>, Erwin Sukma<sup>4</sup>  
<sup>1234</sup> Universitas Cokroaminoto Palopo

<sup>1</sup>akramunnisa@uncp.ac.id,

<sup>2</sup>dianradika@uncp.ac.id.,

<sup>3</sup>idhamrusdi@uncp.ac.id


<sup>4</sup>erwin.sukma817@gmail.com

#### Article Info

##### Kata Kunci:

YOLO, deteksi objek,  
box loss,  
classification loss,  
distribution focal  
loss, kurva pelatihan,  
generalisasi

Copyright © 2026  
The Author(s)



Lisensi: cc-by-sa

#### Abstrak

Penelitian ini menyajikan kajian kuantitatif atas catatan (*log*) proses pelatihan sebuah model deteksi objek berbasis arsitektur YOLO (*You Only Look Once*) sepanjang 100 epoch, dengan fokus kajian pada tiga komponen fungsi *loss*, yaitu *box loss*, *classification loss*, dan *distribution focal loss*, pada masing-masing partisi data latih dan data validasi. Metode analisis yang digunakan meliputi statistik deskriptif, visualisasi tren, deteksi *outlier* berbasis metode *Interquartile Range* (IQR), serta analisis korelasi antarvariabel. Hasil kajian menunjukkan bahwa *classification loss* dan *distribution focal loss* menunjukkan pola konvergensi yang baik pada kedua partisi data, sementara *box loss* pada data validasi cenderung stagnan pada nilai yang relatif tinggi, sebuah indikasi yang mengarah pada kemungkinan terjadinya kesenjangan generalisasi pada model. Selain itu, teridentifikasi pula sejumlah titik data yang menyimpang secara signifikan dari pola tren lokalnya, yang secara lebih kuat diduga merupakan kesalahan pemformatan angka dibandingkan representasi fenomena pelatihan yang aktual. Berdasarkan temuan tersebut, penelitian ini merekomendasikan perlunya audit kualitas data *log* secara sistematis serta penerapan ukuran statistik yang tahan terhadap *outlier* (*outlier-robust*) dalam praktik pemantauan pelatihan model ke depannya.

## PENDAHULUAN

Deteksi objek merupakan salah satu tugas fundamental dalam bidang *Computer Vision* (CV) yang bertujuan mengidentifikasi lokasi dan kategori objek di dalam sebuah citra. Salah satu arsitektur yang paling banyak diadopsi baik di lingkungan akademik maupun industri adalah YOLO (*You Only Look Once*), yang dikenal karena kemampuannya melakukan deteksi secara *real-time* dengan akurasi yang kompetitif. Performa YOLO sangat bergantung pada proses optimisasi fungsi *loss* selama pelatihan, di mana penurunan nilai *loss* dari waktu ke waktu (epocih) menjadi indikator utama bahwa model sedang mempelajari representasi yang bermakna dari data latih.

Pada YOLOv2, total *loss* didekomposisi menjadi tiga komponen: box *loss*, classification *loss*, dan distribution focal *loss* (DFL). Box *loss* mengukur akurasi prediksi posisi dan dimensi bounding box terhadap ground truth menggunakan varian IoU seperti CIoU, yang mempertimbangkan tumpang tindih, jarak titik pusat, dan rasio aspek. Classification *loss* mengukur kesalahan penentuan kelas objek, umumnya dihitung dengan Binary Cross-Entropy atau Focal Loss untuk mengatasi ketidakseimbangan proporsi objek dan latar belakang. Adapun DFL merepresentasikan posisi tepi bounding box sebagai distribusi probabilitas, bukan nilai tunggal, sehingga model dapat menangkap ketidakpastian batas objek secara lebih adaptif dan menghasilkan estimasi lokasi yang lebih akurat, terutama pada objek dengan batas kurang jelas akibat oklusi atau blur.

Meskipun visualisasi kurva *loss* telah menjadi praktik standar dalam pemantauan pelatihan model, interpretasi kurva tersebut sering dilakukan secara sepintas tanpa analisis kuantitatif yang memadai. Padahal, pembacaan yang cermat terhadap dinamika *loss* dapat mengungkap berbagai fenomena penting, seperti *overfitting*, ketidakstabilan optimisasi, maupun anomali pada proses pencatatan data itu sendiri. Penelitian ini berfokus pada rumusan masalah: (1) bagaimana pola penurunan ketiga komponen *loss* pada data latih; (2) apakah terdapat kesenjangan generalisasi antara data latih dan validasi; (3) apakah terdapat anomali pada data log; dan (4) bagaimana korelasi antarkomponen *loss*.

Tujuan penelitian ini adalah mendeskripsikan secara kuantitatif tren setiap komponen *loss*, mengevaluasi indikasi generalisasi model, mengidentifikasi anomali pada data *log* menggunakan metode statistik baku, serta merumuskan rekomendasi praktis bagi peneliti dan praktisi yang bekerja dengan log pelatihan model deteksi objek. Secara teoretis, penelitian ini memperkaya literatur mengenai analisis kuantitatif dinamika pelatihan model deep learning. Secara praktis, temuan ini dapat dijadikan rujukan bagi tim pengembang model visi komputer dalam menyusun prosedur pemantauan dan penjaminan kualitas data pelatihan yang lebih andal.

YOLO memandang deteksi objek sebagai satu persoalan regresi tunggal yang memetakan piksel citra ke koordinat bounding box dan probabilitas kelas, dengan setiap komponen *loss* mengoptimalkan aspek berbeda secara simultan. Box *loss* menggunakan varian CIoU yang mempertimbangkan jarak pusat, rasio aspek, dan tumpang tindih untuk mempercepat konvergensi (Zheng et al., 2020). Classification *loss* berbasis binary cross-entropy, kadang dimodifikasi menjadi Focal Loss untuk mengatasi ketidakseimbangan contoh latar depan-belakang (Lin et al., 2017).

Distribution focal loss merepresentasikan posisi tepi bounding box sebagai distribusi probabilitas, sehingga estimasi lokasi lebih presisi dan mampu menangkap ketidakpastian akibat oklusi atau citra buram (Li et al., 2020).

Kurva loss terhadap epoch merupakan salah satu alat diagnostik paling mendasar dalam pengembangan model deep learning, karena memplot performa model pada data latih dan data validasi secara bersamaan sehingga memungkinkan identifikasi pola underfitting, overfitting, maupun kecocokan yang baik (good fit). Pola penurunan loss data latih yang konsisten umumnya mengindikasikan proses optimisasi berjalan sebagaimana mestinya, namun tidak secara langsung menjamin peningkatan generalisasi model. Ketika loss validasi berhenti menurun atau bahkan meningkat sementara loss latih terus menurun, kondisi tersebut umumnya diinterpretasikan sebagai indikasi overfitting, yaitu model yang berkinerja baik pada data latih namun gagal melakukan generalisasi pada data baru (Viering & Loog, 2023).

Data log pelatihan tidak luput dari risiko kesalahan pencatatan maupun gangguan teknis pada pipeline logging, sehingga diperlukan metode identifikasi titik data yang menyimpang signifikan dari sebaran mayoritas data. Interquartile range (IQR) merupakan pendekatan non-parametrik yang umum digunakan untuk tujuan tersebut, dengan sebuah nilai diklasifikasikan sebagai outlier apabila berada di bawah  $Q_1 - 1,5 \times IQR$  atau di atas  $Q_3 + 1,5 \times IQR$ ; meskipun demikian, aturan fence dengan koefisien tetap ( $k = 1,5$ ) ini tidak memperhitungkan ukuran sampel dan karakteristik distribusi data, sehingga berpotensi menandai terlalu banyak titik sebagai outlier pada sampel besar (Lin et al., 2025).

## METODE

### Jenis Penelitian

Penelitian ini menggunakan pendekatan kuantitatif deskriptif berbasis analisis data sekunder, yaitu penelitian yang berfokus pada pengolahan dan interpretasi data log pelatihan model yang telah tersedia, tanpa melakukan pelatihan ulang model. Pendekatan ini dipilih karena tujuan utama penelitian adalah mengungkap pola, tren, dan anomali pada data yang sudah ada secara sistematis dan terukur.

### Sumber dan Objek Penelitian

Data yang dianalisis berupa berkas hasil uji data latih yang dihasilkan oleh proses pelatihan model deteksi objek berbasis YOLO, terdiri atas 100 baris data yang merepresentasikan 100 epoch pelatihan dan 7 kolom, yaitu *epoch*, *train/box\_loss*, *train/cls\_loss*, *train/dfl\_loss*, *val/box\_loss*, *val/cls\_loss*, dan *val/dfl\_loss*. Objek penelitian adalah dinamika numerik dari keenam variabel loss tersebut sepanjang proses pelatihan.

### Tahapan Penelitian

#### 1. Pengumpulan dan Pembersihan Data

- Memeriksa struktur dan format berkas log pelatihan.
- Mengidentifikasi missing value, nilai yang hilang atau tidak wajar pada data.

#### 2. Analisis Statistik Deskriptif

- a. Menghitung rerata, median, simpangan baku, serta nilai minimum dan maksimum untuk setiap *variabel loss*.
  - b. Menghitung reduksi loss antara median *epoch* awal dan median *epoch* akhir.
- 3. Visualisasi dan Analisis Tren**
- a. Membuat kurva *loss* terhadap *epoch* untuk data latih dan data validasi.
  - b. Membandingkan pola tren antara kedua partisi data untuk menilai indikasi generalisasi.
- 4. Deteksi Outlier dan Analisis Korelasi**
- a. Menerapkan metode IQR ( $1,5 \times \text{IQR}$ ) pada setiap variabel *loss* untuk mengidentifikasi anomali.
  - b. Menghitung korelasi Pearson antarvariabel *loss* untuk menilai keterkaitan antarkomponen.

### Teknik Pengumpulan Data

Adapun teknik pengumpulan data yang dikumpulkan secara otomatis oleh *pipeline* pelatihan model YOLO26 dalam bentuk uji data latih yang mencatat nilai *loss* pada akhir setiap *epoch*. Data ini bersifat sekunder dan diperoleh langsung dari hasil proses pelatihan yang telah dijalankan sebelumnya.

### Teknik Analisis Data

Analisis dilakukan menggunakan bahasa pemrograman *Python* dengan pustaka *pandas* untuk pengolahan data dan *matplotlib* untuk visualisasi. Pemilihan median sebagai ukuran pemusatan utama dalam analisis reduksi *loss* didasarkan pada pertimbangan bahwa median lebih tahan terhadap pengaruh *outlier* ekstrem yang teridentifikasi dalam data.

## HASIL

### Statistik Deskriptif

Statistik deskriptif untuk keenam variabel *loss* yang dianalisis yang berupa *train/box\_loss*, *train/cls\_loss*, *train/dfl\_loss*, *val/box\_loss*, *val/cls\_loss*, dan *val/dfl\_loss*. Pada tabel 1 dibawah merupakan rincian hasil dari rerata, median, standar deviasi, nilai minimum, nilai maksimum dan hasil presentase dari reduksi median dari keenam variabel *loss*. Nilai simpangan baku yang sangat besar dibandingkan mediannya pada *train/cls\_loss* dan *val/cls\_loss* mengindikasikan sebaran yang sangat tidak simetris, konsisten dengan pola *loss* yang sangat tinggi pada *epoch-epoch* awal pelatihan kemudian menurun tajam yang terlihat pada tabel 1 berikut.


Tabel 1. Ringkasan statistik deskriptif variabel *loss* (n = 100 epoch)

| Variabel              | Rerata | Median | Std. Dev. | Min   | Maks   | Reduksi Median (%) |
|-----------------------|--------|--------|-----------|-------|--------|--------------------|
| <i>train/box_loss</i> | 59,61  | 11,94  | 60,24     | 0,64  | 159,02 | 99,55              |
| <i>train/cls_loss</i> | 17,45  | 0,59   | 58,53     | 0,22  | 409,15 | 99,88              |
| <i>train/dfl_loss</i> | 0,013  | 0,013  | 0,003     | 0,010 | 0,021  | 47,26              |
| <i>val/box_loss</i>   | 102,47 | 107,07 | 26,67     | 1,06  | 138,17 | 12,25              |

|                     |       |       |       |       |        |       |
|---------------------|-------|-------|-------|-------|--------|-------|
| <i>val/cls_loss</i> | 8,02  | 0,60  | 35,43 | 0,52  | 266,46 | 99,49 |
| <i>val/dfl_loss</i> | 0,015 | 0,014 | 0,001 | 0,013 | 0,020  | 14,68 |

### Tren Box Loss: Data Latih vs Validasi

Analisis tren *Box loss* pada data latih menurun tajam dan konsisten sepanjang pelatihan, dari kisaran 140–160 pada *epoch* awal menjadi konsisten di bawah 1 setelah *epoch* ke-54. Sebaliknya, *box loss* data validasi bertahan pada kisaran 100–125 hampir sepanjang 100 *epoch* tanpa tren penurunan yang jelas, diselingi beberapa titik anomali yang turun tajam sebelum kembali melonjak pada *epoch* berikutnya.




Gambar 1. Perbandingan Kurva *Box Loss* Data Latih dan Validasi

Sumber: Hasil Olah Data Penulis (2026)

Pada gambar 1 diatas menunjukkan grafik yang menggambarkan pola stagnasi *box loss* validasi pada level tinggi, berdampingan dengan penurunan *box loss* latih yang sangat tajam, merupakan indikasi kesenjangan generalisasi pada aspek lokalisasi *bouding box*. Pada gambar 1 diatas menunjukkan kemungkinan penjelasan lain yang menunjukkan adanya inkonsistensi pada skala pencatatan data validasi itu sendiri, sebagaimana dibahas pada bagian 4.5.

### Tren Classification Loss: Data Latih vs Validasi

Analisisi Tren *classification loss* disajikan dalam skala logaritmik mengingat rentang nilainya yang sangat lebar. Baik *classification loss* data latih maupun validasi menunjukkan pola penurunan yang sejalan, turun sangat tajam dalam sepuluh *epoch* pertama dan selanjutnya melandai menuju nilai stabil di bawah 1, dengan reduksi median mencapai 99,88% (latih) dan 99,49% (validasi).




Gambar 2. Perbandingan kurva *classification loss* (skala logaritmik)

Sumber: Hasil Olah Data Penulis (2026)

Pada gambar 2 diatas menunjukkan grafik *classification loss* (skala log) untuk data latih dan validasi sepanjang 100 epoch, dengan penurunan tajam pada fase awal yang diselingi satu lonjakan anomali pada validasi di sekitar epoch 11–12—pola paku tunggal yang lebih mungkin merupakan artefak pemformatan angka pada log ketimbang fenomena pelatihan sesungguhnya. Setelah fase awal tersebut, kedua kurva menurun stabil dan bergerak berdampingan dengan gap kecil hingga sekitar epoch 90, mengindikasikan proses optimisasi yang sehat tanpa overfitting signifikan, sebelum akhirnya loss latih turun lebih tajam ke bawah 0,3 sementara loss validasi stagnan di sekitar 0,5–0,6 pada fase akhir, menandakan mulai munculnya sedikit indikasi overfitting menjelang akhir pelatihan..

### Tren Distribution Focal Loss: Data Latih vs Validasi

Analisis Tren *distribution focal loss* berada pada rentang nilai yang jauh lebih sempit (0,010–0,021) dibandingkan dua komponen lainnya, dengan tren penurunan yang lebih moderat: 47,26% (latih) dan 14,68% (validasi). Pada gambar 3 dibawah ini menunjukkan kedua kurva relatif berhimpit dan stabil sepanjang pelatihan.



Gambar 3. Perbandingan Kurva *Distribution Focal Loss* Data Latih dan Validasi  
Sumber: Hasil Olah Data Penulis (2026)

Pada gambar 3 diatas menunjukkan grafik *distribution focal loss* (DFL) untuk data latih dan validasi sepanjang 100 epoch pada skala linear, dengan kedua kurva menurun secara konsisten dan relatif mulus tanpa lonjakan anomali ekstrem seperti pada *classification loss* sebelumnya, meski lioss validasi menampilkan fluktuasi (noise) yang lebih besar dengan satu puncak kecil di sekitar epoch 14–15. *Loss* latih menurun lebih tajam dari sekitar 0,021 menjadi mendekati 0,010, sementara *loss* validasi menurun lebih landai dan mulai menstabil di kisaran 0,014 sejak sekitar epoch 60 hingga akhir pelatihan. Gap antara kedua kurva yang melebar secara bertahap—*loss* latih terus turun sementara *loss* validasi mendatar—mengindikasikan pola konvergensi yang baik secara keseluruhan namun disertai indikasi *overfitting* ringan menjelang akhir pelatihan, serupa dengan pola yang teramati pada *classification loss*.


### Deteksi dan Karakterisasi Anomali Data

Penerapan metode IQR mengungkap sejumlah titik data yang menyimpang signifikan dari sebaran mayoritas. Pola yang patut mendapat perhatian khusus teramati pada *val/box\_loss*, di mana sebelas titik data terdeteksi sebagai outlier yang tersebar sporadis, dengan nilai yang tiba-tiba anjlok sebelum kembali ke kisaran semula pada epoch berikutnya, pola yang lebih mungkin disebabkan oleh artefak pemformatan angka ketimbang dinamika pelatihan yang sesungguhnya.

Tabel 2. Ringkasan Hasil Deteksi *Outlier* Berbasis Metode Iqr

| Variabel       | Jumlah Outlier | Interpretasi                              |
|----------------|----------------|-------------------------------------------|
| train/box_loss | 0              | Tren mulus, tidak ada anomali             |
| train/cls_loss | 10             | Dinamika awal pelatihan yang wajar        |
| train/dfl_loss | 0              | Tren mulus, tidak ada anomali             |
| val/box_loss   | 11             | Kemungkinan artefak data                  |
| val/cls_loss   | 11             | Sebagian wajar, sebagian perlu verifikasi |
| val/dfl_loss   | 3              | Fluktuasi kecil, dampak minor             |

Tabel 2 di atas menunjukkan komponen loss pada data latih (box dan dfl) tidak memiliki outlier dan tren mulus, sementara classification loss pada data latih memiliki 10 outlier yang wajar akibat dinamika awal pelatihan; pada data validasi, box loss dan classification loss masing-masing memiliki 11 outlier yang mengindikasikan kemungkinan artefak data dan perlu diverifikasi, sedangkan dfl loss validasi hanya memiliki 3 outlier dengan dampak minor.




Gambar 4. Diagram Kotak Nilai Terstandarisasi (Z-Score) Keenam Variabel Loss  
Sumber: Hasil olah data penulis (2026)

Pada gambar 4 di atas menunjukkan Grafik boxplot ini berupa distribusi z-score dari enam variabel loss (Box, Cls, DFL untuk training dan validasi) selama proses training model. Sebagian besar loss cukup stabil di sekitar nol, tetapi Tr-Cls dan Val-Cls memiliki banyak outlier tinggi (hingga z-score 6-7), sementara Val-Box memiliki outlier ekstrem rendah (sekitar -3.5 hingga -4), menandakan adanya beberapa epoch dengan lonjakan atau penurunan loss yang tidak biasa.

### Analisis Korelasi Antarvariabel Loss

Analisis Korelasi positif yang kuat teramati antara *train/box\_loss* dan *train/cls\_loss*, mengindikasikan kedua komponen menurun bersamaan sepanjang pelatihan. Korelasi antara variabel data latih dan variabel data validasi yang bersesuaian juga tergolong positif, memperkuat temuan bahwa komponen klasifikasi menggeneralisasi dengan baik. Sebaliknya, *val/box\_loss* menunjukkan korelasi yang jauh lebih lemah dengan variabel lain.





Gambar 5. Matriks Korelasi Pearson Antara Keenam Variabel Loss

Sumber: Hasil Olah Data Penulis (2026)

Pada gambar 5 ini menunjukkan korelasi antar enam variabel loss selama training, di mana train/df\_loss berkorelasi kuat dengan train/box\_loss (0.84) dan val/df\_loss (0.83), serta train/cls\_loss berkorelasi tinggi dengan val/cls\_loss (0.84), menandakan variabel-variabel tersebut cenderung bergerak bersamaan; sementara val/box\_loss hampir tidak berkorelasi dengan variabel lain (nilai mendekati 0), menunjukkan pola pergerakannya relatif independen.

### Manfaat dan Implikasi bagi Praktik Pemantauan Model

Temuan dalam penelitian ini memberikan beberapa manfaat nyata bagi praktik pengembangan model deteksi objek, antara lain:

- Diagnosis lebih akurat: memisahkan gejala overfitting yang sesungguhnya dari artefak kualitas data pada kurva loss.
- Dasar pengambilan keputusan: memberikan acuan kuantitatif untuk pemilihan checkpoint model terbaik, bukan sekadar pembacaan visual.
- Penjaminan kualitas data: menegaskan perlunya validasi otomatis pada pipeline logging pelatihan model.

### SIMPULAN

Berdasarkan analisis terhadap log pelatihan model deteksi objek berbasis YOLO sepanjang 100 epoch, dapat disimpulkan beberapa hal sebagai berikut:

- Classification loss dan distribution focal loss menunjukkan konvergensi yang baik, dengan pola penurunan yang konsisten antara data latih dan data validasi.
- Box loss menunjukkan pola yang lebih kompleks, ditandai penurunan tajam pada data latih yang tidak diikuti penurunan serupa pada data validasi, mengindikasikan potensi kesenjangan generalisasi.
- Ditemukan sejumlah titik data yang menyimpang tajam dan tidak konsisten dengan dinamika optimisasi yang wajar, yang lebih mungkin merupakan artefak kualitas data ketimbang fenomena pelatihan yang sesungguhnya.

Penelitian ini menegaskan bahwa analisis kuantitatif dan sistematis terhadap log pelatihan, yang melampaui sekadar pembacaan visual kurva loss, merupakan langkah penting dalam praktik pengembangan model deep learning yang andal. Metodologi yang digunakan statistik deskriptif, analisis tren, deteksi outlier berbasis IQR, dan analisis korelasi dapat diadopsi sebagai bagian dari prosedur baku evaluasi kualitas proses pelatihan model deteksi objek.

#### DAFTAR PUSTAKA

- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. arXiv preprint.
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). Ultralytics YOLO (Version 8.0) [Software]. Ultralytics.
- Li, X., Wang, W., Wu, L., Chen, S., Hu, X., Li, J., Tang, J., & Yang, J. (2020). Generalized focal loss: Learning qualified and distributed bounding boxes for dense object detection. *Advances in Neural Information Processing Systems (NeurIPS)*, 33, 21002–21012.
- Lin, T.-Y., Goyal, P., Girshick, R., He, K., & Dollár, P. (2017). Focal loss for dense object detection. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 2980–2988. <https://doi.org/10.1109/ICCV.2017.324>
- Lin, H., Zhang, R., & Tong, T. (2025). When Tukey meets Chauvenet: A new boxplot criterion for outlier detection. *Journal of Computational and Graphical Statistics*. <https://doi.org/10.1080/10618600.2025.2520577>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Viering, T., & Loog, M. (2023). The shape of learning curves: A review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(6), 7799–7819. <https://doi.org/10.1109/TPAMI.2022.3220744>
- Zheng, Z., Wang, P., Liu, W., Li, J., Ye, R., & Ren, D. (2020). Distance-IoU loss: Faster and better learning for bounding box regression. *Proceedings of the AAAI Conference on Artificial Intelligence*, 34(07), 12993–13000. <https://doi.org/10.1609/aaai.v34i07.6999>